



## مرور کلی بر کاربرد روش‌های پیشرفته هوش محاسباتی در اکتشاف منابع معدنی

حبیب اله بازدار، هادی فتاحی\* و فریدون قدیمی

دانشکده مهندسی معدن، دانشگاه صنعتی اراک، اراک، ایران

دریافت مقاله: ۱۳۹۴/۰۴/۱۹، پذیرش: ۱۳۹۴/۱۲/۲۲

### چکیده

علوم زمین به‌طور عمومی و اکتشاف منابع معدنی به‌خصوص، به دلیل پیچیدگی‌هایی که دارد و نیز عوامل تأثیرگذار و دخیل در آن، همواره جزو علمی بوده است که احاطه بر تمام ویژگی‌های آن یا ناممکن بوده و یا بسیار مشکل است. به دلیل دشواری بودن اندازه‌گیری دقیق مؤلفه‌ها و مرزبندی آنها، در چند سال اخیر سعی شده است برای رفع این نوع مشکل‌ها و مسائل، از روش‌های جدید مانند روش‌های پیشرفته هوش محاسباتی استفاده شود که توانایی بالایی در بسیاری از زمینه‌های محاسباتی دارند. با توجه به تنوع کارهای تحقیقاتی انجام‌شده در این زمینه و نبود مقاله مروری جامع، انجام این کار پژوهشی ضروری است. هدف از نگارش این مقاله، مروری جامع بر کاربردهای انواع روش‌های پیشرفته هوش محاسباتی در حیطه اکتشاف منابع معدنی و ایجاد منبع مطالعاتی جامع برای پژوهشگران علاقه‌مند به این زمینه است. نتایج این تحقیقات همگی نشان می‌دهند، روش‌های پیشرفته هوش محاسباتی در مقایسه با سایر روش‌ها در بررسی اکتشاف منابع معدنی، کارآمدتر، سریعتر، دقیقتر و مقرون به صرفه‌تر هستند.

**واژه‌های کلیدی:** روش‌های پیشرفته هوش محاسباتی، اکتشاف، منابع معدنی، مدل‌سازی

### مقدمه

(Bazdar et al., 2015a). اکتشاف منابع معدنی دارای مراحل

است که در پایان هر مرحله تصمیم گرفته می‌شود ادامه اکتشاف مقرون به صرفه خواهد بود یا خیر. این تصمیم‌گیری به عوامل بسیاری از جمله عوامل فنی، اقتصادی، اجتماعی و سایر عوامل بستگی دارد. کلیه روش‌های جدید استفاده شده در اکتشاف منابع معدنی، به تسهیل این تصمیم‌گیری پرداخته است و هدف کلی این روش‌ها نیز چیزی جز این نیست. از روش‌های سنتی به کار گرفته شده، می‌توان به روش‌های زمین‌آماری، وزن شواهد<sup>۱</sup>، بایسین<sup>۱</sup> و بررسی‌های زمین‌شناسی و سنگ‌شناسی، اشاره کرد. در روش‌های زمین‌آماری هورنیک و همکاران (Hornik et

برکسی پوشیده نیست که منابع معدنی یکی از مهمترین مواد اولیه برای صنایع و همچنین ابزاری سودمند برای دولت‌ها به‌عنوان منبع درآمد است. سه حلقه اکتشاف، استخراج و فرآوری که رابطه تنگاتنگی با هم دارند و هر مرحله ارزش افزوده بیشتری نسبت به مرحله پیش از خود دارد، از مهمترین عوامل ایجاد معدن است. یکی از اصلی‌ترین مراحل برای پیدایش معدن، اکتشاف است و در صورتی که این مرحله به‌خوبی انجام نشود، ضررهای جبران‌ناپذیری را در مراحل استخراج و به‌ویژه فرآوری بر بهره‌بردار وارد خواهد کرد

1. Weight of Evidence

\*مسئول مکاتبات: h.fattahi@arakut.ac.ir

اصل هدایت‌کننده روش‌های هوشمند، بهره‌برداری از ویژگی دقیق نبودن برای مهار کردن مسأله و پایین آوردن هزینه راه حل است. روش‌های پیشرفته هوش محاسباتی را می‌توان حاصل تلاش‌های جدید علمی دانست که مدل‌سازی، تحلیل و در نهایت کنترل سامانه‌های پیچیده را با سهولت و موفقیت بیشتری امکان‌پذیر می‌سازد. شبکه‌های عصبی مصنوعی<sup>۱</sup>، الگوریتم ژنتیک<sup>۲</sup>، سامانه‌های فازی<sup>۳</sup>، هوش پرندگان<sup>۴</sup>، الگوریتم‌های تکاملی<sup>۵</sup> و... از روش‌های پیشرفته هوش محاسباتی به حساب می‌آیند (Bazdar et al., 2015a). مدل‌سازی با این روش‌ها در سال‌های اخیر در علوم مختلف رونق بسیاری داشته است که به‌عنوان مثال می‌توان به کاربرد شبکه عصبی مصنوعی در پیش‌بینی آلودگی آب زیرزمینی (Ghadimi, 2015)، پیش‌بینی فضای تخریب‌شده اطراف یک فضای زیرزمینی (Fattahi et al., 2013d) و کاربرد ماشین بردار پشتیبان در پیش‌بینی آلودگی آب و خاک (Ghadimi, 2014a; Ghadimi, 2014b)، کاربرد روش عصبی-فازی در پیش‌بینی سرعت حفر تونل توسط دستگاه TBM<sup>۶</sup> (Fattahi, 2016a) اشاره کرد. بسیاری از سامانه‌های زنده و غیر زنده طبیعی، نسبت به سامانه‌های ساخت دست بشر از لحاظ کارایی برتری دارند. راهنمای خود بودن و تولید مثل، قوانینی در سامانه‌های زیستی و طبیعی هستند که به سختی می‌توان حتی بعضی از آنها را در سامانه‌های ساخت دست بشر یافت. همین امر پژوهشگران را بر آن داشته که سامانه‌های طبیعی و هوش حاکم بر رفتار آنها را به‌عنوان الگوی طراحی سامانه‌های مهندسی مورد توجه قرار دهند. چنین تلاش‌هایی به ایجاد مجموعه روش‌های بهینه‌سازی برگرفته از طبیعت یا مبتنی بر هوش مصنوعی منجر شده است که به دو زیر مجموعه اصلی تقسیم می‌شوند: روش‌های مبتنی بر طبیعت جاندار و روش‌های برگرفته از طبیعت بی‌جان. بیشتر روش‌های مبتنی بر طبیعت جاندار از فرآیند تکاملی جانداران در طبیعت الهام می‌گیرند. در این فرآیند، ویژگی‌های جانداران

(al., 1989)، ژورنل و هویرگ (Journal and Huijbregts, 1978)، میسترا و همکاران (Misra et al., 2007) و رندو (Rendu, 1979)؛ در روش وزن شواهد آگتربرگ و بونهام-کارت (Agterberg and Bonham-Carter, 1999) و پوروال و همکاران (Porwal et al., 2010a)؛ در روش بایسین پوروال و همکاران (Porwal et al., 2006a) و ضیائی و همکاران (Ziaii et al., 2009) و در بررسی‌های زمین‌شناسی، کریم‌پور و همکاران (Karimpour et al., 2011)؛ (Karimpour et al., 2010)، پژوهشهایی را انجام داده‌اند. روش‌های مرسوم برای تحقق اهداف یادشده، دارای کمبودهایی است. لذا در سال‌های اخیر روش‌های پیشرفته هوش محاسباتی همگام با علوم دیگر برای مدل‌سازی در بسیاری از علوم مربوط به زمین از جمله علوم مربوط به اکتشاف منابع معدنی استفاده شده است. هرچند، نتایج کاربرد این روش‌ها کارآیی آنها را به‌خوبی نشان می‌دهند؛ ولی برای نتیجه قطعی، بررسی توانایی‌های معدنی از لحاظ ساختار زمین‌شناسی، مینرالوژی، سنگ‌شناسی و سایر عوامل ضروری است. هدف از تدوین این مقاله، فراهم کردن مجموعه‌ای جامع از پژوهش‌های انجام شده طی دهه‌های اخیر، برای علاقه‌مندان به مطالعه علوم اکتشاف منابع معدنی و کاربردهای مختلف روش‌های پیشرفته هوش محاسباتی در این باره است.

### روش‌های پیشرفته هوش محاسباتی

روش‌های پیشرفته هوش محاسباتی به مجموعه‌ای از شیوه‌های جدید محاسباتی در علوم رایانه، هوش مصنوعی، یادگیری ماشینی و بسیاری از زمینه‌های کاربردی دیگر اطلاق می‌شود. در تمامی این زمینه‌ها به بررسی، مدل‌سازی و آنالیز پدیده‌های بسیار پیچیده‌ای نیاز است که شیوه‌های علمی دقیق در گذشته در حل آسان، تحلیلی و کامل آنها موفق نبوده‌اند. روش‌های هوشمند با قبول دقیق نبودن و با محور قرار دادن ذهن انسان به پیش می‌رود.

1. Bayesian  
2. Artificial neural networks (ANN)  
3. Genetic algorithm (GA)  
4. Fuzzy systems (FS)

5. Swarm intelligence (SI)  
6. Evolutionary algorithms (EA)  
7. Tunnel Boring Machine (TBM)

مغز انسان داشته باشد (Jorjani et al., 2008). قابلیت پردازش شبکه از نوع ارتباط بین واحدها و وزن‌های اتصال سرچشمه می‌گیرد که یا از فرآیند یادگیری به‌دست می‌آید یا از قبل تعیین شده است (Monjezi and Dehghani, 2008). نرون کوچکترین واحد پردازش اطلاعات است (Specht, 1991). از اجتماع چند نرون که به‌طور موازی عمل کنند یک لایه به‌وجود می‌آید. هر لایه وظیفه خاصی دارد و با ترکیب لایه‌ها، شبکه‌های عصبی مصنوعی به‌وجود می‌آید. با توجه به هدفی که شبکه عصبی مصنوعی برای آن طرح می‌شود، لایه‌های متعددی در نظر گرفته می‌شود (Acharya et al., 2006). شبکه عصبی مصنوعی یک سامانه پردازش اطلاعات است که با شبیه‌سازی و ساده‌سازی شبکه‌های عصبی بدن انسان به‌وجود آمده‌اند. شکل ۱ روند کلی شبکه عصبی مصنوعی را به‌صورت شماتیک نشان می‌دهد. خروجی نرون‌های دیگر در وزن‌های متفاوت ضرب می‌شوند و به‌عنوان ورودی به نرون جدید می‌رسند. این ورودی‌ها پس از جمع شدن و گذشتن از تابعی به نام تابع انتقال از نرون خارج می‌شوند. بنابراین، هر نرون مقدار زیادی ورودی و تنها یک خروجی دارد. اتصال تعداد زیادی از این نرون‌ها به یکدیگر می‌تواند یک شبکه عصبی مصنوعی را تشکیل دهد (Hagan et al., 2002).

یک شبکه عصبی مصنوعی شامل اجزای سازنده لایه‌ها و وزن‌هاست. رفتار شبکه عصبی مصنوعی نیز وابسته به ارتباط بین اعضاست (Demuth and Beale, 2002).

در حالت کلی در شبکه عصبی مصنوعی سه نوع لایه نرونی وجود دارد (Demuth and Beale, 2002):  
لایه ورودی<sup>۴</sup>: دریافت اطلاعات خامی که به شبکه تغذیه شده است.

لایه پنهان<sup>۵</sup>: عملکرد لایه پنهان به‌وسیله ورودی‌ها و وزن ارتباط بین آنها و لایه‌های پنهان تعیین می‌شود.

لایه خروجی<sup>۶</sup>: عملکرد واحد خروجی بسته به فعالیت واحد

بهبود می‌یابد تا بهتر بتواند با محیط سازگار شوند و در رقابت با سایر جانداران برای دست‌یابی به منابع محدود طبیعی پیروز شوند. بهینه‌یابی مورچه<sup>۱</sup>، الگوریتم‌های تکاملی<sup>۲</sup> و شبیه‌سازی تبرید<sup>۳</sup>، مثال‌هایی از چنین الگوریتم‌هایی هستند. بهینه‌یابی مورچه و الگوریتم‌های تکاملی از طبیعت و شبیه‌سازی تبرید، از فرآیند سردسازی فلزات در تولید فلزات مستحکم الهام گرفته شده‌اند. ترکیب مختلف الگوریتم‌های بهینه‌ساز با روش‌های هوشمند، برای آموزش مدل در روش‌های هوشمند و سایر مسائل بهینه‌سازی مربوط به آنها به کار گرفته شده است (Fattahi, 2015a; Fattahi, 2015b). روش‌های بهینه‌سازی مبتنی بر روش‌های رایانش نرم، وابسته به گروه روش‌های مستقیم است و شباهت زیادی به روش‌های جست‌وجوی تصادفی دارند. روش‌های جست‌وجوی تصادفی تنها از راهبرد جست‌وجوی کلی برخوردارند؛ در حالی که روش‌های مبتنی بر هوش مصنوعی به‌طور هم‌زمان هر دو راهبرد جست‌وجوی کلی و محلی را اجرا می‌کنند. در حقیقت، روش‌های پیشرفته هوش محاسباتی، سامانه‌های دینامیکی هوشمند مبتنی بر داده‌های تجربی هستند که با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به همین دلیل، به این روش‌ها هوشمند نیز می‌گویند؛ چرا که بر اساس محاسبات روی داده‌های عددی، قوانین کلی را فرا می‌گیرند. در این روش‌ها داده‌های مشاهده‌ای به مدل آموزش داده می‌شوند و پس از آموزش مدل با دقت مناسب کار پیش‌بینی و شبیه‌سازی را انجام می‌دهد. در ادامه به مروری جامع بر کاربرد روش‌های پیشرفته هوش محاسباتی در بررسی اکتشاف منابع معدنی پرداخته می‌شود.

## شبکه عصبی مصنوعی و کاربرد آن در اکتشاف منابع معدنی

### شبکه عصبی مصنوعی


شبکه عصبی مصنوعی مجموعه‌ای از ارتباطات بین واحدها یا گره‌هاست که سعی می‌کند عملکردی مانند مجموعه نرون‌های

1. Ant Colony Optimization (ACO)  
2. Evolutionary Algorithms (EAs)  
3. Simulated Annealing (SA)

4. Input layer  
5. Hidden layer  
6. Output layer

حلقه‌ای وجود ندارد. خروجی هر لایه بر همان لایه تأثیری ندارد.  
پس‌خور<sup>۱</sup>: داده‌ها از گره‌های لایه بالا به گره‌های لایه پایین باز خورانه می‌شوند.  
جانبی: خروجی گره‌های هر لایه به عنوان ورودی گره‌های همان لایه استفاده می‌شوند.

پنهان و وزن ارتباط بین واحد پنهان و خروجی است.  
هر دو لایه از یک شبکه به وسیله وزن‌ها و در واقع اتصالات با هم ارتباط می‌یابند. در شبکه‌های عصبی مصنوعی چند نوع اتصال و یا پیوند وزنی وجود دارد:  
پس‌خور<sup>۱</sup>: بیشترین پیوندها از این نوع است. در آن سیگنال‌ها تنها در یک جهت حرکت می‌کنند. از ورودی به خروجی هیچ



شکل ۱. روند کلی شبکه عصبی مصنوعی به صورت شماتیک (Basheer and Hajmeer, 2000; Bazdar et al., 2015a)

Fig. 1. The general trend of artificial neural network schematically (Basheer and Hajmeer, 2000; Bazdar et al., 2015a)

هر شبکه عصبی مصنوعی سه مرحله آموزش، اعتبارسنجی و اجرا را پشت سر می‌گذارد. در واقع شبکه‌های عصبی مصنوعی را می‌توان در حل مسائلی که روابط دقیق ریاضی بین ورودی‌ها و خروجی‌های آن برقرار نیست، به کار برد. این شبکه‌ها از عناصر ساده‌ای تشکیل شده‌اند که به‌طور موازی عمل می‌کنند و با الهام از شبکه‌های بیولوژیک هر یک از این عناصر را نرون می‌نامند. آموزش دیدن شبکه‌های عصبی مصنوعی در واقع چیزی جز تنظیم وزن‌های ارتباطی این نرون‌ها به ازای دریافت مثال‌های مختلف نیست تا خروجی شبکه به سمت خروجی مطلوب همگرا شود (Doulati Ardejani et al., 2012). شبکه‌های عصبی مصنوعی می‌توانند بر اساس طراحی خود

سیگنال‌های ورودی را پردازش و به سیگنال‌های خروجی موردنظر تبدیل کنند. به‌طور معمول، پس از آن که یک شبکه عصبی مصنوعی طراحی و پیاده‌سازی شد، باید مؤلفه‌های  $w$  و  $b$  به ازای مجموعه‌هایی از سیگنال ورودی، به گونه‌ای تنظیم شوند که سیگنال‌های خروجی شبکه خروجی مطلوب را تشکیل دهند. چنین فرآیندی را آموزش دیدن شبکه عصبی مصنوعی می‌نامند (در نخستین مرحله آموزش، مقادیر  $w$  و  $b$  به‌طور تصادفی انتخاب می‌شوند؛ زیرا تا این مؤلفه‌ها مقدار نداشته باشند، شبکه عصبی مصنوعی قابل استفاده نخواهد بود)، در حین آموزش دیدن شبکه عصبی مصنوعی (یعنی به تدریج هم‌زمان با افزایش دفعاتی که مقادیر مؤلفه‌ها برای رسیدن به خروجی مطلوبتر،

1. Feed Forward  
2. Back-propagation

تنظیم می‌شوند) مقدار مؤلفه‌ها به مقدار حقیقی و نهایی خود نزدیکتر می‌شوند. به‌طور کلی دو روش برای آموزش دادن شبکه‌های عصبی مصنوعی وجود دارد. روش با نظارت و روش بدون نظارت (Eskandari et al., 2004).

### کاربرد شبکه عصبی مصنوعی در اکتشاف منابع معدنی

سینگر و کودا (Singer and Kouda, 1996)، در پژوهشی با استفاده از شبکه عصبی مصنوعی پیشخور به اکتشاف ذخایر کروکو در منطقه هو کروکو ژاپن پرداختند. ساختار مدل آنها از یک لایه پنهان و پنج نورون تشکیل شده بود. هدف از این مدل‌سازی تعیین فاصله تا ذخیره کروکو بود. مقدار میانگین پیریت، سریسیت، ژیپس و آنهدریت از ۶۹ گمانه به‌عنوان مجموعه داده آموزش در نظر گرفته شد. بعد از آموزش مدل، مدل آموزش یافته برای کل ۱۵۲ گمانه در نظر گرفته شد و در نهایت نقشه کنتموری با توجه به فاصله از ذخیره مورد نظر تعیین شد.

در پژوهشی دیگر، هریس و پن (Harris and Pan, 1999)، برای تعیین توانایی معدنی، چند روش آنالیز را با یکدیگر مقایسه کردند. روش‌های به کار رفته عبارت بودند از: شبکه‌های عصبی مصنوعی احتمالاتی<sup>۱</sup>، رگرسیون لجستیک<sup>۲</sup> و آنالیز تفکیک<sup>۳</sup>. مجموعه داده از هشت متغیر زمین‌شناسی، ژئوشیمیایی و ژئوفیزیکی، مختصات نقطه برداشت و بود یا نبود کانه‌زایی طلا (از ۱۶۳۸۳ گمانه اکتشافی) تشکیل شده بود. مجموعه داده آموزش به مقدار ۲۰ درصد کل گمانه‌ها یعنی تعداد ۳۲۷۷ و مجموعه داده اعتبارسنجی ۸۰ درصد داده‌ها یعنی تعداد ۱۳۱۰۶ داده تعیین شد. دقت مدل آموزش دیده برای تعیین نقاط با کانه‌زایی و نقاط بدون کانه‌زایی، به ترتیب ۸۶/۷ و ۹۳/۸ تعیین شد. آنالیز تفکیک غیر مؤلفه‌ای و رگرسیون لجستیک شبکه عصبی مصنوعی نیز بر روی داده‌ها آزمایش شد که در کل شبکه‌های عصبی مصنوعی احتمالاتی کارایی بهتری را نسبت به دو روش دیگر نشان دادند.

در پژوهشی دیگر، سینگر و کودا (Singer and Kouda, 1999)، روش وزن شواهد و شبکه عصبی مصنوعی احتمالاتی را با داده‌های حاصل از حفاری دریاچه آندنسون، مانیتوبا، کانادا انجام دادند. نتایج نشان داد که خطای طبقه‌بندی مناطق دارای کانه‌زایی و مناطق بدون کانه‌زایی هنگامی که روش شبکه عصبی مصنوعی احتمالاتی به کار گرفته می‌شود نسبت به روش وزن شواهد به مراتب پایین‌تر است.

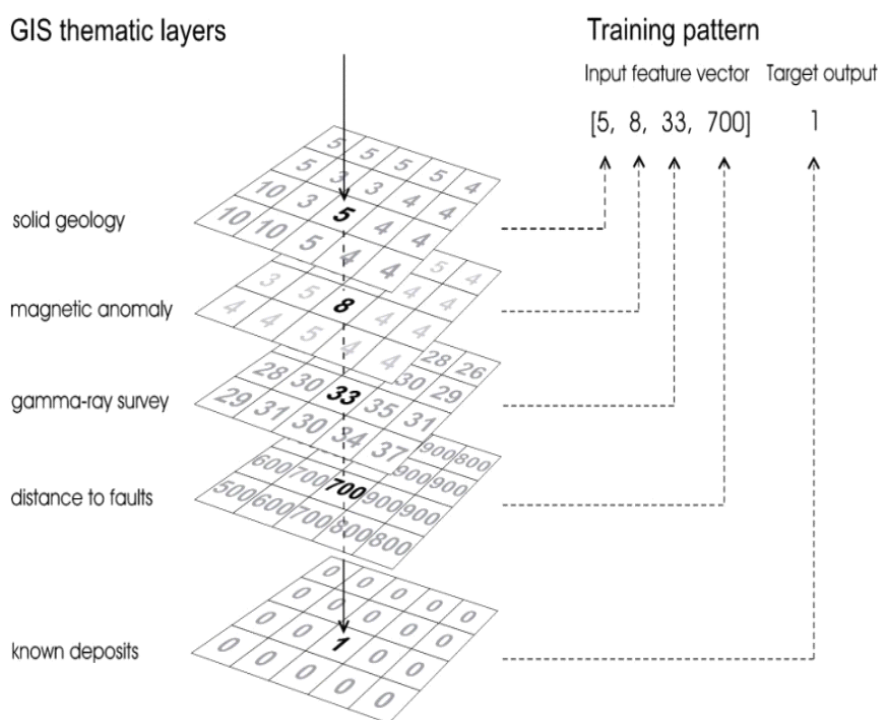
براون و همکاران (Brown et al., 2000) در پژوهشی، شبکه عصبی مصنوعی چندلایه پیشخور را که با یک الگوریتم گرادبان نزولی پس انتشار آموزش دیده بود، به‌منظور برآورد مناطق مساعد برای طلا با استفاده از مجموعه داده رستری GIS<sup>۴</sup> برای نقشه ۱:۱۰۰۰۰۰ منطقه تترفیلد، ولز جنوبی جدید، استفاده کردند. مجموعه داده شامل زمین‌شناسی، گسل‌های محلی، مغناطیس‌سنجی هوایی، برداشت گاماسنجی و ۶۳ موقعیت کانه‌زایی در منطقه بود. اطلاعات موجود با استفاده از GIS ترکیب و آموزش شبکه عصبی مصنوعی با این اطلاعات انجام شد (شکل ۲). گرچه آموزش مدل به‌صورت مدل باینری انجام شد؛ ولی خروجی آن با یک بازه ۰/۱ تا ۰/۹ نشان داده شد. نقشه توانایی معدنی منطقه با استفاده از این داده‌ها تهیه شد. برای برآورد کارایی مدل شبکه عصبی مصنوعی، نقشه توانایی با استفاده از روش وزن شواهد و نیز منطق فازی تهیه شد. نتایج، کارایی مدل شبکه عصبی مصنوعی را نسبت به روش‌های دیگر نشان داد.

در پژوهشی اسکابار (Skabar, 2003)، با استفاده از شبکه عصبی مصنوعی پیشخور، نقشه توانایی معدنی در منطقه جنوب غرب ویکتوریا، استرالیا برای اکتشاف طلا را تهیه کرد. متغیرهای ورودی مورد استفاده شامل داده‌های زمین‌شناسی، ژئوفیزیک و ژئوشیمی منطقه بود. نقشه توانایی به‌دست آمده از این بررسی در مقایسه با بررسی‌های قبلی و با استفاده از روش‌های سنتی، پیشرفت قابل ملاحظه‌ای داشت. در پژوهشی دیگر، فونگ و همکاران (Fung et al., 2005)،

1. probabilistic neural networks (PNN)  
2. Logistic Regression (LR)  
3. discriminant analysis (DA)  
4. Geographic Information System (GIS)

کل منطقه به ۱/۲۵۴/۰۰۰ سلول تقسیم شد. تنها ۱۲۰ سلول مرتبط با کانه‌زایی بود و ۱۴۸ سلول دیگر نیز به‌طور تصادفی برای آموزش و آزمون مدل انتخاب شدند. در مجموع ۲۶۸ سلول برای آموزش و آزمون در نظر گرفته شد که تعداد ۱۸۷ سلول برای آموزش و ۸۱ سلول نیز برای آزمون مدل استفاده شد. خروجی مدل یک مقدار از ۰ تا ۱ بود که نشان‌دهنده میزان ارتباط با کانه‌زایی بود. هنگامی که مقدار بازه خروجی برای تعیین کانه‌زایی ۰/۱ تا ۰/۹ در نظر گرفته شد، شبکه عصبی مصنوعی رگرسیون عمومی دارای بیشترین و شبکه‌های عصبی مصنوعی چند جمله‌ای دارای کمترین کارایی بود. در نهایت محققان پیشنهاد کردند، هنگامی که نتایج متضاد از شبکه‌های مختلف به دست می‌آید، از الگوریتم‌های بهینه‌ساز همچون الگوریتم ژنتیک و منطق فازی استفاده شود.


شبکه‌های عصبی مصنوعی مختلف را برای تعیین توانایی معدنی با یکدیگر مقایسه کردند. چهار شبکه عصبی مصنوعی مختلف، شبکه عصبی مصنوعی چند جمله‌ای<sup>۱</sup>، شبکه عصبی مصنوعی رگرسیون عمومی<sup>۲</sup>، شبکه‌های عصبی مصنوعی احتمالاتی و شبکه عصبی مصنوعی پس‌انتشار<sup>۳</sup>، با یکدیگر مقایسه شدند. مجموعه داده به کار رفته برای آموزش مدل، داده‌های GIS بود که مساحت حدود ۱۰۰ کیلومتر مربع را در بر می‌گرفت و ۱۰ لایه داده رستری به‌عنوان بردار ورودی در نظر گرفته شد. شکل ۳ الگوی نمونه به کار گرفته شده لایه‌های GIS به‌عنوان مجموعه داده ورودی و خروجی را نشان می‌دهد. داده‌ها شامل اطلاعاتی مانند زمین‌شناسی یا نزدیکترین فاصله به گسل بود. منطقه مورد نظر به یک شبکه مربعی که هر سلول دارای مساحت ۱۰۰ متر بود، تقسیم شد. هر سلول با موقعیت مکانی خود و مقدار مستقل که یک ماتریس دو بعدی بود، مشخص می‌شد.



شکل ۲. ارتباط شماتیک بین لایه‌های GIS و بردارهای ورودی در شبکه عصبی مصنوعی (Brown et al., 2000)

**Fig. 2 .** Relationship between GIS thematic layers and feature vectors used as input to the neural network (Brown et al., 2000).

1. Polynomial Neural Network(PNN)
2. General Regression Neural Network(GRNN)
3. Back Propagation Neural Network(BPNN)



شکل ۳. الگوی نمونه ورودی/خروجی استفاده شده برای مجموعه داده‌های آموزش و آزمون (Fung et al., 2005)

Fig. 3. A typical input/output pattern used to train and test data sets (Fung et al., 2005)

نمود پیدا می‌کرد. وی برای آموزش شبکه عصبی مصنوعی از روش بایسین استفاده کرد که تا حدود زیادی معایب یادشده را برطرف کرد.

لیت و دسوزا فیلهو (Leite and de Souza Filho, 2009b)، از شبکه عصبی مصنوعی احتمالاتی، برای تهیه نقشه توانایی عناصر گروه پلاتین در منطقه کاراجاس برزیل استفاده کردند. داده‌های آنها به‌عنوان ورودی شامل اطلاعات طیف‌سنجی گاما، مغناطیس‌سنجی و زمین‌شناسی بود. با استفاده از این داده‌ها، لایه‌های اطلاعات بر روی نقشه پیاده‌شده و بردارهای مشخصه<sup>۳</sup> برای آموزش شبکه از آن استخراج شد. مکان‌ها با مختصات معلوم دارای توانایی کانه‌زایی برای آموزش مدل شبکه عصبی مصنوعی مشخص شدند. دو نقشه توانایی، یکی برای توانایی طلا و عناصر گروه پلاتین و دیگری برای مس و عناصر گروه پلاتین رسم شد. نقشه توانایی طلا و عناصر گروه پلاتین با سه طبقه‌بندی مناطق با توانایی بالا، متوسط و پایین و نقشه توانایی مس و گروه عناصر پلاتین با دو طبقه‌بندی مناطق با توانایی بالا و پایین تهیه شد. در نقشه توانایی طلا و عناصر گروه پلاتین، ۵۷٪ درصد منطقه مورد بررسی دارای توانایی بالا و در نقشه توانایی مس و گروه عناصر پلاتین، ۱۷٪ درصد مناطق دارای توانایی بالا بود.

در پژوهشی اسکابار (Skabar, 2005)، با استفاده از پرسپترون احتمالی چندلایه، به تهیه نقشه توانایی معدنی کاستل مین ویکتوریا در استرالیا پرداخت. وی با استفاده از روشی جدید مشکلات اساسی استفاده از پرسپترون‌های چندلایه را کاهش داد. روش جدید از تمام پیکسل‌های منطقه مورد بررسی برای آموزش مدل استفاده می‌کرد و حساسیت کمتری نسبت به انتخاب نمونه‌ها برای آموزش مدل نسبت به مدل‌های قبلی داشت. دو مورد یادشده از برتری‌های روش ارائه شده نسبت به مدل‌های شبکه عصبی مصنوعی قبلی بود. برای نشان دادن کارایی روش ارائه شده، نقشه توانایی منطقه تهیه شد و با روشی دیگر به نام روش تخمینی چگالی پارزن<sup>۱</sup> مقایسه شد.

در پژوهشی دیگر، اسکابار (Skabar, 2007)، از پرسپترون احتمالی چندلایه برای تهیه نقشه توانایی معدنی کاستل مین ویکتوریا در استرالیا استفاده کرد. وی برای آموزش شبکه از روش جدیدی استفاده نمود. روش مرسوم برای آموزش، روش شیب نزولی<sup>۲</sup> بود که دارای معایبی از جمله تعیین وزن‌های اولیه و نیز تعیین نسبت تعداد داده برای آموزش به تعداد داده برای اعتبارسنجی بود. این مشکلات به‌خصوص در تهیه نقشه توانایی معدنی که تعداد نقاط کانه‌زایی به کل نقاط اندک بود، بیشتر

1. Parzen window density estimation based approach  
2. Gradient descent  
3. Feature Vectors

مصنوعی در مقایسه با روش وزن شواهد، نیاز به داده کمتری برای آموزش دارد و این خود برتری آشکاری را نشان می‌دهد. همچنین به این دلیل که مدل شبکه عصبی مصنوعی در مقایسه با روش منطق فازی نیاز به نظر کارشناسی ندارد، کارآیی بیشتری از آن دارد. برای نشان دادن کارآیی شبکه عصبی مصنوعی، سه روش آموزش و آزمون به کار گرفته شد که شبکه عصبی مصنوعی پیوند شعاعی پایه<sup>۱</sup>، نتایج بهتر و همچنین هدف‌های اکتشافی جدیدتری را نشان می‌داد.

در پژوهشی عابدی و نوروزی (Abedi and Norouzi, 2012)، سه روش داده محور (بایسین، K نزدیکترین همسایه<sup>۲</sup> و طبقه‌بندی کننده شبکه عصبی مصنوعی) را برای تهیه نقشه توانایی معدنی ذخیره مس پورفیری استفاده کردند. لایه‌های مختلف اطلاعات زمین‌شناسی، ژئوفیزیکی و ژئوشیمیایی مس پورفیری نوجون، واقع در استان کرمان ایران، برای تهیه نقشه توانایی معدنی به منظور اکتشاف منابع معدنی، ترکیب شدند. دقت طبقه‌بندی دو روش بایسین، K نزدیکترین همسایه، به مقدار ۵۲/۳۸ درصد بود که ۲۱ گمانه را به ۵ طبقه تقسیم کردند. برای مدل شبکه عصبی مصنوعی، سه مدل عصبی مصنوعی پرسپترون چندلایه<sup>۳</sup>، تابع شعاعی و شبکه عصبی مصنوعی احتمالاتی به کار رفت. بیشترین دقت طبقه‌بندی مربوط به تابع شعاعی به میزان، ۸۰/۹۵ درصد بود.

پوروال و همکاران (Porwal et al., 2003a) نیز در پژوهشی کاربرد شبکه عصبی مصنوعی تابع شعاعی خالص شبکه را با استفاده از داده‌های GIS برای تهیه نقشه توانایی معدنی ذخیره فلزات پایه در هند شرقی نشان دادند. مدل‌های مختلفی آموزش داده شد و مدلی که بالاترین دقت طبقه‌بندی را داشت، انتخاب شد. خروجی مدل یک عدد بین ۰ و ۱ بود که نشان می‌داد که منطقه مورد نظر در بخش کانه‌زایی و یا این که در بخش عقیم وجود دارد. نقشه توانایی معدنی با سه بخش کانه‌زایی با توانایی

در تحقیقی دیگر، لیت و دسوزا فیلهو (Leite and de Souza Filho, 2009a)، نقشه توانایی مس-طلا را در منطقه کاراجاس برزیل، با استفاده از شبکه عصبی مصنوعی تهیه کردند. تابع شعاعی<sup>۱</sup> را به مدل عصبی مصنوعی مرتبط کردند. با استفاده از مجموعه داده و اعتبارسنجی، مدل آموزش داده شده و دقت کلی مدل، ۹۱/۷ درصد به دست آمد. نقشه توانایی معدنی به صورت باینری رسم شد که به دو بخش با توانایی بالا و پایین تقسیم می‌شد. مشخص شد که ۴/۱۸ درصد منطقه مورد بررسی در بخش با توانایی بالاست، به خصوص بخش‌هایی که در ارتباط با نوع کانه‌زایی اکسید آهن بوده و مرتبط با سنگ‌های ولکانیکی و آلتراسیون هیدروترمال است.

وانگ و همکاران (Wang et al., 2011)، در پژوهشی با استفاده از داده‌های به دست آمده از نقشه‌های زمین‌شناسی، مقاطع زمین‌شناسی، گمانه‌های اکتشافی، ثقل‌سنجی و مغناطیس‌سنجی و با کاربرد روش‌های فرکتالی، فرکتالی چندگانه و شبکه عصبی مصنوعی احتمالاتی، مدل سه بعدی زمین‌شناسی ذخیره پورفیری مولیبدن، سرب، روی و نقره در منطقه لانچان چین را به دست آوردند. در این مطالعه کاربرد مدل عصبی مصنوعی برای تجمع لایه‌های آنومالی‌های مختلف از جمله آنومالی‌های زمین‌شناسی و ژئوشیمیایی بود.

ماگالهاس و سوزا فیلهو (Magalhães and Souza Filho, 2012)، با استفاده از روش‌های وزن شواهد، شبکه عصبی مصنوعی و مدل‌سازی فضایی فازی، و داده‌های ژئوفیزیک، زمین‌شناسی و ژئوشیمیایی منطقه مورد بررسی، نقشه توانایی معدنی کانی‌سازی طلا در معدن طلای آماپاری برزیل را تهیه کردند. داده‌های مورد استفاده برای این منظور شامل ژئوفیزیک هوایی، نقشه‌های زمین‌شناسی و نیز داده‌های ژئوشیمیایی آبراهه‌ای بود. کارآیی مدل شبکه عصبی مصنوعی از چند جهت نسبت به دو روش دیگر برتری داشت. مدل شبکه عصبی

1. radial basis functional

2. radial basis functional link net(RBFLN)

3. k-nearest neighbor(k-nn)

4. multi-layer perceptron

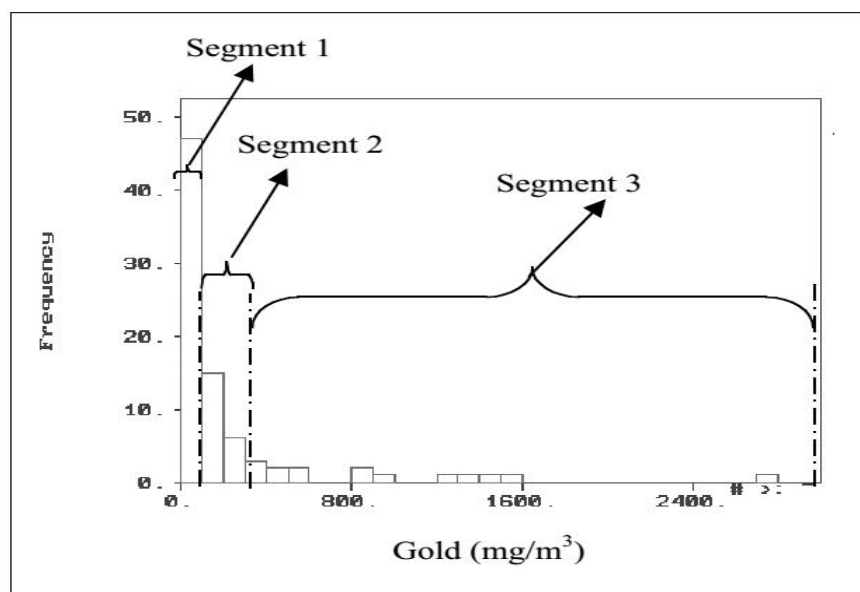


کریجینگ نیز انجام شد. نتایج حاصل برتری مدل شبکه عصبی مصنوعی را نشان داد.

سامانتا و همکاران (Samanta et al., 2006)، به منظور بررسی کارایی آموزش‌های مختلف مدل شبکه عصبی مصنوعی، چند مدل مختلف را در تخمین عیار طلا، بوکسیت و آهن به کار گرفتند. هدف اصلی مطالعه آنها بررسی دو نوع آموزش مدل یعنی آموزش محلی<sup>۱</sup> و آموزش سراسری<sup>۲</sup> بود. برای آموزش محلی چهار مدل و برای آموزش سراسری دو مدل در نظر گرفته شد. نتایج به دست آمده در بررسی موردی در این پژوهش تفاوت چندانی بین دو نوع آموزش مدل نشان نداد و دلیل این موضوع، سطح خطای ملایم<sup>۴</sup> احتمال داده شد. با این که تفاوت چندانی بین دو نوع آموزش سراسری و آموزش محلی در داده‌ها دیده نشد، محققان پیشنهاد کردند برای جلوگیری از مشکل مینیمم محلی<sup>۵</sup> در آموزش محلی، استفاده از آموزش سراسری برتری دارد.

بالا، توانایی متوسط و توانایی پایین تهیه شد. ۶ درصد منطقه مورد بررسی در بخش با توانایی بالا قرار داشت و نیز بخش با توانایی بالا ۹۴ درصد ذخایر شناخته شده را در بر می گرفت.

در پژوهشی دیگر، سامانتا و همکاران (Samanta et al., 2002)، با استفاده از مدل شبکه عصبی مصنوعی به تخمین عیار طلا در ذخیره پلاسری پرداختند. داده‌های آنها شامل اطلاعات استخراج شده از گمانه‌های اکتشافی بود. مشکل اصلی در رابطه با این داده‌ها، اندک بودن داده‌ها بود که هنگام تقسیم داده‌ها به مجموعه داده‌های آموزش و آزمون، این مشکل بیشتر نمود پیدا می کرد و باعث می شد که انتخاب تصادفی داده‌ها، مشکل ارباب بودن داده‌ها را ایجاد کند. برای غلبه بر این مسأله از الگوریتم ژنتیک برای بهینه‌سازی مجموعه داده‌ها استفاده و هر مجموعه داده به سه قسمت تقسیم شد. به عنوان نمونه، شکل ۴ تقسیم مجموعه داده آزمون را نشان می دهد. برای مقایسه و ارزیابی کارایی این مدل، تخمین عیار به وسیله روش‌های مختلف



شکل ۴. تقسیم داده در مجموعه داده آموزش (Samanta et al., 2002)

Fig. 4. Data segmentation in training data set (Samanta et al., 2002)

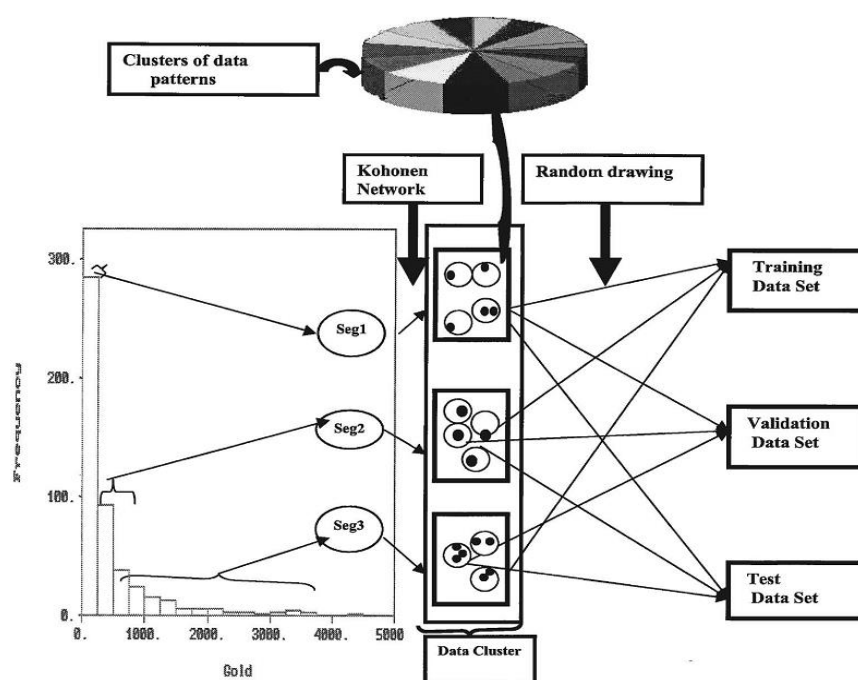
یک منطقه معدنی استفاده کردند. خطای متوسط کمتر از یک درصد بود. هدف آنها مقایسه روش جدید با روش‌های

در پژوهشی دیگر، یاما و لینبری (Yama and Lineberry, 1999)، از مدل شبکه عصبی مصنوعی در پیش‌بینی سولفور در

- |                              |                         |
|------------------------------|-------------------------|
| 1. Biased subset             | 4. Smooth error surface |
| 2. Local learning algorithm  | 5. Local minima         |
| 3. Global learning algorithm |                         |

مجموعه داده‌های آموزش و آزمون را به وجود می‌آورد. برای غلبه بر این مشکل آنها از روش ترکیبی تقسیم داده<sup>۱</sup> و شبکه کوهونن<sup>۲</sup> برای تقسیم داده‌ها استفاده کردند (شکل ۵). دو مدل عصبی مصنوعی و پنج روش کریجینگ برای پیش‌بینی عیار طلا در منطقه مورد بررسی به کار گرفته شد. در این بررسی کارآیی تمام روش‌ها تقریباً یکسان بود؛ هر چند که در دقت پیش‌بینی متغیر دیگر (سطح آب زیرزمینی) اندکی تفاوت به دست آمد.

زمین‌آماری از جمله کریجینگ بود. در نهایت اعلام کردند که روش جدید نسبت به روش کریجینگ برتری دارد و یا حداقل نتایج روش کریجینگ را به دست می‌دهد. در تحقیقی دیگر، سامانتا و همکاران (Samanta et al., 2004)، شبکه عصبی مصنوعی و همچنین روش کریجینگ را برای پیش‌بینی عیار طلای پلاستی به کار گرفتند. محدودیت موجود، اندک بودن داده‌ها بود که این خود مشکل تقسیم



شکل ۵. نمودار تقسیم داده با استفاده از بخش‌بندی و شبکه کوهونن (Samanta et al., 2004)

Fig. 5. Schematic diagram of data division using data segmentation and Kohonen network (Samanta et al., 2004)

متغیرهای ورودی متغیرهای توصیفی بود که شامل سنگ‌های دگرگونی، ولکانیکی متوسط، سنگ‌آهک، باتولیت، ولکانیکی فلسی، ولکانیکی بایمودال، کونگومرا، رسوبات و شکستگی هاست. ورودی‌هایی که شامل مشخصات رخساره‌ای سنگ‌ها بود، بدین صورت مقاردهی شد که با در نظر گرفتن یک سلول به مساحت یک کیلومتر مربع و محاسبه سطح اشغال شده برای هر رخساره، به ورودی‌ها مقاردهی شد. برای شکستگی‌ها نیز محدوده‌ای ۳۰۰ متری در نظر گرفته شد.

هریس و همکاران (Harris et al., 2003)، در پژوهشی چهار روش وزن شواهد، شبکه عصبی مصنوعی احتمالاتی، آنالیز تفکیک و رگرسیون لجستیک را برای تعیین توانایی معدنی سه منطقه مختلف به کار گرفتند. منطقه اول، طلای کارلین<sup>۱</sup> بود که متغیرهای ورودی، شامل هشت متغیر نقشه شماتیک، ساختار زمین‌شناسی، مؤلفه عمودی مغناطیسی، نسبت مقاومت، مقدار کل رادیومتری، مقدار طلا، مقدار آرسنیک و مقدار جیوه بود. منطقه دوم، منطقه کانای زایی مس آلاموس<sup>۲</sup> بود. در این جا

1. Carlin  
2. Alamos

از ۱۴۳ گمانه بود. در بین داده‌ها روی اجزایی تمرکز داده شد که میزان بالای سیلیس و اکسید آلومینیوم به عنوان عناصر اصلی و مس، سرب و روی به عنوان عناصر کمیاب داشته باشند. با این که مقادیر زیادی از این داده‌ها دارای توزیع تقریباً نرمال یا لاگ نرمال بودند، یافتن ارتباط و همبستگی بین مؤلفه‌ها از طریق روش‌های زمین آماری میسر نشد. در نهایت، با استفاده از مدل عصبی مصنوعی توزیع توانایی معدنی منطقه بررسی و ترسیم شد.

در تحقیقی دیگر، بوگرین و همکاران (Bougrain et al., 2003)، نقشه توانایی منطقه معدنی در امریکای جنوبی را با استفاده از مدل شبکه عصبی مصنوعی تهیه کردند. داده‌های آنها از نقشه GIS منطقه که شامل داده‌های زمین‌شناسی، ژئوفیزیکی و ژئوشیمیایی بود، استخراج شده بود. ۲۵ مشخصه از داده‌های یادشده استخراج شد. این ویژگی‌ها شامل موارد نوع و سن سنگ درون‌گیر، نزدیکی به امتداد گسل مجاور، شدت و عمق زلزله در زیر ذخیره، فاصله از آتشفشان فعال، مشخصات هندسی منطقه فرورانش و موقعیت ذخیره بود. برای آموزش مدل، دو طبقه خروجی در نظر گرفته شد که شامل "ذخیره" و "باطله" می‌شد. مناطق ذخیره شامل ۳۹۸ موقعیت شناخته شده بود که دارای توانایی عناصری مانند طلا، نقره، مس، مولیبدن، آنتیموان، جیوه، سرب و روی بودند. ۲۴۳ موقعیت نیز به عنوان باطله مشخص شد. انتخاب مناطق باطله از اهمیت بالایی برای آموزش مدل برخوردار بود. چون این مناطق در عین حال که باید عاری از پتانسیل معدنی باشد، باید هم از لحاظ موقعیت و هم از لحاظ مشخصات ساختاری و زمین‌شناسی نزدیکی خاصی با مناطق ذخیره داشته باشد. با این مشخصات ذکر شده نقشه توانایی منطقه تهیه شد.

در پژوهشی دیگر، طهماسبی و هزارخانی (Tahmasebi and Hezarkhani, 2011)، برای بهینه‌سازی و کاهش پیچیدگی مدل شبکه عصبی مصنوعی و همچنین جلوگیری از قرار گرفتن در مینیمم محلی، روشی را ارائه نمودند. بدین منظور چندین مدل

خروجی مدل نیز مناطق کانه‌زایی مس بود که مناطق کانه‌زایی نیز با محدوده‌ای ۵۰۰ متری از مناطق عقیم مشخص می‌شدند. منطقه سوم، منطقه نوادا<sup>۱</sup> دارای کانه‌زایی مس بود. ورودی‌های مدل شامل متغیرهای توصیفی بر اساس ساختار زمین‌شناسی و سن زمین‌شناسی و همچنین رادیومتری، مغناطیس‌سنجی، ثقل‌سنجی و داده‌های ژئوشیمیایی بود. خروجی مدل نیز مقدار مس بود. روش‌های مختلف در سه منطقه مختلف نتایج تقریباً متفاوتی را نشان داد.

در پژوهشی دیگر، او و لی (Oh and Lee, 2010)، از مدل شبکه عصبی مصنوعی برای تعیین توانایی معدن طلا واقع در کره جنوبی استفاده کردند. داده‌های ورودی مدل آنها شامل داده‌های ژئوفیزیکی (مغناطیس‌سنجی)، زمین‌شناسی (ساختار زمین‌شناسی و گسل‌ها) و داده‌های ژئوشیمیایی بود. ۷۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای آزمون به کار گرفته شد. برای آموزش مدل، چهار مجموعه داده متفاوت با استفاده از روش‌های نسبت احتمال<sup>۲</sup> و وزن شواهد تشکیل شد.

در پژوهشی، ریگول سانچز و همکاران (Rigol-Sanchez et al., 2003)، از مدل شبکه عصبی مصنوعی پس‌انتشار برای تعیین توانایی طلای منطقه مورد بررسی، استفاده کردند. متغیرهای ورودی شامل: تصاویر ماهواره‌ای، داده‌های ژئوشیمیایی (۵۹ عنصر در ۳۷۲ موقعیت)، برداشت مغناطیس‌سنجی و ثقل‌سنجی (۳۳۰ ایستگاه زمینی) و نقشه درزه و شکستگی‌ها بود. این داده‌ها در فضای GIS به صورت لایه‌های اطلاعاتی روی یکدیگر قرار گرفتند. خروجی مدل شامل ۴۹ موقعیت شناخته شده کانه‌زایی طلا بود. بعد از آنالیز و پیش پردازش داده‌ها، مدل آموزش‌دیده و نقشه توانایی طلای منطقه مورد بررسی ترسیم شد.

کویکه و همکاران (Koike et al., 2002)، در پژوهشی با استفاده از شبکه عصبی مصنوعی به بررسی توزیع عناصر در ذخایر نوع کروکو در ژاپن پرداختند. داده‌های آنها شامل داده‌های زمین‌شناسی و ژئوشیمیایی به دست آمده از ۱۹۱۷ مغزه

1. Nevada


2. Likelihood ratio

توانایی‌های معدنی اندکی با موقعیت مشخص موجود بود، آموزش شبکه نسبت به شبکه‌های عصبی مصنوعی مرسوم بهتر انجام شد. همچنین پیش‌بینی توانایی معدنی منطقه به صورت باینری و چند طبقه انجام شد که هر چه تعداد طبقات بالاتر می‌رفت، خطای پیش‌بینی نیز بیشتر می‌شد.

در تحقیقی دیگر، چاترجی و همکاران (Chatterjee et al., 2006)، از مدل شبکه عصبی مصنوعی برای تخمین عیار در معدن سنگ آهک واقع در هند استفاده کردند. ورودی مدل شامل موقعیت فضایی نمونه و ۹ ویژگی لیتولوژیکی بود. در کل ۱۱ مؤلفه به عنوان ورودی انتخاب شد. شکل ۶ ساختار شبکه عصبی مصنوعی به کار رفته را نشان می‌دهد. خروجی مدل نیز ۴ ویژگی ماده معدنی یعنی عیار آهک، اکسید آهن، سیلیس و اکسید آلومینیوم بود. برای بررسی کارایی این روش، مقدار عیار با روش کریجینگ نیز تخمین زده شد که نتایج به دست آمده، برتری روش پیشنهاد شده را نشان داد.

عصبی مصنوعی را آزمایش و مدلی که کمترین خطا را داشت، انتخاب کردند. این مدل از پیچیدگی کمتری نسبت به بقیه مدل‌ها برخوردار بود و با سرعت بیشتری پردازش داده‌ها را انجام می‌داد. همچنین این مدل نسبت به بقیه مدل‌ها، با تعداد داده کمتری آموزش می‌یافت. برای تعیین کارایی این روش، با استفاده از داده‌های عیار آهن یک معدن نیز روش‌های تخمین‌گر دیگری مانند روش زمین‌آمار و پرسپترون چند لایه، پتانسیل معدنی منطقه تعیین شد که کارایی بالاتر روش جدید ارائه شده را نشان می‌داد.

در پژوهشی دیگر، بهنیا (Behnia, 2007)، با استفاده از شبکه عصبی مصنوعی پیوند شعاعی پایه، به تهیه نقشه توانایی یک منطقه معدنی پرداخت، داده‌های مورد استفاده شامل لایه‌های اطلاعاتی چینه‌شناسی، زمین‌شناسی ساختاری، ژئوفیزیکی، ژئوشیمیایی و توانایی‌های معدنی با موقعیت مشخص بودند. یکی از مزایای استفاده از این روش این بود که به دلیل این که منطقه مورد نظر به لحاظ کار اکتشافی چندان مورد توجه قرار نگرفته و



شکل ۶. ساختار شبکه عصبی مصنوعی چندلایه به کار رفته در تخمین سنگ آهک (Chatterjee et al., 2006)

Fig. 6. Architecture of multilayered artificial neural network for estimation of limestone. (Chatterjee et al., 2006)

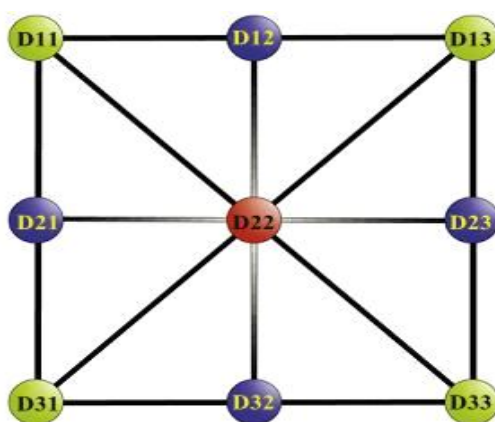
بود که در آموزش مدل، مشکل ایجاد می‌کرد. آنها با استفاده از روش ایجاد داده‌های تصادفی<sup>۱</sup> به افزایش تعداد داده‌های ورودی برای آموزش مدل پرداختند. نتایج نشان داد که با افزایش حجم مجموعه داده ورودی، دقت پیش‌بینی و کارایی مدل بالاتر می‌رود.

در تحقیقی دیگر، گوو (Guo, 2010)، برای تعیین میزان عیار مگنتیت و هماتیت از مدل شبکه عصبی مصنوعی استفاده کرد. مجموعه داده مورد استفاده، شامل میزان حساسیت مغناطیسی و نیز مقادیر هماتیت و مگنتیت سنگ مربوطه بود. یک مدل پرسپترون چهار لایه برای آموزش انتخاب شده و با مجموعه داده ذکر شده، آموزش یافت. با این مدل آموزش داده شده، میزان عیار مگنتیت و هماتیت با استفاده از داده‌های حساسیت مغناطیسی که توسط روش ژئوفیزیکی برداشت می‌شود، تخمین زده شد.

در پژوهشی نیز، لی و همکاران (Li et al., 2010c)، با استفاده از ترکیب انتقال موجک<sup>۲</sup> و شبکه عصبی مصنوعی که به اختصار شبکه عصبی مصنوعی موجکی<sup>۳</sup> نامیده می‌شود، به تخمین عیار در یک ذخیره مس پرداختند. مجموعه داده آنها شامل عیار مس در بلوک‌های مشخص و موقعیت مکانی نمونه‌ها بود. شکل هر بلوک بدین صورت بود که مرکز هر بلوک توسط نقاط اطراف تخمین زده می‌شد (شکل ۷).

در تحقیقی دیگر، لی و همکاران (Lee et al., 2014)، توانایی معدنی طلا و نقره یک منطقه را با استفاده از ترکیب چهار روش متفاوت به دست آوردند. روش‌های مورد استفاده آنها عبارت بود از: نسبت همسایگی، وزن شواهد، رگرسیون لجستیک و شبکه عصبی مصنوعی. مجموعه داده مورد استفاده، شامل ۴۶ ذخیره طلا-نقره شناخته شده در منطقه و ۲۶ متغیر مرتبط با کانه‌زایی طلا نقره شامل داده‌های زمین‌شناسی و سنگ‌شناسی، شکل گسل‌ها، داده‌های ژئوشیمیایی عناصر مرتبط و داده‌های ژئوفیزیکی (مغناطیس‌سنجی)، می‌شد. توانایی معدنی به‌طور جداگانه با چهار روش نسبت همسایگی، وزن شواهد، رگرسیون لجستیک و شبکه عصبی مصنوعی به دست آمد که دقت طبقه‌بندی این روش‌ها به ترتیب ۷۲/۲۴ درصد، ۶۵/۸۵ درصد، ۷۲/۲۳ درصد و ۷۱/۰۲ درصد اندازه‌گیری شد. با ترکیب نتایج به دست آمده این چهار روش به وسیله روش نسبت همسایگی، دقت طبقه‌بندی به ۸۳/۹۷ درصد ارتقا یافت که بهبود بسیار مناسبی بود.

در پژوهشی دیگر، براون و همکاران (Brown et al., 2003)، با استفاده از مدل پرسپترون چندلایه، به تعیین توانایی یک معدن طلا پرداختند. مجموعه داده آنها چندین لایه توصیفی و همچنین داده‌های عددی بود که در GIS روی هم قرار گرفته بودند. یکی از مشکلات این پژوهش، تعداد کم ذخیره‌های شناخته شده



شکل ۷. آرایش فضایی ورودی و خروجی (نقطه قرمز نشان‌دهنده نقطه تخمین است) (Li et al., 2010c)

Fig. 7. Input/Output configurations (red indicate estimation) (Li et al., 2010c)

1. Random noise
2. Wavelet transform
3. Wavelet Neural Network(WNN)

عنصر آرسنیک، آنتیمون، کادمیم، سرب و روی به‌عنوان خروجی و دو عنصر طلا و نقره نیز خروجی مدل محسوب شدند. آموزش مدل توسط الگوریتم بهینه‌سازی علف‌های هرز انجام شد. در نهایت، به‌عنوان مقایسه، مدل‌سازی مشابهی با روش رگرسیون چندگانه خطی<sup>۱</sup> نیز انجام شد که نتایج به‌دست آمده، برتری مدل هوشمند را نشان داد (جدول ۱).

در تحقیقی دیگر، بازدار و همکاران (Bazdar et al., 2015b)، با استفاده از مدل شبکه عصبی مصنوعی، به پیش‌بینی عیار طلا و نقره در بخشی از کانسار طلای زرشوران ایران پرداختند. داده‌های مورد استفاده، داده‌های به‌دست آمده از آنالیز ۳۶ عنصری برداشت شده از دو ترانسه در محل کانسار بود. با استفاده از ماتریس همبستگی، عناصر دارای همبستگی بالا با طلا و نقره به‌عنوان ورودی مدل انتخاب شدند. بدین ترتیب پنج

جدول ۱. مقایسه خطای مدل شبکه عصبی مصنوعی با نتایج رگرسیون خطی چندگانه (Bazdar et al., 2015b)

Table. 1. Comparison of the results of ANN and MLR (Bazdar et al., 2015b)

Data set					
Gold	Training	0.6920	0.6463	0.0915	0.1580
	Test	0.7368	0.7602	0.0879	0.1122
silver	Training	0.9553	0.7646	0.0268	0.0855
	Test	0.9815	0.8859	0.0144	0.0479

بیانگر حالت دو طبقه‌ای و  $m$  نشانگر تعداد نمونه‌هاست، یافتن چندسطحی  $f(x)=0$  برای جدا کردن داده‌های ورودی در حالتی که دو طبقه جداپذیر خطی باشند، مقدور است.

$$f(x) = w \cdot x + b = \sum_{k=1}^m w_k \cdot x_k + b = 0 \quad (1)$$

در معادله بالا  $w$  بردار وزنی و  $b$  بایاس را نشان می‌دهند.  $w$  و  $b$  برای تعیین موقعیت چندسطحی جداکننده به کار برده می‌شوند. این چندسطحی جداکننده باید قیود زیر را برآورده کند.

$$y_i \cdot f(x_i) = y_i \cdot (w_i \cdot x_i + b) \geq 1 \quad i = 1, 2, \dots, m \quad (2)$$

با معرفی لاگرانژین چندگانه  $\alpha_i$  مسأله یافتن چندسطحی جداکننده بهینه، به‌صورت زیر فرمول‌بندی می‌شود:

$$\begin{aligned} \text{Maximize } L(\alpha) &= \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \\ \text{Subject to } \sum_{i=1}^m \alpha_i y_i &= 0, \quad \alpha_i \geq 0, \quad i = 1, \dots, m \end{aligned} \quad (3)$$

تابع تصمیم خطی با حل مسأله بهینه‌سازی دو گانه بالا ایجاد می‌شود که به‌صورت زیر تعریف می‌شود:

## ماشین بردار پشتیبان<sup>۲</sup> و کاربرد آن در اکتشاف منابع معدنی

### ماشین بردار پشتیبان

در مهندسی گاهی با مسائلی روبه‌رو می‌شویم که به ناچار با یک دسته داده‌های تجربی پراکنده سر و کار داریم. برای مدل کردن و استفاده از این داده‌ها، معمولاً مقایسه‌ای بین داده‌ها انجام می‌شود و آنها را به نسبت تعداد طبقه‌هایی که در آنها قرار دارند، جدا می‌کند. ماشین بردار پشتیبان روشی مؤثر برای مدل‌سازی داده‌هاست. این روش با افزایش ابعاد مسأله و با استفاده از نگاشت کرنل یک چارچوب کاری یکپارچه را برای اغلب مدل‌ها فراهم می‌کند و امکان مقایسه را به‌وجود می‌آورد. اساس این روش برای تقسیم‌بندی دو طبقه‌ای خروجی‌ها بر اساس ورودی‌های معلوم است (Fattahi et al., 2013a). به‌طور خلاصه می‌توان گفت در روش ماشین بردار پشتیبان، بردارهای ورودی به یک فضای چند بعدی نگاشت می‌شوند.

با داشتن مجموعه داده معلوم  $T = \{x_i, y_i\}_{i=1}^m$  که  $x_i \in R^n$ ، نشان‌دهنده بردارهای ورودی  $y_i \in \{+1, -1\}$

1. Multiple Linear Regression (MLR)  
2. support vector machine(SVM)

ماشین بردار پشتیبان پیشرفته<sup>۲</sup> به تهیه نقشه توزیع مکانی آرسنیک در یک معدن طلا، اقدام کردند. دو روش یاد شده برای پیش‌بینی غلظت آرسنیک در رسوبات با استفاده از توزیع غلظت طلا در رسوبات، مقدار آرسنیک و موقعیت مکانی نمونه‌ها، مورد استفاده قرار گرفتند. آنالیز نتایج کارآیی بیشتر و قابلیت پیش‌بینی بهتر ماشین بردار پشتیبان و حداقل مربعات ماشین بردار پشتیبان قوی را نسبت به روش‌های شبکه‌های عصبی مصنوعی و کریجینگ نشان داد. عملکرد ماشین بردار پشتیبان توسط نقاط دورافتاده تحت تأثیر قرار گرفت. حذف نقاط دورافتاده از مجموعه داده‌ها و استفاده از ماشین بردار پشتیبان، نتایج را بهبود بخشید.

در پژوهشی دیگر، اسمیرنوف و همکاران ( Smirnoff et al., 2008)، با استفاده از ماشین بردار پشتیبان، به ساختن مدل سه بعدی زمین‌شناسی پرداختند. سه مختصات منحصر به فرد برای هر نقطه در فضای بازسازی سه بعدی، توصیف شد. با این حال، تنها تعداد محدودی از آنها از طریق داده‌های حفاری، نقشه‌برداری زمین‌شناسی سطحی و پروفایل لرزه‌ای، در دسته‌هایی طبقه‌بندی شدند. نقاط با برجسب<sup>۳</sup> دسته‌های مشخص، تبدیل به نمونه‌ها در مجموعه آموزش ماشین بردار پشتیبان شدند، در حالی که مختصات نقطه در فضای سه بعدی، به عنوان ویژگی نمونه‌ها، استفاده شد.

در پژوهشی دیگر، وانگ و چانگ-یو ( Wang and ChangYu, 2010)، تصاویر سنجش از راه دور و ماشین بردار پشتیبان را با موفقیت برای اکتشاف منابع معدنی، استفاده کردند. مجموعه داده مورد استفاده شامل تصاویر سنجش از راه دور و مقدار سه کانی مرتبط با آلتراسیون و کانه‌زایی یعنی کائولینیت، کلریت و ایلیت بود. پس از پیش پردازش داده‌های سنجش از راه دور، شامل کالیبراسیون داده‌ها، تصحیح جوی و تصحیح هندسی و داده‌های عناصر هدف، مدل آموزش دیده و منطقه مورد نظر به واحدهای لیتولوژیکی مربوط به عناصر طبقه‌بندی شد.

$$f(x) = \text{sign} \left( \sum_{i,j=1}^m \alpha_i y_i (x_i, x_j) + b \right) \quad (4)$$

روش ماشین بردار پشتیبان در طبقه‌بندی غیرخطی با استفاده از تابع کانونی استفاده می‌شود. با استفاده از تابع نگاشت غیرخطی  $\phi(\bullet)$  در جایی که طبقه‌بندی خطی وجود دارد، داده‌های اصلی  $X$  به فضای ویژگی با ابعاد بالا نگاشته می‌شود.

(5) تابع کانونی نامیده می‌شود و  $K(x_i, x_j) = \phi(x_i)\phi(x_j)$  در روش ماشین بردار پشتیبان،  $K(x_i, x_j) = \exp(-\|x_i - x_j\|/2\sigma^2)$  RBF ماشین بردار پشتیبان ساخته شده به وسیله تابع پایه‌ای شعاعی، توانایی بسیار خوبی در طبقه‌بندی غیرخطی دارد. به همین دلیل در اغلب پژوهش‌ها تابع RBF در الگوریتم ماشین بردار پشتیبان استفاده می‌شود. در این جا C و  $\sigma$  مؤلفه‌های مشخص شده توسط طراح است. انتخاب خوب مؤلفه‌ها نقش برجسته و مهمی در عملکرد مطمئن ماشین بردار پشتیبان ایفا می‌کند که می‌توان با استفاده از الگوریتم‌های بهینه‌سازی، مقدار بهینه این مؤلفه‌ها را به دست آورد. در بعضی مسائل نیز طبقه‌بندی دو طبقه‌ای کارآیی چندانی ندارد و از رگرسیون بردار پشتیبان برای تعیین مقدار دقیق خروجی استفاده می‌شود ( Fattahi et al., 2015; Fattahi, 2016).

لازم به یادآوری است که با توجه به گستردگی مطالب در مورد روش ماشین بردار پشتیبان، مطالب دیگری نیز وجود دارد که به جهت رعایت اختصار اشاره‌ای به آنها نشده است. لذا جهت فهم بیشتر روش ماشین بردار پشتیبان، بررسی سایر منابع توصیه می‌شوند (Ng and Gong, 2002; Ancona et al., 2003; Cao and Tay, 2003; Shin et al., 2005; Chen and Hsieh, 2006; Huang et al., 2007; Gang and Zhuping, 2011).

### کاربرد ماشین بردار پشتیبان در اکتشاف منابع معدنی

در پژوهشی، تواراکافی و همکاران ( Twarakavi et al., 2006)، با استفاده از ماشین بردار پشتیبان و حداقل مربعات

1. Radial-Basic Function (RBF)

2. least-square support vector machines (robust LS-SVM)

3. Label

از آزمایش، ترکیبی از مؤلفه‌های مستقل گرفته شده از استر، مؤلفه‌های اصلی، شیب گرفته شده از مدل رقمی ارتفاع، انحنا و زبری و متوسط مغناطیس سنجی هوایی و واریانس حساسیت مغناطیسی، بالاترین دقت و درستی طبقه‌بندی کلی ۹۲/۳۴ درصد برای طبقه‌های سنگ‌شناسی بر روی نمونه‌های اعتبارسنجی مستقل ارائه شد. مقایسه با طبقه‌بندی حداکثر احتمال، نشان داد که ماشین بردار پشتیبان، دقت بالاتری هم از نظر طبقه‌بندی نمونه‌های اعتبارسنجی مستقل و هم از نظر شباهت با نقشه‌های سنگ‌شناسی سنگ بستر موجود، فراهم می‌کند.

در تحقیقی دیگر، عابدی و همکاران (Abedi et al., 2012)، طبقه‌بندی چندگانه مناطق توانایی معدنی مس پورفیری نوچون واقع در استان کرمان ایران را با استفاده از ماشین بردار پشتیبان انجام دادند. مجموعه داده آنها شامل ۱۳ لایه با داده‌های زمین‌شناسی، ژئوفیزیکی و ژئوشیمیایی استخراج شده از ۲۱ گمانه اکتشافی موجود در منطقه بود. تمرکز اقتصادی مس (به‌عنوان مثال، عیار مس بالای حد) در هر یک از ۲۱ گمانه حفر شده توسط کارشناسان مورد بررسی قرار گرفت تا آنها را به پنج طبقه، طبقه‌بندی کنند. نحوه طبقه‌بندی چنین بود که بهترین طبقه که برای ادامه عملیات حفاری اکتشافی است، متعلق به طبقه ۵ و طبقه کیفی بسیار خوبی است. اگر منطقه مورد بررسی مربوط به طبقه ۱، ۲ و ۳ باشد، حفاری اضافی توصیه نمی‌شود؛ حفاری در مناطق متعلق به طبقه ۴، بسته به نظر کارشناس است. روش ماشین بردار پشتیبان که روش داده محور تشخیص الگوست، ۲۱ گمانه را به ۵ طبقه با میزان درستی طبقه‌بندی ۵۲/۳۸ درصد تقسیم کرد.

در تحقیقی دیگر، چاترجی و بنداپادیای (Chatterjee and Bandopadhyay, 2011)، تخمین ذخیره پلاتین خلیج گودنیوز با استفاده از حداقل مربعات رگرسیون بردار پشتیبان<sup>۳</sup> با انتخاب بعد فضای ورودی و ابر مؤلفه انجام دادند. تخمین ذخیره ذخایر پلاسز به دلیل تنوع در ذخایر، همیشه کار دشوار و

در پژوهشی دیگر، زوو و کارانزا (Zuo and Carranza, 2011)، با استفاده از ماشین بردار پشتیبان به تهیه نقشه توانایی طلا پرداختند. طبق بررسی‌های قبلی در این منطقه اغلب ذخایر موجود طلا در ارتباط با محور طاق‌دیس با روند شمال شرقی- جنوب غربی و همچنین مرز بین دو سازند معین بوده‌اند. بنا براین نزدیکی به محور طاق‌دیس و مرز بین سازندها، به‌عنوان کنترل‌کننده و مؤلفه‌های مدل سازی در نظر گرفته شد. هم برای مناطق با توانایی معدنی و هم مناطق عقیم، نقاطی برای آموزش مدل مشخص شد. مناطق ذخیره‌دار شامل ۲۰ نقطه با توانایی مشخص و مناطق بدون ذخیره شامل دو مجموعه تصادفی ۲۰ نقطه‌ای بودند. با انجام آموزش مدل، از بین دو مجموعه داده برای نقاط غیر ذخیره مجموعه‌ای که مدل دقت بیشتری را با آن نشان می‌داد، انتخاب شد. در نهایت، با مدل آموزش یافته و همچنین روش وزن شواهد، توانایی منطقه مورد نظر تعیین شد که برتری روش ماشین بردار پشتیبان را به روش وزن شواهد نیز نشان داد.

در پژوهشی، یوو و همکاران (Yu et al., 2012)، طبقه‌بندی لیتولوژیکی (سنگ‌شناسی) با داده‌های سنجش از راه دور و با استفاده از روش ماشین بردار پشتیبان، انجام دادند. در این بررسی، الگوریتم ماشین بردار پشتیبان برای طبقه‌بندی سنگ‌شناسی خودکار منطقه مورد بررسی در شمال غرب هند با استفاده از تصاویر استر<sup>۱</sup>، همراه با مدل رقمی<sup>۲</sup> گرفته شده از استر و داده مغناطیس‌سنجی هوایی، به کار گرفته شد. مجموعه‌ای از ماشین بردار پشتیبان با استفاده از ترکیب مختلف مجموعه داده‌های ورودی از میان ۴۷ مجموعه داده‌ها از جمله ۱۴ باند اصلی استر و ۳۳ مجموعه داده‌های مشتق شده از داده‌های استر، مدل رقمی ارتفاع استخراج و داده مغناطیس‌سنجی هوایی انتخاب شد و برای تعیین ورودی مطلوب که بالاترین دقت طبقه‌بندی را ارائه دهد، مورد آزمایش قرار گرفتند. شکل ۸، دید کلی از مدل ماشین بردار پشتیبان به کار رفته را نشان می‌دهد. بعد

1. Advanced Space-borne Thermal Emission and Reflection Radiometer (ASTER)

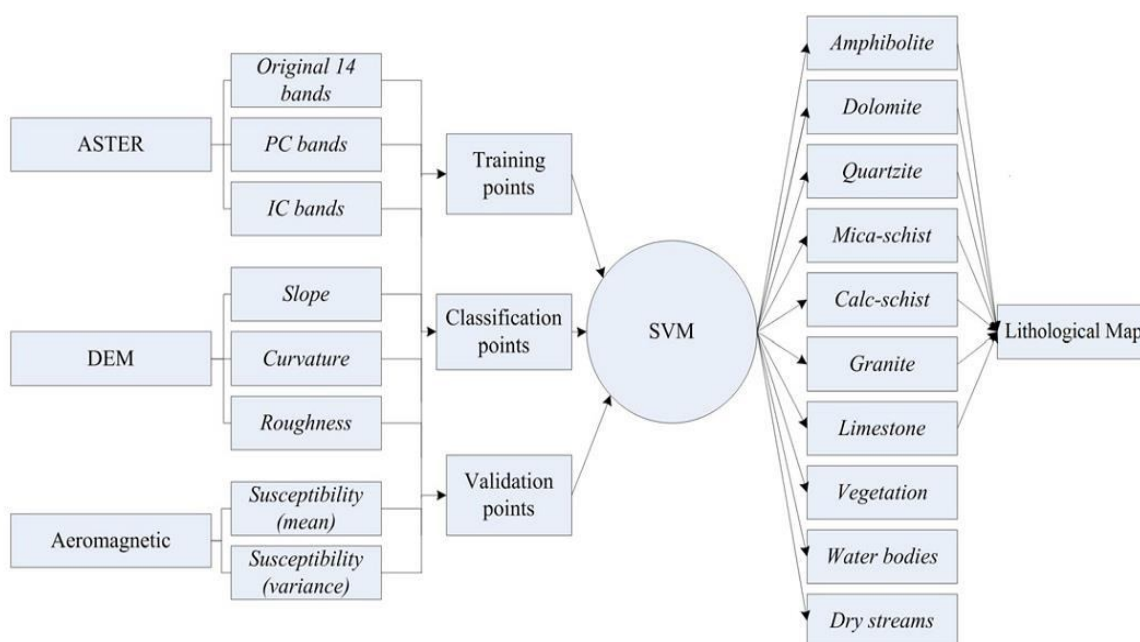
2. Digital Elevation Model (DEM)

3. least squares support vector regression(LSSVR)



نشان داد که اگر ۸ نمونه در همسایگی، فاصله آنها و زاویه از نقطه تخمین به عنوان ورودی برای مدل ماشین بردار پشتیبان در نظر گرفته شود، کارایی مدل بهتر از حالت‌های دیگر است. ورودی مشخص شده پیشنهادی مدل ماشین بردار پشتیبان با کریجینگ و مدل مرسوم ماشین بردار پشتیبان (موقعیت مکانی به عنوان ورودی) در تخمین ذخیره، مقایسه شد. نتایج مقایسه نشان داد که فضای ورودی مدل ماشین بردار پشتیبان پیشنهادی، بهتر از دو مدل دیگر است.

چالش برانگیزی بوده است. هنگامی که داده‌های مته گمانه‌ها اندک و پراکنده باشند، پیچیدگی تخمین منابع افزایش می‌یابد. از آن جا که ذخایر پلاسرا با تعداد کم نمونه واریوگرام قطعه قطعه تولید می‌کنند، روش‌های سنتی زمین‌آماري مانند کریجینگ معمولی، گاهی اوقات قادر به تولید نتایج رضایت‌بخش نیستند. در این بررسی ماشین بردار پشتیبان برای تخمین ذخایر پلاسرا پلاتین استفاده شد. مؤلفه‌های ماشین بردار پشتیبان و پهنای باند تابع هسته توسط الگوریتم ژنتیک انتخاب و الگوریتم بر روی یک مجموعه داده تست آزمایش شد. نتایج



شکل ۸. دید کلی فرآیند طبقه‌بندی توسط ماشین بردار پشتیبان (Yu et al., 2012)

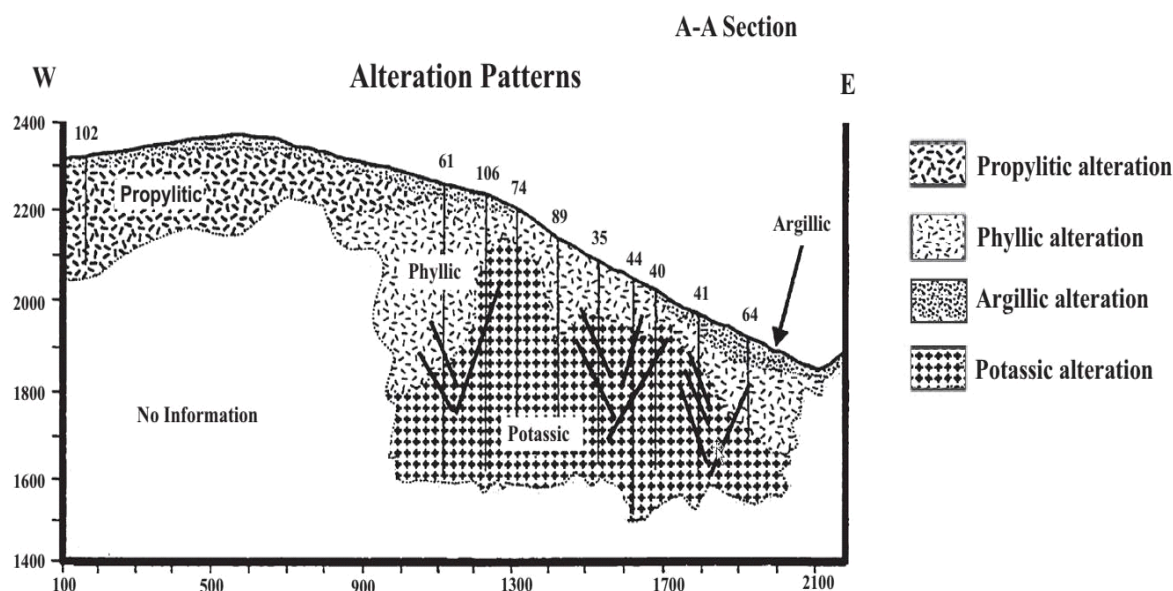
Fig. 8. Overview of SVM classification process (Yu et al., 2012)

بیشتر در ارتباط با آلتراسیون پتاسیک و کمی نیز با آلتراسیون فلیک است؛ بنابراین جدایش مرز آلتراسیون‌ها از اهمیت زیادی برخوردار بود. بهترین مقادیر برای C و  $\lambda$  (که از مهمترین مؤلفه‌های ماشین بردار پشتیبان هستند) که در آموزش و آزمون داده‌ها کارایی خوبی داشتند، به ترتیب  $0.001/0$  و  $1$  بود. هنگامی که این مقادیر برای C استفاده شد، مناطق آلتراسیون فلیک و پتاسیک با دقت حدود به ترتیب ۹۵ درصد و ۱۰۰

در تحقیقی دیگر، عباس‌زاده و همکاران (Abbaszadeh et al., 2013)، مناطق آلتراسیون ذخیره مس پورفیری سونگون را با روش یادگیری ماشین مبتنی بر ماشین بردار پشتیبان جدا کردند. مجموعه داده آنها، اطلاعات ادخال سیال، و هفت متغیر از جمله دمای همگن، شوری، فشار، عمق، چگالی و عیار مس بود. شکل ۹، نقاط نمونه‌برداری در منطقه را نشان می‌دهد. از آنجایی که بر اساس بررسی‌ها مشخص شده بود کانی‌سازی مس

(Malekzadeh Shafaroudi and Karimpour, 2015; )  
(Malekzadeh Shafaroudi et al., 2015).

درصد، از هم جدا شدند. تعیین مناطق آلتراسیون در پروژه‌های اکتشافی جزو مهمترین بخش‌های پروژه است و پژوهشگران زیادی با روش‌های دیگری این مناطق را از هم تفکیک کرده‌اند



شکل ۹. پروفایل زون‌های آلتراسیون در مقطع A-A. شماره‌های روی سطح، نقاط حفاری شده را نشان می‌دهد (Hezarkhani and Williams-Jones, 1998).

**Fig. 9.** Profiles showing the alteration zones along cross-sections A-A. Numbers on surface indicate drill holes (Hezarkhani and Williams-Jones, 1998).

روش بردار ماشین پشتیبان برتری بیشتری نسبت به سایر روش‌ها دارد.

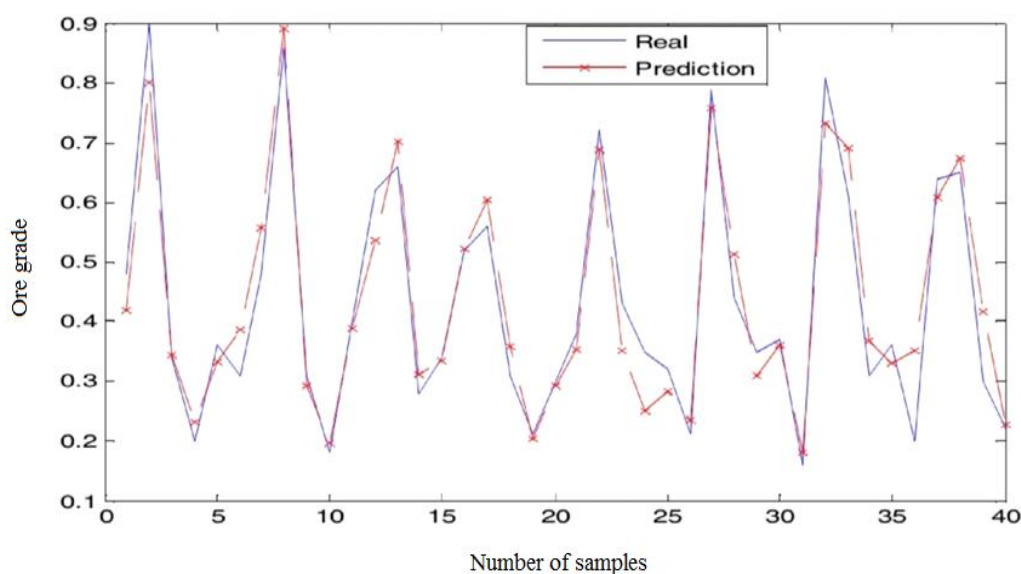
در تحقیقی دیگر، ساوو کرون و همکاران (Savu-Krohn et al., 2011)، دو روش جدید یادگیری ماشین به نام برنامه‌نویسی خطی پیشرفته<sup>۱</sup> و روش ماشین بردار پشتیبان را برای طبقه‌بندی توانایی معدنی کولتان (سنگ معدنی تانتالیم و نیوبوم) به کار گرفتند. آنها این طبقه‌بندی را با استفاده از مجموعه داده‌های ژئوشیمیایی منطقه انجام دادند. نتایج به دست آمده، برتری روش ماشین بردار پشتیبان را نسبت به برنامه‌نویسی خطی پیشرفته نشان داد.

در تحقیقی دیگر، لی و همکاران (Li et al., 2010a)، روش

در تحقیقی دیگر، پوروال و همکاران (Porwal et al., 2010b)، با استفاده از روش ماشین بردار پشتیبان، به طبقه‌بندی زمین‌شناسی کمر بند متالورژیک آروالی در هندوستان پرداختند. منطقه آروالی منبع ذخایر مهمی از فلزات پایه از جمله مس و روی است. تشخیص الگوی کنترل کننده‌های کانه‌زایی از اهمیت زیادی برخوردار است که می‌تواند در پیش‌بینی مناطق مستعد مورد استفاده قرار گیرد. این بررسی بر اساس داده‌های به دست آمده از روش ژئوفیزیکی لرزه‌نگاری دو بعدی بازتابی، زمین‌شناسی، زمین باستان‌شناسی مرتبط با منطقه انجام شد. مقایسه این روش با مدل‌های به دست آمده با روش‌های دیگر از جمله شبکه عصبی مصنوعی و رگرسیون لجستیک، نشان داد که

ماشین بردار پشتیبان را برای ساخت یک مدل طبقه‌بندی توانایی معدنی بر اساس عیار ماده معدنی به کار گرفتند. مجموعه داده آنها موقعیت فضایی سه بعدی نقاط نمونه‌برداری و عیار ماده معدنی بود. برای مقایسه، منطقه مورد نظر با چند روش دیگر نیز مورد بررسی قرار گرفت. روش‌های دیگر شامل پلیگون تیسسن<sup>۱</sup>،

نسبت معکوس فاصله<sup>۲</sup> و درون‌یابی کریجینگ<sup>۳</sup> بود. نتایج به دست آمده، دقت و توانمندی و همچنین اقتصادی بودن روش ماشین بردار پشتیبان را نسبت به سایر روش‌ها نشان داد (شکل ۱۰).



شکل ۱۰. مقادیر تخمین زده و واقعی عیار کانسنگ (Li et al., 2010a)

Fig. 10. Prediction values and real values of ore grade (scale) (Li et al., 2010a)

روش زمین‌آماري مشخص شد. همچنین روش بردار ماشین پشتیبان نسبت به روش شبکه عصبی مصنوعی دارای خطای کمتری بود (جدول ۲).

در تحقیقی دیگر، اوومن و همکاران (Oommen et al., 2011)، دو روش ماشین بردار پشتیبان و ماشین بردار پشتیبان وابسته<sup>۵</sup> را برای توانایی طلا در منطقه خلیج گودنیوز آلاسکا به کار بردند. چند روش سنتی و زمین‌آماري نیز برای مقایسه به کار گرفته شد. مجموعه داده مورد استفاده، موقعیت مکانی نمونه‌ها و عیار طلا بود. منطقه مورد بررسی به دو ناحیه "درون

در تحقیقی دیگر، دوتا و همکاران (Dutta et al., 2010)، دو روش یادگیری ماشین به نام‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی را برای تخمین عیار منطقه معدنی طلا در استفاده کردند. داده‌های ورودی و خروجی مدل‌ها از گمانه‌های حفر شده در منطقه به دست آمدند. داده‌های ورودی موقعیت مکانی نمونه‌ها و سطح آب زیرزمینی و داده خروجی عیار طلا نمونه بود. برای مقایسه با روش‌های زمین‌آماري، تخمین عیار به روش کریجینگ معمولی<sup>۴</sup> نیز انجام شد. با مقایسه روش‌ها و میزان خطای آنها، برتری روش‌های یادگیری ماشین نسبت به

1. Thiessen polygons
2. Ratio distance power inverse
3. Kriging interpolation
4. Ordinary kriging
5. Relevant Vector Machines (RVM)

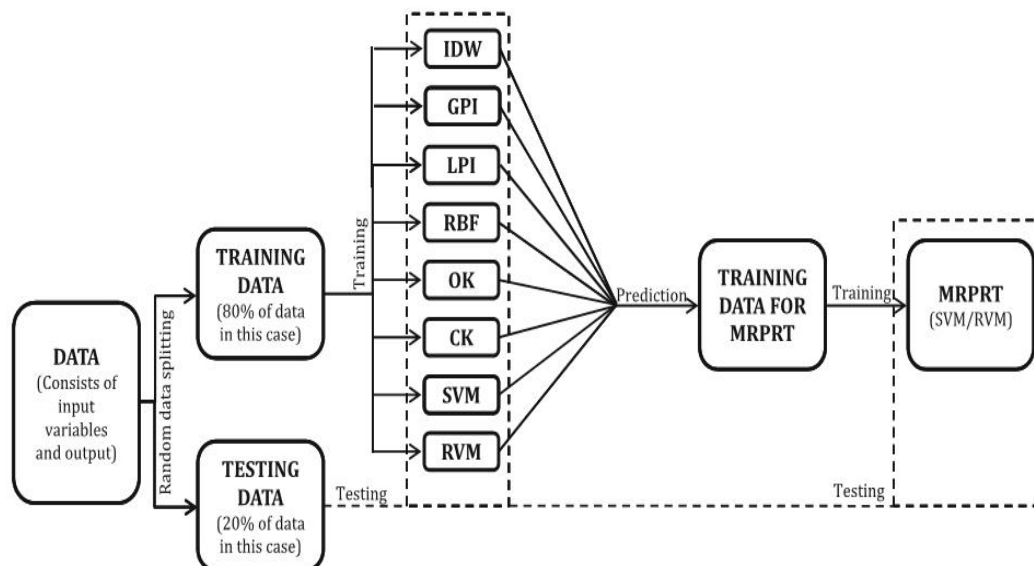
داخل خلیج نشان می‌دهد. البته این افزایش کارآیی در دو ناحیه مورد بررسی متفاوت بود و در درون خلیج بیشتر به چشم می‌خورد.

خلیج " و "بیرون خلیج" تقسیم شد. روش‌های یادگیری ماشین به مراتب کارآیی بهتری نسبت به روش‌های سنتی از خود نشان دادند. شکل ۱۱، نمودار جریان روش آنها را برای نقاط نمونه

جدول ۲. مقایسه کارآیی سه روش به کار رفته در منطقه مورد بررسی "نام" واقع در ایالت آلاسکا (Dutta et al., 2010)

**Table 2.** Comparison between performance of three method used in Nom district located on state of Alaska (Dutta et al., 2010)

Statistics	SVM	NN	OK
Mean Error	-8.1	-1.30	33.54
Mean Absolute Error	341.2	351.50	353.02
Root Mean Squared Error	563.13	564.34	565.23
$R^2$	0.234	0.191	0.193



شکل ۱۱. نمودار جریان روش استفاده شده برای نقاط داخل خلیج (Oommen et al., 2011)

**Fig. 11.** Workflow of the approach considering the sample points inside the Bay (Oommen et al., 2011).

روش نزدیکترین همسایگی به تخمین عیار پرداختند. با استفاده از چند روش مرسوم نیز درون لیتولوژیکی یابی برای تخمین عیار انجام شد که در نهایت دقت بالاتر روش یادگیری ماشین مشخص شد.

در تحقیقی دیگر ژانگ و همکاران (Zhang et al., 2013)، با استفاده از روش حداقل مربعات ماشین بردار پشتیبان پیشرفته به طبقه‌بندی لیتولوژیکی و سپس تخمین عیار ماده معدنی پرداختند. ورودی مدل آنها مختصات مکانی و خروجی آنها نوع لیتولوژیکی زمین بود. پس از تقسیم لیتولوژیکی، با استفاده از

$\mu_{A(x)}$  را تابع عضویت می‌نامند. مجموعه  $A$  از لحاظ ریاضی معادل تابع عضویت  $\mu_{A(x)}$  است و بنابراین با معلوم بودن  $\mu_{A(x)}$  مجموعه  $A$  نیز معلوم خواهد بود (Ross, 2009).

### سامانه استنتاجی فازی

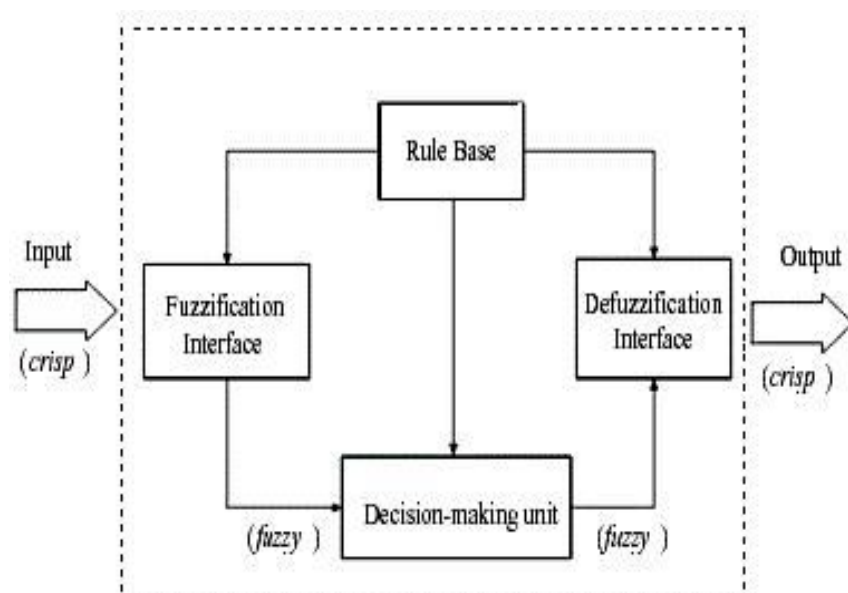
سامانه‌های استنتاج فازی<sup>۱</sup> سامانه‌هایی هستند که پدیده‌های غیر قطعی و نامشخص را توصیف می‌کنند. در سامانه‌های عملی سؤال کلیدی این است که چگونه می‌توان دانش بشری را در چهار چویی مشابه مدل‌های ریاضی رابطه‌مند کرد. آنچه که یک سامانه فازی انجام می‌دهد، تبدیل است؛ بنابراین این سامانه‌ها، سامانه‌هایی مبتنی بر دانش هستند (Zadeh, 1965; Klir and Yuan, 1995). قلب یک سامانه فازی یک پایگاه دانش<sup>۲</sup> بوده که از قواعد اگر-آن‌گاه<sup>۴</sup> فازی تشکیل شده است. یک قاعده اگر-آن‌گاه فازی یک عبارت اگر-آن‌گاه است که بعضی کلمات آن به وسیله توابع عضویت پیوسته مشخص شده‌اند. شکل ۱۲ ساختار یک سامانه فازی را نشان می‌دهد.

### منطق فازی و کاربرد آن در اکتشاف منابع معدنی

#### منطق فازی

یک مجموعه فازی، تعمیم یک مجموعه کلاسیک است که امکان می‌دهد تابع عضویت<sup>۱</sup> هر مقداری را در بازه  $[0, 1]$  اختیار کند. به عبارت دیگر تابع عضویت یک مجموعه کلاسیک فقط می‌تواند دو مقدار صفر و یک داشته باشد؛ در حالی که تابع عضویت یک مجموعه فازی، یک تابع پیوسته در محدوده  $[0, 1]$  است. بنابراین، مجموعه فازی، مجموعه‌ای با یک تابع عضویت پیوسته است. در مجموعه کلاسیک  $A$ ، یک عضو می‌تواند یا کاملاً عضو آن مجموعه باشد و یا کاملاً در آن مجموعه وجود نداشته باشد. تابع عضویت این مجموعه برای اعضا، مقدار یک و برای غیر اعضا، مقدار صفر را بر می‌گرداند. این مقادیر صفر و یک را مقادیر عضویت می‌نامیم. پس در یک مجموعه کلاسیک اعضا فقط می‌تواند دو مقدار بگیرند به نحوی که:

$$\mu_{A(x)} = \begin{cases} 1, & X \notin A \\ 0, & X \in A \end{cases} \quad (6)$$



شکل ۱۲. سامانه‌های فازی متشکل از یک پایگاه دانش که از قواعد اگر-آن‌گاه فازی تشکیل شده است (Abreu and Ribeiro, 2003)

Fig. 12. A fuzzy system structure consisting of knowledge base and if-then rule (Abreu and Ribeiro, 2003)

1. Membership Function
2. Fuzzy Inference System(FIS)
3. Knowledge base
4. If-then rule

برای توضیحات بیشتر روش منطق فازی، منابع هایک، مندل؛ یاگر و زاده ( Mendel, 1995; Hājek, 1998; Yager and Zadeh, 2012)، توصیه می‌شود.

### کاربرد روش منطق فازی در اکتشاف منابع معدنی

در پژوهشی، پوروال و همکاران (Porwal et al., 2003b)، با استفاده از دو مدل منطق فازی دانش محور<sup>۱</sup> به بررسی توانایی معدنی فلزات پایه در ایالت متالورژی آروالی در هندوستان پرداختند. مدل دانش محور از یک تابع عضویت منطقی برای استخراج مقادیر عضویت فازی لایه‌های ورودی استفاده می‌کرد و مدل داده محور که در آن از یک تابع خطی پله‌ای که بر اساس مقدار عددی ارتباط فضایی بین لایه‌های ورودی و ذخایر شناخته شده، ایجاد شده بود، استفاده می‌شد. مجموعه داده آنها شامل چندین لایه اطلاعات زمین‌شناسی مانند سنگ‌شناسی، چینه‌شناسی، محیط رسوبی، نقشه سنگ‌های آذرین مافیک، زمین ساخت و سایر مشخصات ساختاری زمین‌شناسی بود. در نهایت، نتایج به دست آمده از دو مدل دانش محور و داده‌های محور، همخوانی قابل توجهی با یکدیگر داشتند.

در تحقیقی دیگر پوروال و همکاران (Porwal et al., 2006b)، با استفاده از روش ترکیبی منطق فازی و وزن شواهد، پتانسیل معدنی فلزات پایه در ایالت متالورژی آروالی در هندوستان را مورد بررسی قرار دادند. مجموعه داده‌ها لایه اطلاعات زمین‌شناسی مانند سنگ‌شناسی، چینه‌شناسی، محیط رسوبی، نقشه سنگ‌های آذرین مافیک، زمین ساخت و سایر مشخصات ساختاری زمین‌شناسی بود که در بررسی سال ۲۰۰۲ نیز با یک روش منطق فازی دیگر مورد بررسی قرار گرفته بودند. توانایی معدنی منطقه در سه دسته بالا، متوسط و پایین به دست آمد. در قسمت‌های با توانایی بالا و متوسط نسبت به بررسی قبلی افزایش کارایی و دقت نشان داده شد؛ ولی در قسمت‌های با توانایی پایین افت دیده شد.

در پژوهشی دیگر عابدی و همکاران (Abedi et al., 2013a)،

سه نوع سامانه استنتاج فازی بر روی قواعد، اگر- آن‌گاه فازی تعریف شده است:

### الف) سامانه استنتاجی فازی خالص

ساختار اصلی یک سامانه فازی خالص<sup>۱</sup> از پایگاه قواعد فازی و سامانه استنتاج فازی تشکیل شده است. پایگاه قواعد فازی مجموعه‌ای از قواعد اگر- آن‌گاه فازی را نشان می‌دهد. موتور استنتاج فازی این قواعد را به یک نگاشت از مجموعه‌های فازی در فضای ورودی به مجموعه‌های فازی خروجی بر اساس اصول منطق فازی ترکیب می‌کند ( Zadeh, 1965; Klir and Yuan, 1995).

### ب) سامانه استنتاج فازی ممدانی

سامانه استنتاج فازی ممدانی<sup>۲</sup> مشابه سامانه فازی خالص است؛ با این تفاوت که از یک فازی‌ساز<sup>۳</sup> در ورودی که متغیرهایی با مقادیر حقیقی را به یک مجموعه فازی تبدیل کرده و یک غیرفازی‌ساز<sup>۴</sup> در خروجی که یک مجموعه فازی را به یک متغیر با مقدار حقیقی تبدیل می‌کند، تشکیل شده است. این سامانه فازی معایب سامانه فازی خالص و سامانه فازی تاکاگی- سوگونو و کانگ<sup>۵</sup> را می‌پوشاند.

### پ) سامانه استنتاج فازی تاکاگی-سوگونو-کانگ

مشکل اصلی در رابطه با سامانه فازی خالص این است که ورودی‌ها و خروجی‌های آن مجموعه فازی هستند (واژه‌هایی در زبان طبیعی). در حالی که در سامانه‌های مهندسی، ورودی‌ها و خروجی‌ها متغیرهایی با مقادیر حقیقی هستند. برای حل این مشکل، سامانه فازی تاکاگی- سوگونو و کانگ نوع دیگری از سامانه‌های فازی را معرفی کرده‌اند که ورودی‌ها و خروجی‌هایی با مقادیر واقعی هستند. بخش آن‌گاه قواعد فازی از یک عبارت توصیفی با مقادیر زبانی به یک رابطه ریاضی ساده تبدیل شده است. این تغییر ترکیب قواعد فازی را ساده‌تر می‌کند. در حقیقت، سامانه فازی تاکاگی- سوگونو و کانگ یک میانگین وزنی از مقادیر بخش‌های آن‌گاه قواعد است ( Zadeh, 1965; Klir and Yuan, 1995).

1. Pure fuzzy inference system  
2. Mamdani fuzzy inference system  
3. Fuzzifier

4. DeFuzzifier  
5. Takagi Sugeno Kang FIS  
6. Knowledge-Driven

پتانسیل تهیه شد. برای ارزیابی دقت این روش، از اطلاعات ذخیره‌های مشخص شده برای تهیه نقشه پتانسیل استفاده شد که نتایج خوبی را در بر داشت.

در تحقیقی دیگر ناکس-رینسون (Knox-Robinson, 2000)، با استفاده از روش منطق فازی برداری<sup>۱</sup> به تعیین توانایی یک منطقه معدنی پرداختند. روش‌های مرسوم، توانایی معدنی منطقه را به دو طبقه با توانایی بالا و توانایی پایین طبقه‌بندی می‌کردند. آنها با این روش منطق فازی برداری مناطق با توانایی متوسط را نیز مورد بررسی قرار دادند. داده‌ها و لایه‌های اطلاعاتی در محیط GIS ترکیب شدند.

در تحقیقی دیگر عابدی و همکاران (Abedi et al., 2013b)، با استفاده از یک روش منطق فازی سلسله مراتبی به تعیین توانایی یک ذخیره مس پورفیری پرداختند. بدین منظور، چندین داده ژئوفیزیکی به دست آمده از روش‌های مغناطیس‌سنجی و الکتریکی مورد استفاده قرار گرفتند. برای وزن‌دهی به لایه‌های اطلاعاتی از سه کارشناس علوم زمین استفاده شد و با استفاده از روش منطق فازی تقسیم‌بندی بر اساس توانایی معدنی انجام گرفت. تعیین درستی و اعتبار نتایج نیز با استفاده از نتایج گمانه‌های موجود مورد بررسی قرار گرفت که نشان داد نتایج امید بخش است.

در پژوهشی دیگر، تنگستانی و مر (Tangestani and Moore, 2003)، از یک مدل منطق فازی برای تعیین توانایی مس پورفیری در منطقه شهر بابک ایران استفاده کردند. داده‌هایی که مورد استفاده قرار گرفت شامل ۱۱ نقشه آنومالی‌های ژئوفیزیکی و ژئوشیمیایی، زمین‌شناسی سنگ بستر، نزدیکی به خطواره<sup>۲</sup> شرقی-غربی، نزدیکی به توده‌های نفوذی گرانیتی و متوسط و نزدیکی به هاله آلتراسیون بود. این لایه‌های اطلاعاتی در محیط GIS ترکیب شده و تابع عضویت فازی برای هر یک از این لایه‌ها تعیین شد. شکل ۱۳، نحوه ترکیب لایه‌های مختلف این مطالعه را در یک نقشه توانایی نشان می‌دهد.

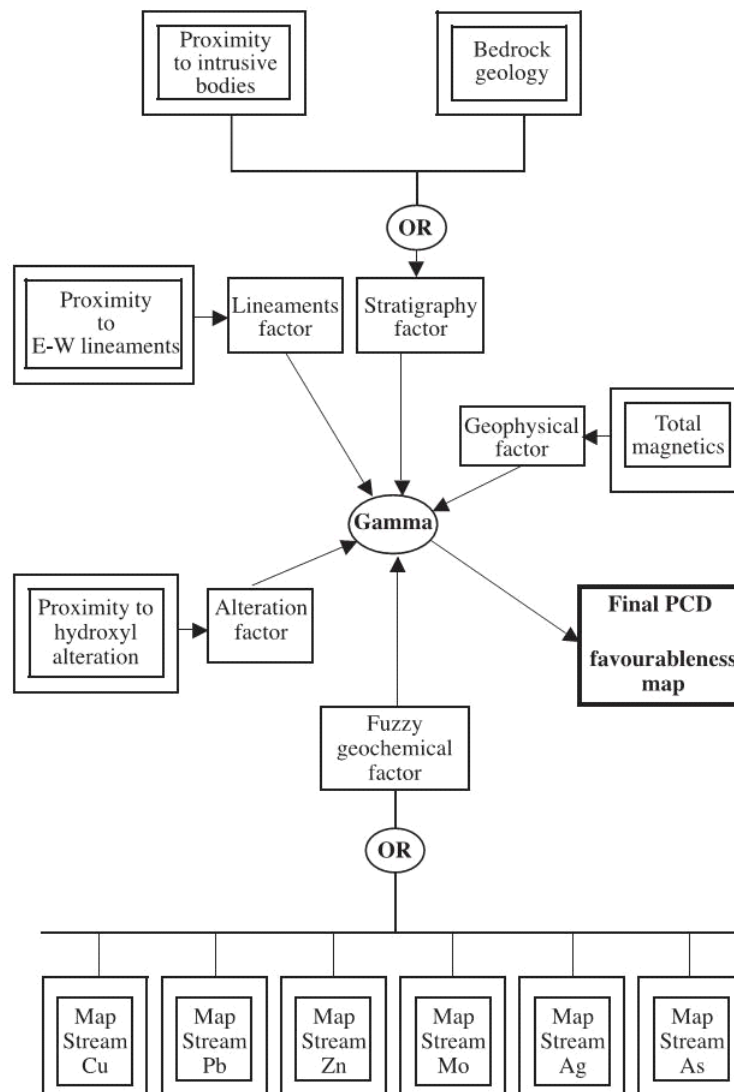
کاربرد یک روش جدید تصمیم‌گیری چند معیاره<sup>۳</sup> به نام برتری‌دهی فازی<sup>۴</sup> برای تهیه نقشه توانایی مواد معدنی برای ذخیره مس مولیدن پورفیری را نشان دادند. لایه‌های رستری مختلف شامل داده‌های مربوط به زمین‌شناسی، ژئوفیزیک و داده‌های ژئوشیمیایی برای نقشه پتانسیل معدنی ترکیب شدند. در یک نمونه مورد بررسی، ۱۳ لایه داده مربوط به ذخیره مس نوچون واقع در استان کرمان ایران برای اکتشاف منطقه مورد نظر استفاده شد. خروجی‌ها با استفاده از ۲۱ گمانه حفر شده در این منطقه مورد بررسی قرار گرفتند. مقایسه نقشه خروجی توانایی معدنی با غلظت مس و مولیدن مشاهده شده در گمانه‌ها، نشان می‌داد که تصمیم‌گیری چند معیاره برتری‌دهی فازی ابرازی مفید برای نقشه توانایی معدنی است. روش ارائه شده کارآیی بالایی برای نقشه توانایی معدنی، در نتیجه کاهش هزینه‌های حفاری اکتشافی در منطقه مورد بررسی را نشان داد.

در تحقیقی دیگر زوو و همکاران (Zuo et al., 2009)، با استفاده از ترکیب روش‌های منطق فازی جامع چند لایه<sup>۵</sup> و آنالیز نسبت فازی نامتقارن<sup>۶</sup> به بررسی یک توانایی مس پورفیری پرداختند. در این بررسی، اطلاعات باینری در دو لایه شامل سنگ معدنی مطلوب، سنگ نفوذی، گسل‌ها و آنومالی‌های ژئوشیمیایی بر اساس مدل ذخیره مس پورفیری تعیین شده و توسط آنالیز نسبت فازی نامتقارن، درجه‌بندی شدند. اهداف اکتشافی با مقادیر تابع عضویت فازی بزرگتر از ۰/۸ به عنوان ذخیره و با مقادیر کوچکتر از ۰/۳۶ به عنوان اهداف ریسک‌پذیر شناخته شدند.

در پژوهشی دیگر نجفی و همکاران (Najafi et al., 2014)، روش سلسله مراتبی فازی<sup>۷</sup> و GIS را برای نقشه توانایی ذخیره مس طلای معدن طاهرآباد در شرق ایران استفاده کردند. داده‌های ورودی آنها لایه‌هایی شامل اطلاعات زمین‌شناسی، ژئوفیزیکی و ژئوشیمیایی بود. لایه‌ها ابتدا با روش سلسله مراتبی وزن‌دهی شدند و سپس با روش منطق فازی و ادغام آنها، نقشه

1. multi-criteria decision making (MCDM)  
2. Fuzzy outranking approach  
3. multilevel fuzzy comprehensive evaluation  
4. asymmetric fuzzy relation analysis

5. fuzzy analytical hierarchy process (AHP)  
6. Vectorial fuzzy logic  
7. Lineament



شکل ۱۳. ترکیب لایه‌های مختلف در یک نقشه توانایی (Tangestani and Moore, 2003)

Fig. 13. Summarising evidence maps at the final favourability map (Tangestani and Moore, 2003)

روش‌های ترکیبی<sup>۱</sup> در هوش محاسباتی  
روش عصبی-فازی و کاربرد آنها در اکتشاف منابع معدنی  
روش عصبی-فازی

Sarıdemir, 2008). مجموعه‌های فازی، توابع عضویت، عملگرهای منطقی و قوانین اگر-آن‌گاه مؤلفه‌های فرآیند سامانه استنتاج فازی هستند.


سامانه استنتاج فازی ابزاری برای فرمول‌بندی نگاشت یک ورودی به یک خروجی است. چنین فرآیندی به وسیله منطق فازی و ابزارهای آن انجام می‌شود. منطق فازی و به‌طور خاص سامانه‌های استنتاج فازی در سال‌های اخیر کاربردهای فراوانی در زمینه‌های مختلف علوم و مهندسی داشته است (Topçu and



آموزشی تطبیقی شبکه‌های عصبی مصنوعی سود می‌برد و معمولاً به اختصار ANFIS<sup>۲</sup> نامیده می‌شود. با استفاده از مجموعه‌ای از داده‌های ورودی و خروجی، ANFIS قادر است سامانه فازی بنا کند که مؤلفه‌های توابع عضویت ورودی و خروجی آن با استفاده از یک الگوریتم انتشار برگشتی یا ترکیبی از الگوریتم انتشار برگشتی و روش حداقل مربعات<sup>۳</sup> به خوبی تنظیم شوند که به این علت این سامانه تطبیقی نامیده می‌شود (Fattahi et al., 2013c).

شکل ۱۴، ساختار ANFIS را که شامل دو ورودی، چهار قانون و یک خروجی در مدل فازی سوگنو است، نشان می‌دهد. برای سادگی فرض می‌شود که در این مدل به ازای هر ورودی دو تابع عضویت وجود دارد.

ارزشی یا تصمیمی وابسته به خروجی نگاشت می‌کند. دو نوع سامانه‌های استنتاج فازی عبارتند از: نوع ممدانی و اصلیان (Mamdani and Assilian, 1975) و نوع سوگنو (Sugeno, 1985). این دو نوع سامانه شباهت‌های بسیاری با هم دارند. دو بخش اصلی فرآیند فازی که شامل فازی‌سازی ورودی‌ها و اعمال عملگرهای فازی است در این دو نوع سامانه کاملاً مشابه هستند و تنها تفاوت اصلی بین آنها در این است که توابع عضویت خروجی در سامانه سوگنو به صورت خطی هستند. از آنجا که سامانه نوع سوگنو کارآتر از سامانه نوع ممدانی است؛ لذا این قابلیت را دارد که در ایجاد مدل‌های فازی، در آن از روش‌های تطبیقی<sup>۱</sup> استفاده شود. بدین ترتیب مدل‌های تطبیقی فازی می‌توانند ایجاد شوند. سامانه استنتاج فازی از الگوریتم‌های



شکل ۱۴. (a) مدل فازی TSK مرتبه اول، (b) شماتیک ساختار ANFIS (Jang, 1993; Fattahi et al., 2013b)

**Fig. 14.** (a) The first-order of Takagi– Sugeno–Kang (TSK) fuzzy model, (b) Corresponding ANFIS architecture (Jang, 1993; Fattahi et al., 2013b)

برای مدل سوگنو، مجموعه قوانین نمونه را که با احتساب دو تابع عضویت برای هر ورودی برابر  $۲^۲=۴$  قانون اگر- آن‌گاه است، می‌توان به صورت زیر بیان کرد:

فرضیات بالا برای تسهیل شناخت و فهم ANFIS در نظر گرفته شده‌اند. بدیهی است که این ساختار ساده قابل گسترش و تعمیم به هر بعد دلخواهی است.

1. Adaptive  
 2. Adaptive neuro-fuzzy inference system  
 3. Least square method

$$\begin{aligned}
 \text{Rule 1: if } In_1 \text{ is } A_1 \text{ and } In_2 \text{ is } B_1 \text{ then } f_{11} &= p_{11}In_1 + q_{11}In_2 + r_{11} \\
 \text{Rule 2: if } In_1 \text{ is } A_1 \text{ and } In_2 \text{ is } B_2 \text{ then } f_{12} &= p_{12}In_1 + q_{12}In_2 + r_{12} \\
 \text{Rule 3: if } In_1 \text{ is } A_2 \text{ and } In_2 \text{ is } B_1 \text{ then } f_{21} &= p_{21}In_1 + q_{21}In_2 + r_{21} \\
 \text{Rule 4: if } In_1 \text{ is } A_2 \text{ and } In_2 \text{ is } B_2 \text{ then } f_{22} &= p_{22}In_1 + q_{22}In_2 + r_{22}
 \end{aligned} \quad (V)$$

$$O_{ij}^3 = \bar{W}_{ij} = \frac{W_{ij}}{\sum_{i=1}^2 \sum_{j=1}^2 W_{ij}}, \quad i, j = 1, 2 \quad (12)$$

که  $\bar{W}_{ij}$  وزن‌های نرمال شده لایه سوم هستند.

**لایه ۴:** هر گره در این لایه یک گره تطبیقی است و خروجی‌های آن به سادگی از ضرب وزن متناظر لایه سوم در یک چند جمله‌ای مرتبه اول که همان تابع عضویت خروجی است به دست می‌آید. بنابراین خروجی‌های این لایه به صورت زیر داده می‌شوند:

$$(13)$$

$$O_{ij}^4 = \bar{W}_{ij} f_{ij} = \bar{W}_{ij} (p_{ij}In_1 + q_{ij}In_2 + r_{ij}), \quad i, j = 1, 2$$

**لایه ۵:** تک گره موجود در این لایه یک گره ثابت است که با نماد  $\Sigma$  نشان داده می‌شود. در این لایه خروجی نهایی از جمع خروجی‌های لایه چهارم تعیین می‌شود یعنی:

$$(14)$$

$$\begin{aligned}
 Out = O^5 &= \sum_{i=1}^2 \sum_{j=1}^2 \bar{W}_{ij} f_{ij} = \sum_{i=1}^2 \sum_{j=1}^2 \bar{W}_{ij} (p_{ij}In_1 + q_{ij}In_2 + r_{ij}) \\
 &= \sum_{i=1}^2 \sum_{j=1}^2 [(\bar{W}_{ij} p_{ij})In_1 + (\bar{W}_{ij} q_{ij})In_2 + (\bar{W}_{ij} r_{ij})]
 \end{aligned}$$

که خروجی نهایی  $Out$  ترکیبی خطی از مؤلفه‌های توابع عضویت خروجی است. اگر مؤلفه‌های توابع عضویت ورودی ثابت فرض شوند. جزئیات بیشتر و اصول ریاضی الگوریتم آموزشی ترکیبی در مرجع مربوط به انفیس نوشته آقای جانگ (Jang, 1993) آمده است.

### کاربرد روش عصبی - فازی در اکتشاف منابع معدنی

در تحقیقی، پوروال و همکاران (Porwal et al., 2004)، مدلی بر اساس سامانه استنتاج عصبی - فازی تطبیقی را برای تعیین توانایی فلزات پایه در منطقه آروالی هندوستان، به کار گرفتند. مجموعه داده آنها لایه‌های چینه - سنگ شناسی، نقشه

که  $A_i$  و  $B_j$  ( $i, j = 1, 2$ ) به ترتیب نمادهایی برای توابع عضویت دو ورودی  $In_1$  و  $In_2$  هستند. همچنین  $p_{ij}$ ،  $q_{ij}$  و  $r_{ij}$  بیانگر مؤلفه‌های توابع عضویت خروجی هستند که از مرتبه اول نیز هست.

چنانچه در شکل ۱۴ نشان داده شده است، ساختار نمونه ANFIS شامل ۵ لایه است که هر لایه دارای وظیفه خاصی است که به صورت زیر بیان می‌شوند:

**لایه ۱:** در این لایه همه گره‌ها، گره‌های تطبیقی هستند. در این لایه مقادیر توابع عضویت به ازای ورودی‌ها محاسبه می‌شوند؛

بنابراین خروجی‌های این لایه عبارتند از:

$$O_{A_i}^1 = \mu_{A_i}(In_1), \quad i = 1, 2 \quad (8)$$

$$O_{B_j}^1 = \mu_{B_j}(In_2), \quad j = 1, 2$$

که  $\mu_{A_i}$  و  $\mu_{B_j}$  توابع عضویت مربوط به ورودی هستند که در این مدل از شکل کلی توابع زنگوله‌ای شکل تعمیم یافته که به صورت زیر تعریف می‌شوند، استفاده شده است:

$$\mu_{A_i}(In_1, a_i, b_i, c_i) = \frac{1}{1 + \left| \frac{In_1 - c_i}{a_i} \right|^{2b_i}}, \quad i = 1, 2 \quad (9)$$

$$\mu_{B_j}(In_2, a_j, b_j, c_j) = \frac{1}{1 + \left| \frac{In_2 - c_j}{a_j} \right|^{2b_j}}, \quad j = 1, 2 \quad (10)$$

**لایه ۲:** در این لایه گره‌ها با علامت  $\Pi$  نشان داده می‌شوند و بیانگر انجام ضرب ساده هستند. خروجی‌های این لایه به صورت زیر بیان می‌شوند:

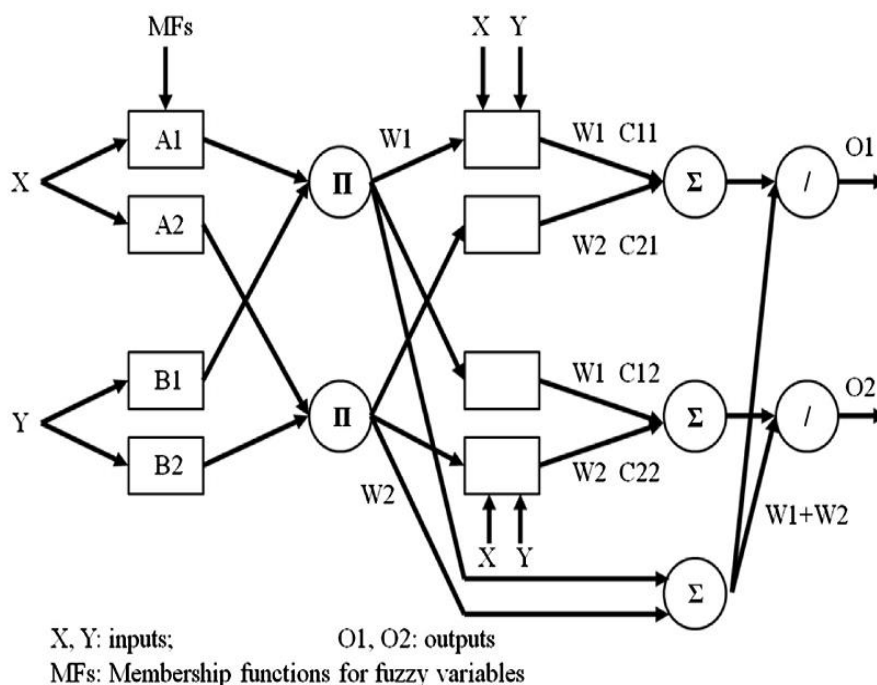
$$O_{ij}^2 = W_{ij} = \mu_{A_i}(In_1) \mu_{B_j}(In_2), \quad i, j = 1, 2 \quad (11)$$

که  $W_{ij}$  وزن‌های لایه دوم هستند.

**لایه ۳:** گره‌ها در این لایه با علامت  $N$  نشان داده می‌شوند و بیانگر انجام عمل نرمالیزه کردن در شبکه هستند. خروجی‌های این لایه به صورت زیر بیان می‌شوند:

اضطرابی<sup>۱</sup> (ترکیب دو روش، شبکه عصبی مصنوعی و منطق فازی) را برای تخمین عیار معرفی کردند. ترکیب این دو روش هوش مصنوعی از طریق قدرت کلامی و عددی سامانه‌های هوشمند به دست می‌آید. شکل ۱۵ ساختار مدل به کار رفته در این بررسی را نشان می‌دهد. برای بهبود کارایی این سامانه، الگوریتم ژنتیک به عنوان روشی شناخته شده برای حل مسائل بهینه‌سازی پیچیده، برای بهینه‌سازی مؤلفه‌های شبکه از جمله میزان یادگیری، حرکت شبکه و تعداد توابع عضویت<sup>۲</sup> برای هر ورودی، به کار گرفته شد. مقایسه این روش‌ها (شبکه عصبی مصنوعی، سامانه تطبیقی استنتاج عصبی-فازی) با روش جدید نیز از طریق بررسی موردی در معدن مس سونگون، واقع در آذربایجان شرقی ایران انجام شد. نتایج نشان داد که روش جدید می‌تواند جایگزینی دقیق، سریعتر و به جای روش‌های وقت گیر موجود برای تخمین عیار باشد. بنابراین، برای تخمین عیار در مسائل مشابه، استفاده آن پیشنهاد شد.

ساختاری و حساسیت مغناطیسی منطقه بودند که در GIS ترکیب شدند. ۵۴ نقطه مشخص دارای ذخیره معلوم نیز برای به دست آوردن دقت مدل استفاده شد که مدل آنها در نهایت ۹۶ درصد ذخایر معلوم را مشخص کرد. در تحقیقی دیگر توتمز (Tutmez, 2009)، مدلی عصبی-فازی را برای تخمین مؤلفه‌های ذخیره معدنی به کار برد. مدل او بر این اساس بود که خوشه‌بندی اولیه توسط سامانه فازی صورت می‌گرفت و مقادیر آن به عنوان ورودی به شبکه عصبی داده می‌شد. او برای درستی سنجی مدل خود از داده‌های دو منطقه استفاده کرد و سپس برای کار مقایسه‌ای، تخمین مؤلفه‌های ذخیره را با روش‌های سنتی مانند کریجینگ و وزن‌دهی فاصله معکوس نیز انجام داد. نتایج به دست آمده، برتری مدل ساخته شده را به روش‌های سنتی نشان داد. در پژوهشی دیگر، طهماسبی و هزارخانی (Tahmasebi and Hezarkhani, 2012)، سیستم استنتاج عصبی-فازی



شکل ۱۵. ساختار مدل CANFIS به کار گرفته شده (Tahmasebi and Hezarkhani, 2012b)

Fig. 15. CANFIS architecture (Tahmasebi and Hezarkhani, 2012b)

1. Coactive Neuro-Fuzzy Inference System(CANFIS)  
2. membership functions

شبکه عصبی مصنوعی برای تعیین توانایی معدنی ارائه کردند. روش آنها بدین صورت بود که برای تعیین مؤلفه‌های مدل شبکه عصبی مصنوعی از جمله تعداد ورودی‌ها، تعداد نرون‌ها و لایه‌های پنهان، سرعت حرکت و یادگیری، از الگوریتم ژنتیک استفاده کردند. برای مقایسه کارآیی روش جدید، آنها نقشه پتانسیل را با مدل شبکه عصبی مصنوعی مرسوم (تعیین مؤلفه‌های مدل با آزمون و خطا) و منطق فازی نیز به دست آوردند. مجموعه داده آنها شامل موقعیت نقاط نمونه برداری و درصد آهن بود که موقعیت به عنوان ورودی و درصد آهن به عنوان خروجی مدل در نظر گرفته شد. نتایج حاصل کارآیی بهتر روش جدید را تأیید کرد.

در پژوهشی دیگر چاترجی و همکاران (Chatterjee et al., 2008)، از یک مدل شبکه عصبی مصنوعی و الگوریتم ژنتیک برای تخمین عیار در یک معدن سنگ آهک استفاده کردند. داده‌های مورد نیاز از ۲۱ گمانه به دست آمد. داده‌ها شامل چهار مشخصه مقدار آهک، اکسید آهن، سیلیس و مقدار کل کربن بود. هشت نوع لیتولوژی متفاوت نیز در منطقه در نظر گرفته شد. موقعیت فضایی و نیز لیتولوژی به عنوان ورودی مدل و ویژگی‌های سنگ معدن به عنوان خروجی مدل در نظر گرفته شدند. برای چهار مشخصه سنگ معدنی، چهار مدل متفاوت در نظر گرفته شد. مؤلفه‌های مدل با استفاده از الگوریتم ژنتیک تعیین شده و نقشه تخمین عیار ماده معدنی تهیه شد.

در تحقیقی دیگر، لی و همکاران (Li et al., 2010b)، با استفاده از روش رگرسیون بردار پشتیبان<sup>۳</sup> و الگوریتم بهینه‌سازی ازدحام ذرات<sup>۴</sup>، به تخمین عیار ماده معدنی پرداختند. مجموعه داده آنها داده‌های به دست آمده از یک ذخیره مس پورفیری بود. منطقه مورد نظر به بلوک‌هایی تقسیم و عیار نقاط اطراف هر بلوک به عنوان ورودی به مدل و عیار نقطه مرکزی به عنوان خروجی در نظر گرفته شد. مؤلفه‌های مدل با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات، به دست آمد. روش ارائه شده سرعت

در تحقیقی دیگر ضیایی و همکاران (Ziaii et al., 2007)، با استفاده ترکیب مدل شبکه عصبی مصنوعی پس انتشار و منطقه‌بندی ژئوشیمیایی عمودی به جداسازی کانسنگ پنهان از منطقه پراکنده کانی<sup>۱</sup>، پرداختند. مدل پیشنهادی ادغام بهینه منطقه‌بندی مرسوم و مدل‌های عصبی مصنوعی - فازی بود.

مجموعه داده آنها اطلاعات ژئوشیمیایی، زمین‌شناسی و سنجش از راه دور بود. با مطالعه بر روی روش‌های سنتی، مانند وزن شواهد و روش‌های آماری مشخص شد که این روش‌ها نمی‌تواند به خوبی هدف پژوهش را برآورده کنند. با نتایج به دست آمده از مدل پیشنهادی و حفاری اکتشافی در منطقه و وجود کانسارهای مس پورفیری، کارآیی این مدل تأیید شد.

در تحقیقی دیگر ضیایی و همکاران (Ziaii et al., 2012)، روشی عصبی - فازی بر پایه الگوریتم ژنتیک برای شناسایی آنومالی‌های ژئوشیمیایی با استفاده از سامانه استنتاج فازی تاکاگی، سوگو و کانگ در یک شبکه عصبی مصنوعی تطبیقی پنج لایه پیشخور استفاده کردند.

### کاربرد روش‌های ترکیبی هوش محاسباتی

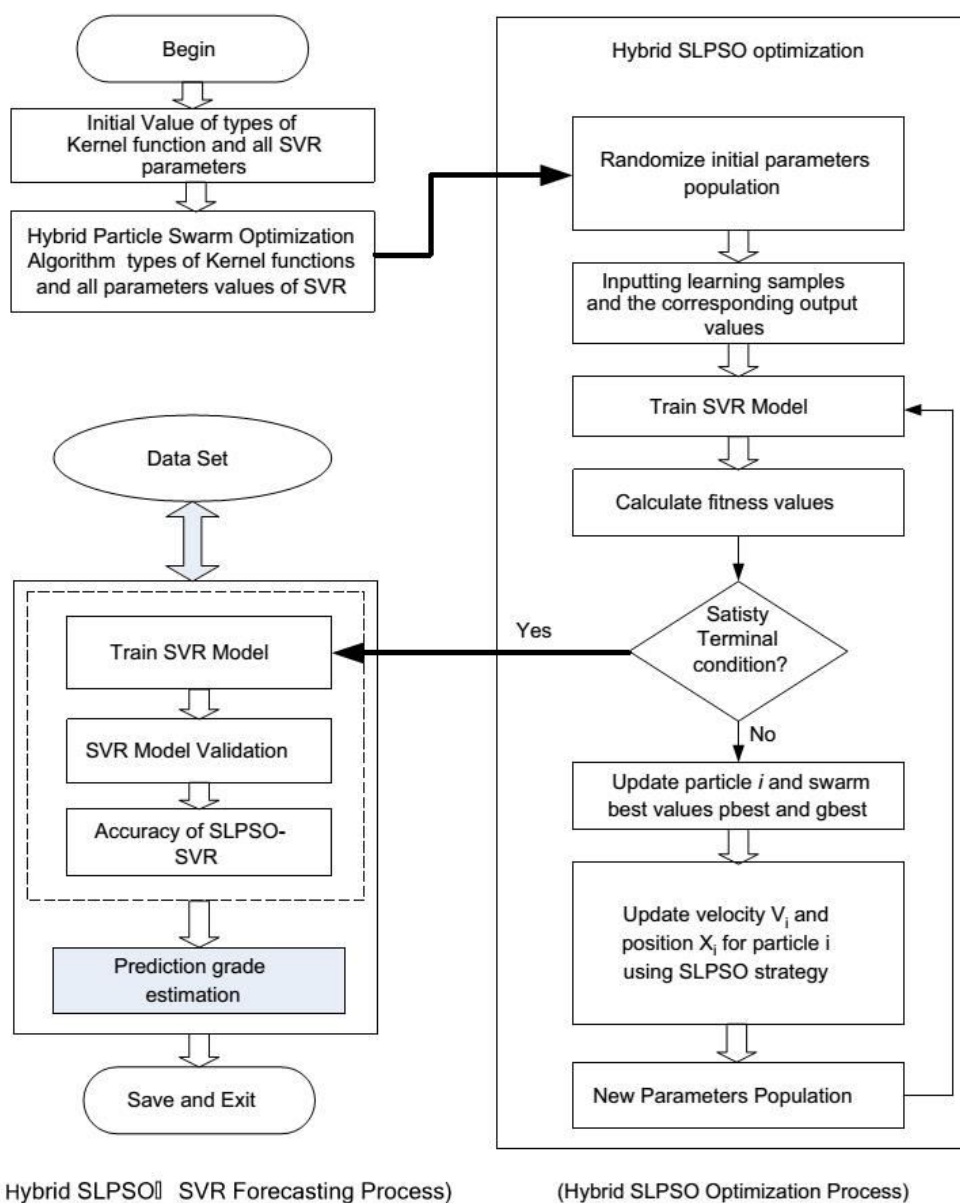
در تحقیقی محمودآبادی و همکاران (Mahmoudabadi et al., 2009)، برای تخمین عیار آهن در معدن گل گهر از مدل شبکه عصبی مصنوعی استفاده کردند. به دلیل کم بودن داده‌ها، آموزش مدل با استفاده از ترکیب الگوریتم ژنتیک و لونبرگ - مارکوارت<sup>۲</sup> انجام شد. داده‌های ورودی شامل مختصات مکانی مغزه گرفته شده و داده خروجی، عیار آهن بود. برای مقایسه با روش‌های دیگر، با استفاده از همین داده‌ها، عیار آهن با پرسپترون چند لایه و نیز روش کریجینگ به دست آمد. نتایج به دست آمده، برتری روش پیشنهاد شده را به خصوص با کاهش تعداد داده‌ها نشان داد.

در پژوهشی دیگر طهماسبی و هزارخانی (Tahmasebi and Hezarkhani, 2010)، روشی جدید برای بهینه‌سازی مدل

1. Zone Dispersed Mineralization (ZDM)  
2. Levenberg-Marquardt (LM)  
3. Support Vector Regression (SVR)  
4. Particle Swarm Optimization (PSO)

مدل از الگوریتم خود انتخاب ازدحام ذرات استفاده کرده‌اند (شکل ۱۶) و همچنین از چیدمان‌های مختلفی در بلوک‌های انتخابی بهره گرفتند. روش ارائه شده آنها نسبت به روش بررسی شده در پژوهش سال ۲۰۱۰ بهبود مناسبی یافت.

و عملکرد مطلوبی را نشان داد. در تحقیقی دیگر لی و همکاران (Li et al., 2013)، با روش رگرسیون بردار ماشین پشتیبان به تخمین عیار ماده معدنی پرداختند. آنها روش خود را نسبت به بررسی پیشین در سال ۲۰۱۰ بدین صورت ارتقا دادند که برای بهینه‌سازی مؤلفه‌های



شکل ۱۶. فرآیند بهینه‌سازی در ترکیب رگرسیون بردار ماشین پشتیبان و الگوریتم ازدحام ذرات (Li et al., 2013)

Fig. 16. Optimization process of hybrid SLPSO-SVR (Li et al., 2013)

روش‌ها مانند سایر روش‌ها، به شکل یک ابزار نگریسته می‌شود و میزان کارایی آن بسته به چگونگی به‌کارگیری آنهاست. در مسائلی که تعداد داده‌های مناسبی در دسترس است، با انتخاب ورودی و خروجی‌های مناسب برای آموزش مدل در محدوده مکانی نمونه‌ها، می‌توان به مدل‌سازی محدوده مورد نظر پرداخت. روش‌های پیشرفته هوش محاسباتی برای مسائل مختلف با یکدیگر ترکیب می‌شوند و با مقایسه نتایج آنها می‌توان روش بهینه را انتخاب کرد. نمونه‌های شرح داده شده در این مقاله، تنها بخشی از کاربرد روش‌های پیشرفته هوش محاسباتی در اکتشاف منابع معدنی را در سال‌های اخیر نشان می‌دهد. امروزه شاهد پیشرفت سریع و کارآمد این روش‌ها هستیم که دریچه نوینی را بر روی اکتشاف منابع معدنی و سایر علوم گشوده‌اند. امید است که پژوهشگران کشورمان به خصوص محققان حوزه علوم زمین، همپای رشته‌های دیگر، کاربرد این روش‌ها را در علوم زمین ارتقا بخشند.

در تحقیقی دیگر رحمان و همکاران ( Rahman et al., 2013)، روشی جدید مبتنی بر الگوریتم ژنتیک برای شناسایی حوزه‌های مواد معدنی در زیرزمین معرفی کردند. مجموعه داده‌ها با انجام تجزیه و تحلیل ژئوشیمیایی گمانه‌ها از یک معدن طلا در غرب استرالیا استخراج شد. نتایج تجربی نشان داد که روش الگوریتم ژنتیک می‌تواند شناسایی حوزه‌های مواد معدنی را با دقت بالایی انجام دهد.

### نتیجه‌گیری

هدف این تحقیق، مروری بر کاربرد مواردی از روش‌های پیشرفته هوش محاسباتی در اکتشاف منابع معدنی بود. استفاده از این روش‌ها در پروژه‌های اکتشافی از کارایی و فواید بسیاری برخوردار است. ذکر این نکته ضروری است که روش‌های مدل‌سازی به‌عنوان روش کمکی در کلیه مراحل تلفیق مکانی داده‌ها به کار گرفته می‌شوند؛ اگر چه در نهایت، نظر کارشناسی است که نتیجه قطعی را مشخص می‌سازد. به‌طور کلی به این

### References

- Abbaszadeh, M., Hezarkhani, A. and Soltani-Mohammadi, S., 2013. An SVM-based machine learning method for the separation of alteration zones in Sungun porphyry copper deposit. *Chemie der Erde-Geochemistry*, 73(4): 545-554.
- Abedi, M. and Norouzi, G.H., 2012. Integration of various geophysical data with geological and geochemical data to determine additional drilling for copper exploration. *Journal of Applied Geophysics*, 83(1): 35-45.
- Abedi, M., Norouzi, G.H. and Bahroudi, A., 2012. Support vector machine for multi-classification of mineral prospectivity areas. *Computers and Geosciences*, 46(1): 272-283.
- Abedi, M., Norouzi, G.H. and Fathianpour, N., 2013a. Fuzzy outranking approach: a knowledge-driven method for mineral prospectivity mapping. *International Journal of Applied Earth Observation and Geoinformation*, 21(1): 556-567.
- Abedi, M., Torabi, S. and Norouzi, G., 2013b. Application of fuzzy AHP method to integrate geophysical data in a prospect scale, a case study: Seridune copper deposit. *Bollettino di Geofisica Teorica ed Applicata*, 54(2): 145-164.
- Abreu, G.L. and Ribeiro, J.F., 2003. On-line control of a flexible beam using adaptive fuzzy controller and piezoelectric actuators. *Sba: Controle e Automação Sociedade Brasileira de Automatica*, 14(4): 377-383.
- Acharya, C., Mohanty, S., Sukla, L. and Misra, V., 2006. Prediction of sulphur removal with *Acidithiobacillus* sp. using artificial neural networks. *Ecological Modelling*, 190(1): 223-230.
- Agterberg, F. and Bonham-Carter, G., 1999. Logistic regression and weights of evidence modeling in mineral exploration. *Proceedings of the 28th International Symposium on Applications of Computer in the Mineral Industry (APCOM)*, Colorado School of Mines, Colorado, USA.
- Ancona, N., Cicirelli, G., Stella, E. and Distanti, A., 2003. Ball detection in static images with

- Support Vector Machines for classification. *Image and Vision Computing*, 21(8): 675-692.
- Basheer, I. and Hajmeer, M., 2000. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1): 3-31.
- Bazdar, H., Fattahi, H. and Ghadimi, F., 2015a. Hybrid ANN with Invasive Weed Optimization Algorithm, a New Technique for Prediction of Gold and Silver in Zarshuran Gold Deposit, Iran. M.Sc. Thesis, Arak University of Technology, Arak, Iran, 120 pp.
- Bazdar, H., Fattahi, H. and Ghadimi, F., 2015b. Hybrid ANN with Invasive Weed Optimization Algorithm, a New Technique for Prediction of Gold and Silver in Zarshuran Gold Deposit, Iran. *Journal of Tethys*, 3(3): 273-286.
- Behnia, P., 2007. Application of Radial Basis Functional Link Networks to exploration for Proterozoic mineral deposits in central Iran. *Natural Resources Research*, 16(2): 147-155.
- Bougrain, L., Gonzalez, M., Bouchot, V., Cassard, D., Lips, A.L., Alexandre, F. and Stein, G., 2003. Knowledge recovery for continental-scale mineral exploration by neural networks. *Natural Resources Research*, 12(3): 173-181.
- Brown, W.M., Gedeon, T., Groves, D. and Barnes, R., 2000. Artificial neural networks: a new method for mineral prospectivity mapping. *Australian Journal of Earth Sciences*, 47(4): 757-770.
- Brown, W.M., Gedeon, T.D. and Groves, D.I., 2003. Use of noise to augment training data: a neural network method of mineral-potential mapping in regions of limited known deposit examples. *Natural Resources Research*, 12(2): 141-152.
- Cao, L.J. and Tay, F.E., 2003. Support vector machine with adaptive parameters in financial time series forecasting. *IEEE Transactions on Neural Networks*, 14(6): 1506-1518.
- Chatterjee, S. and Bandopadhyay, S., 2011. Goodnews Bay Platinum Resource Estimation Using Least Squares Support Vector Regression with Selection of Input Space Dimension and Hyperparameters. *Natural Resources Research*, 20(2): 117-129.
- Chatterjee, S., Bandopadhyay, S. and Rai, P., 2008. Genetic algorithm-based neural network learning parameter selection for ore grade evaluation of limestone deposit. *Mining Technology*, 117(4): 178-190.
- Chatterjee, S., Bhattacharjee, A., Samanta, B. and Pal, S., 2006. Ore grade estimation of a limestone deposit in India using an artificial neural network. *Applied Geographic Information System*, 2(1): 201-220.
- Chen, R.C. and Hsieh, C.H., 2006. Web page classification based on a support vector machine using a weighted vote schema. *Expert Systems with Applications*, 31(2): 427-435.
- Demuth, H. and Beale, M., 2002. Neural network toolbox for use with MATLAB. The Math Works Incorporated, USA, 840 pp.
- Doulati Ardejani, F., Rooki, R., Jodieri Shokri, B., Eslam Kish, T., Aryafar, A. and Tourani, P., 2012. Prediction of rare earth elements in neutral alkaline mine drainage from Razi Coal Mine, Golestan Province, northeast Iran, using general regression neural network. *Journal of Environmental Engineering*, 139(6): 896-907.
- Dutta, S., Bandopadhyay, S., Ganguli, R. and Misra, D., 2010. Machine learning algorithms and their application to Ore Reserve estimation of sparse and imprecise data. *Journal of Intelligent Learning Systems and Applications*, 2(02): 86-96.
- Eskandari, H., Rezaee, M. and Mohammadnia, M., 2004. Application of multiple regression and artificial neural network techniques to predict shear wave velocity from wireline log data for a carbonate reservoir South-West Iran. *Canadian Society of Exploration Geophysicists*, 29(7): 41-47.
- Fattahi, H., 2015a. Prediction of earthquake induced displacements of slopes using hybrid support vector regression with particle swarm optimization. *International Journal of Optimization in Civil Engineering*, 5(3): 267-282.
- Fattahi, H., 2015b. Prediction of slope stability state for circular failure: A hybrid support vector machine with harmony search algorithm. *International Journal of Optimization in Civil Engineering*, 5(1): 103-115.
- Fattahi, H., 2016a. Adaptive neuro fuzzy inference system based on fuzzy C-Means clustering algorithm, a technique for estimation of TBM penetration rate. *International Journal*

- of Optimization in Civil Engineering, 6(2): 159-171.
- Fattahi, H., 2016b. A hybrid support vector regression with ant colony optimization algorithm in estimation of safety factor for circular failure slope. *International Journal of Optimization in Civil Engineering*, 6(1): 63-75.
- Fattahi, H., Ebrahimi, F.M., Shojaee, S., Nekooei, K. and Mansouri, H., 2013a. Application of the hybrid harmony search with support vector machine for identification and classification of damaged zone around underground spaces. *International Journal of Optimization in Civil Engineering*, 3(2): 345-358.
- Fattahi, H., Gholami, A., Amiribakhtiar, M.S. and Moradi, S., 2015. Estimation of asphaltene precipitation from titration data: a hybrid support vector regression with harmony search. *Neural Computing and Applications*, 26(4): 789-798.
- Fattahi, H., Shojaee, S. and Ebrahimi, F.M., 2013b. Application of Adaptive Network-based Fuzzy Inference System for the Assessment of Damaged Zone Around Underground Spaces. *International Journal of Optimization in Civil Engineering*, 3(4): 673-693.
- Fattahi, H., Shojaee, S., Ebrahimi, F.M. and Mansouri, H., 2013c. Hybrid Monte Carlo simulation and ANFIS-subtractive clustering method for reliability analysis of the excavation damaged zone in underground spaces. *Computers and Geotechnics*, 54: 210-221.
- Fattahi, H., Shojaee, S., Ebrahimi, F.M. and Mansouri, H., 2013d. Using latin hypercube sampling based on the ANN-HPSOGA model for estimation of the creation probability of damaged zone around underground spaces. *International Journal of Optimization in Civil Engineering*, 3(3): 389-408.
- Fung, C.C., Iyer, V., Brown, W. and Wong, K.W., 2005. Comparing the performance of different neural networks architectures for the prediction of mineral prospectivity. *International Conference on Machine Learning and Cybernetics*, South China University of Technology, Guangzhou, China.
- Gang, R. and Zhuping, Z., 2011. Traffic safety forecasting method by particle swarm optimization and support vector machine. *Expert Systems with Applications*, 38(8): 10420-10424.
- Ghadimi, F., 2014a. Prediction of Degree of Soil Contamination Based on Support Vector Machine and K-Nearest Neighbor Methods: A Case Study in Arak, Iran. *Iranica Journal of Energy & Environment*, 5(4): 345-353.
- Ghadimi, F., 2014b. A statistical and support vector machine approach for assessing heavy metal contamination in soil, dust and rainwater from the Arak city, Iran. *International Research Journal of Applied and Basic Sciences*, 8(10): 1539-1556.
- Ghadimi, F., 2015. Prediction of heavy metals contamination in the groundwater of Arak region using artificial neural network and multiple linear regression. *Journal of Tethys*, 3(3): 203-215.
- Guo, W.W., 2010. A novel application of neural networks for instant iron-ore grade estimation. *Expert Systems with Applications*, 37(12): 8729-8735.
- Hagan, M.T., Demuth, H.B. and Beale, M.H., 2002. *Neural network design*. Campus Publishing Service, University of Colorado Bookstore, USA, 736 pp.
- Hájek, P., 1998. *Metamathematics of fuzzy logic*. Springer Science and Business Media, Berlin, Germany, 299 pp.
- Harris, D. and Pan, G., 1999. Mineral favorability mapping: a comparison of artificial neural networks, logistic regression, and discriminant analysis. *Natural Resources Research*, 8(2): 93-109.
- Harris, D., Zurcher, L., Stanley, M., Marlow, J. and Pan, G., 2003. A comparative analysis of favorability mappings by weights of evidence, probabilistic neural networks, discriminant analysis, and logistic regression. *Natural Resources Research*, 12(4): 241-255.
- Hezarkhani, A. and Williams-Jones, A.E., 1998. Controls of alteration and mineralization in the Sungun porphyry copper deposit, Iran; evidence from fluid inclusions and stable isotopes. *Economic Geology*, 93(5): 651-670.
- Hornik, K., Stinchcombe, M. and White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5): 359-366.
- Huang, C.L., Chen, M.C. and Wang, C.J., 2007. Credit scoring with a data mining approach



- based on support vector machines. *Expert Systems with Applications*, 33(4): 847-856.
- Jang, J.S.R., 1993. ANFIS: adaptive-network-based fuzzy inference system. Conference of Systems, Man and Cybernetics, Westminster Hotel, Paris, France.
- Jorjani, E., Chelgani, S.C. and Mesroghli, S., 2008. Application of artificial neural networks to predict chemical desulfurization of Tabas coal. *Fuel*, 87(12): 2727-2734.
- Journel, A.G. and Huijbregts, C.J., 1978. Mining geostatistics. Academic Press, Virginia, USA, 600 pp.
- Karimpour, M.H., Farmer, G.L., Stern, C. and Salati, E., 2011. U-Pb zircon geochronology and Sr-Nd isotopic characteristic of Late Neoproterozoic Bornaward granitoids (Taknar zone exotic block), Iran. *Iranian Journal of Crystallography and Mineralogy*, 19(1): 1-18.
- Karimpour, M.H., Stern, C. and Farmer, G., 2010. Zircon U-Pb geochronology, Sr-Nd isotope analyses, and petrogenetic study of the Dehnow diorite and Kuhsangi granodiorite (Paleo-Tethys), NE Iran. *Journal of Asian Earth Sciences*, 37(4): 384-393.
- Klir, G. and Yuan, B., 1995. Fuzzy sets and fuzzy logic. Prentice Hall, Michigan, USA, 245 pp.
- Knox-Robinson, C., 2000. Vectorial fuzzy logic: a novel technique for enhanced mineral prospectivity mapping, with reference to the orogenic gold mineralisation potential of the Kalgoorlie Terrane, Western Australia. *Australian Journal of Earth Sciences*, 47(5): 929-941.
- Koike, K., Matsuda, S., Suzuki, T. and Ohmi, M., 2002. Neural network-based estimation of principal metal contents in the Hokuroku district, Northern Japan, for exploring Kuroko-type deposits. *Natural Resources Research*, 11(2): 135-156.
- Lee, S., Oh, H.J., Heo, C.H. and Park, I., 2014. A case study for the integration of predictive mineral potential maps. *Central European Journal of Geosciences*, 6(3): 373-392.
- Leite, E.P. and de Souza Filho, C.R., 2009a. Artificial neural networks applied to mineral potential mapping for copper-gold mineralizations in the Carajás Mineral Province, Brazil. *Geophysical Prospecting*, 57(6): 1049-1065.
- Leite, E.P. and de Souza Filho, C.R., 2009b. Probabilistic neural networks applied to mineral potential mapping for platinum group elements in the Serra Leste region, Carajás Mineral Province, Brazil. *Computers and Geosciences*, 35(3): 675-687.
- Li, C., Li, J., Li, Z. and Sun, E., 2010a. SVM based ore grade valuation model construction. Sixth International Conference on Natural Computation, Yantai University, Yantai, China.
- Li, X., Xie, Y. and Guo, Q., 2010b. A new intelligent prediction method for grade estimation. 7th International Symposium on Neural Networks, Shanghai University, Shanghai, China.
- Li, X.l., Li, L.h., Zhang, B.l. and Guo, Q.j., 2013. Hybrid self-adaptive learning based particle swarm optimization and support vector regression model for grade estimation. *Neurocomputing*, 118(1): 179-190.
- Li, X.l., Xie, Y.l., Guo, Q.j. and Li, L.h., 2010c. Adaptive ore grade estimation method for the mineral deposit evaluation. *Mathematical and Computer Modelling*, 52(11): 1947-1956.
- Magalhães, L.A. and Souza Filho, C.R., 2012. Targeting of gold deposits in Amazonian exploration frontiers using knowledge-and data-driven spatial modeling of geophysical, geochemical, and geological data. *Surveys in Geophysics*, 33(2): 211-241.
- Mahmoudabadi, H., Izadi, M. and Menhaj, M.B., 2009. A hybrid method for grade estimation using genetic algorithm and neural networks. *Computational Geosciences*, 13(1): 91-101.
- Malekzadeh Shafaroudi, A. and Karimpour, M.H., 2015. Mineralogic, fluid inclusion, and sulfur isotope evidence for the genesis of Sechangi lead-zinc (-copper) deposit, Eastern Iran. *Journal of African Earth Sciences*, 107(1): 1-14.
- Malekzadeh Shafaroudi, A., Karimpour, M.H. and Stern, C., 2015. The Khopik porphyry copper prospect, Lut Block, Eastern Iran: Geology, alteration and mineralization, fluid inclusion, and oxygen isotope studies. *Ore Geology Reviews*, 65(2): 522-544.
- Mamdani, E.H. and Assilian, S., 1975. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1): 1-13.

- Mendel, J.M., 1995. Fuzzy logic systems for engineering: a tutorial. *Proceedings of the IEEE*, 83(3): 345-377.
- Misra, D., Samanta, B., Dutta, S. and Bandopadhyay, S., 2007. Evaluation of artificial neural networks and kriging for the prediction of arsenic in Alaskan bedrock-derived stream sediments using gold concentration data. *International Journal of Mining, Reclamation and Environment*, 21(4): 282-294.
- Monjezi, M. and Dehghani, H., 2008. Evaluation of effect of blasting pattern parameters on back break using neural networks. *International Journal of Rock Mechanics and Mining Sciences*, 45(8): 1446-1453.
- Najafi, A., Karimpour, M.H. and Ghaderi, M., 2014. 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*, 33(1): 142-154.
- Ng, J. and Gong, S., 2002. Composite support vector machines for detection of faces across views and pose estimation. *Image and Vision Computing*, 20(5): 359-368.
- Oh, H.J. and Lee, S., 2010. Application of artificial neural network for gold-silver deposits potential mapping: a case study of Korea. *Natural Resources Research*, 19(2): 103-124.
- Oommen, T., Misra, D., Prakash, A., Bandopadhyay, S., Naidu, S. and Kelley, J.J., 2011. Multiple Regressive Pattern Recognition Technique: An Adapted Approach for Improved Georesource Estimation. *Natural Resources Research*, 20(1): 11-24.
- Porwal, A., Carranza, E. and Hale, M., 2003a. Artificial neural networks for mineral-potential mapping: a case study from Aravalli Province, Western India. *Natural Resources Research*, 12(3): 155-171.
- Porwal, A., Carranza, E. and Hale, M., 2003b. Knowledge-driven and data-driven fuzzy models for predictive mineral potential mapping. *Natural Resources Research*, 12(1): 1-25.
- Porwal, A., Carranza, E. and Hale, M., 2004. A hybrid neuro-fuzzy model for mineral potential mapping. *Mathematical Geology*, 36(7): 803-826.
- Porwal, A., Carranza, E.J.M. and Hale, M., 2006a. Bayesian network classifiers for mineral potential mapping. *Computers and Geosciences*, 32(1): 1-16.
- Porwal, A., Carranza, E.J.M. and Hale, M., 2006b. A hybrid fuzzy weights-of-evidence model for mineral potential mapping. *Natural Resources Research*, 15(1): 1-14.
- Porwal, A., Gonzalez-Alvarez, I., Markwitz, V., McCuaig, T. and Mamuse, A., 2010a. Weights-of-evidence and logistic regression modeling of magmatic nickel sulfide prospectivity in the Yilgarn Craton, Western Australia. *Ore Geology Reviews*, 38(3): 184-196.
- Porwal, A., Yu, L. and Gessner, K., 2010b. SVM-based base-metal prospectivity modeling of the Aravalli Orogen, northwestern India. *European Geosciences Union General Assembly Conference, Austria Center, Vienna, Austria*.
- Rahman, A., Dutta, R. and Smith, D., 2013. Exploring mineral domains with genetic algorithm. *International Joint Conference on Neural Networks, Fairmont Hotel, Dallas, TX, USA*.
- Rendu, J., 1979. Kriging, logarithmic Kriging, and conditional expectation: comparison of theory with actual results. *16th Application Of Computers And Operations Research in the Mineral Industry (APCOM) Symposium, University of Arizona, Tucson, Arizona*.
- Rigol-Sanchez, J., Chica-Olmo, M. and Abarca-Hernandez, F., 2003. Artificial neural networks as a tool for mineral potential mapping with GIS. *International Journal of Remote Sensing*, 24(5): 1151-1156.
- Ross, T.J., 2009. *Fuzzy logic with engineering applications*. John Wiley and Sons, New York, USA, 606 pp.
- Samanta, B., Bandopadhyay, S. and Ganguli, R., 2002. Data segmentation and genetic algorithms for sparse data division in Nome placer gold grade estimation using neural network and geostatistics. *Exploration and Mining Geology*, 11(1-4): 69-76.
- Samanta, B., Bandopadhyay, S. and Ganguli, R., 2006. Comparative evaluation of neural network learning algorithms for ore grade

- estimation. *Mathematical Geology*, 38(2): 175-197.
- Samanta, B., Bandopadhyay, S., Ganguli, R. and Dutta, S., 2004. Sparse data division using data segmentation and Kohonen network for neural network and geostatistical ore grade modeling in Nome offshore placer deposit. *Natural Resources Research*, 13(3): 189-200.
- Savu-Krohn, C., Rantitsch, G., Auer, P., Melcher, F. and Graupner, T., 2011. Geochemical fingerprinting of coltan ores by machine learning on uneven datasets. *Natural Resources Research*, 20(3): 177-191.
- Shin, K.S., Lee, T.S. and Kim, H.j., 2005. An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(1): 127-135.
- Singer, D.A. and Kouda, R., 1996. Application of a feedforward neural network in the search for Kuroko deposits in the Hokuroku district, Japan. *Mathematical Geology*, 28(8): 1017-1023.
- Singer, D.A. and Kouda, R., 1999. A comparison of the weights-of-evidence method and probabilistic neural networks. *Natural Resources Research*, 8(4): 287-298.
- Skabar, A., 2003. Mineral potential mapping using feed-forward neural networks. *International Joint Conference on Neural Networks*, Portland State University, Portland, USA.
- Skabar, A., 2007. Mineral potential mapping using Bayesian learning for multilayer perceptrons. *Mathematical Geology*, 39(5): 439-451.
- Skabar, A.A., 2005. Mapping mineralization probabilities using multilayer perceptrons. *Natural Resources Research*, 14(2): 109-123.
- Smirnoff, A., Boisvert, E. and Paradis, S.J., 2008. Support vector machine for 3D modelling from sparse geological information of various origins. *Computers & Geosciences*, 34(2): 127-143.
- Specht, D.F., 1991. A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6): 568-576.
- Sugeno, M., 1985. *Industrial applications of fuzzy control*. North-Holland, Michigan, USA, 269 pp.
- Tahmasebi, P. and Hezarkhani, A., 2010. Comparison of optimized neural network with fuzzy logic for ore grade estimation. *Australian Journal of Basic and Applied Sciences*, 4(5): 764-772.
- Tahmasebi, P. and Hezarkhani, A., 2011. Application of a modular feedforward neural network for grade estimation. *Natural Resources Research*, 20(1): 25-32.
- Tahmasebi, P. and Hezarkhani, A., 2012. A hybrid neural networks-fuzzy logic-genetic algorithm for grade estimation. *Computers and Geosciences*, 42(1): 18-27.
- Tangestani, M. and Moore, F., 2003. Mapping porphyry copper potential with a fuzzy model, northern Shahr-e-Babak, Iran. *Australian Journal of Earth Sciences*, 50(3): 311-317.
- Topçu, İ.B. and Sarıdemir, M., 2008. Prediction of rubberized concrete properties using artificial neural network and fuzzy logic. *Construction and Building Materials*, 22(4): 532-540.
- Tutmez, B., 2009. Use of hybrid intelligent computing in mineral resources evaluation. *Applied Soft Computing*, 9(3): 1023-1028.
- Twarakavi, N.K., Misra, D. and Bandopadhyay, S., 2006. Prediction of arsenic in bedrock derived stream sediments at a gold mine site under conditions of sparse data. *Natural Resources Research*, 15(1): 15-26.
- Wang, G., Zhang, S., Yan, C., Song, Y., Sun, Y., Li, D. and Xu, F., 2011. Mineral potential targeting and resource assessment based on 3D geological modeling in Luanchuan region, China. *Computers and Geosciences*, 37(12): 1976-1988.
- Wang, Z. and ChangYu, Z., 2010. Rocks/Minerals Information Extraction from EO-1 Hyperion Data Base on SVM. *International Conference on Intelligent Computation Technology and Automation (ICICTA)*, Changsha University of Science and Technology, Changsha, China.
- Yager, R.R. and Zadeh, L.A., 2012. *An introduction to fuzzy logic applications in intelligent systems*. Springer, Michigan, USA, 356 pp.
- Yama, B. and Lineberry, G., 1999. Artificial neural network application for a predictive task in mining. *Mining Engineering*, 51(2): 59-64.
- Yu, L., Porwal, A., Holden, E.J. and Dentith, M.C., 2012. Towards automatic lithological classification from remote sensing data using support vector machines. *Computers and Geosciences*, 45(1): 229-239.

- Zadeh, L.A., 1965. Fuzzy sets. *Information and Control*, 8(3): 338-353.
- Zhang, X., Song, S., Li, J. and Wu, C., 2013. Robust LS-SVM regression for ore grade estimation in a seafloor hydrothermal sulphide deposit. *Acta Oceanologica Sinica*, 32(8): 16-25.
- Ziaii, M., Abedi, A. and Ziaei, M., 2009. Geochemical and mineralogical pattern recognition and modeling with a Bayesian approach to hydrothermal gold deposits. *Applied Geochemistry*, 24(6): 1142-1146.
- Ziaii, M., Abedi, A. and Ziaii, M., 2007. Prediction of hidden ore bodies by new integrated computational model in marginal Lut region in east of Iran. *Fifth Decennial International Conference on Mineral Exploration*, Metro Toronto Convention Centre, Toronto, Canada.
- Ziaii, M., Ardejani, F.D., Ziaei, M. and Soleymani, A.A., 2012. Neuro-fuzzy modeling based genetic algorithms for identification of geochemical anomalies in mining geochemistry. *Applied Geochemistry*, 27(3): 663-676.
- Zuo, R. and Carranza, E.J.M., 2011. Support vector machine: A tool for mapping mineral prospectivity. *Computers & Geosciences*, 37(12): 1967-1975.
- Zuo, R., Cheng, Q. and Agterberg, F.P., 2009. Application of a hybrid method combining multilevel fuzzy comprehensive evaluation with asymmetric fuzzy relation analysis to mapping prospectivity. *Ore Geology Reviews*, 35(1): 101-108.



## Review

# A comprehensive review of the use of computational intelligence methods in mineral exploration

Habibollah Bazdar, Hadi Fattahi\* and Feridon Ghadimi

*Mining Engineering Faculty, Arak University of Technology, Arak, Iran*

Submitted: July 10, 2015

Accepted: Mar. 12, 2016

**Keywords:** *Computational intelligence methods, exploration, minerals, modeling*

## Introduction

Mineral exploration is a process by which it is decided whether or not continuing explorations at the end of each stage  $t$  will be cost-effective or not. This decision is dependent upon many factors including technical factors, economic, social and other related factors. All new methods used in mineral exploration are meant to make this decision making more simplified. In recent years, advanced computational intelligence methods for modeling along with many other disciplines of science, including the science of mineral exploration have been used. Although the results of the application of these methods show a good performance, it is essential to determine the mineral potential in terms of geology, mineralogy, petrology and other factors for a final decision. The purpose of this paper is to provide a comprehensive set of mineral exploration research and different applications of computational intelligence techniques in this respect during the last decades.

## Materials and methods

*Artificial neural network and its application in mineral exploration*

Artificial neural network (ANN) is a series of communications between the units or nodes that try to function like neurons of the human brain

(Jorjani et al., 2008). The network processing capability of communication between the units and the weights connection originates or comes from learning or are predetermined (Monjezi and Dehghani, 2008). The ANN method has been applied in different branches of mining exploration in the last decades (Brown et al., 2000; Leite and de Souza Filho, 2009; Porwal et al., 2003).

## Support vector machines (SVM) and its application in mineral exploration

SVM uses a set of examples with known class of information to build a linear hyperplane separating samples of different classes. This initial dataset is known as a training set and every sample within it is characterized by features upon which the classification is based (Smirnov et al., 2008). The SVM classifier is a new method that has been applied in mining exploration in recent years, for example for separating alterations in initial stages of mining exploration (Abbaszadeh et al., 2013).

## Neuro-fuzzy methods and its application in mineral exploration

The base of fuzzy logic is to make flexible borders between different samples. By applying this method with other methods, we can improve their performance. The adaptive neuro-fuzzy inference system (ANFIS) is one of the useful approaches in this branch of intelligent methods in

mining exploration. For example, we can note the use of this approach in mineral mapping (Porwal et al., 2004).

### **Hybrid computational intelligence methods and its application in mineral exploration**

In order to improve the performance of intelligence methods, often a hybrid form of these methods and optimization algorithms is a fit option. For example, Genetic Algorithm (GA), Ant Colony Optimization and Particle Swarm Optimization (PSO) have been applied with ANN and SVM in research studies. For example, (Chatterjee et al., 2008) applied a genetic algorithm-based ANN for ore grade estimation.

### **Conclusions**

Earth sciences in general and more specifically mineral explorations have always been a part of science that encompasses all the factors involved due to their complexity and the factors that influence them thereby making the solution very difficult or almost impossible to solve. Because of the difficulty of accurate measurement parameters and boundaries, in recent years, researchers have been trying to use modeling in order to simplify natural disasters for better evaluation. One of the models that has received a lot of attention in recent years is modeling with of computational intelligent methods. The appropriate results show the usefulness of these methods.

### **References**

- Abbaszadeh, M., Hezarkhani, A. and Soltani-Mohammadi, S., 2013. An SVM-based machine learning method for the separation of alteration zones in Sungun porphyry copper deposit. *Chemie der Erde-Geochemistry*, 73(4): 545-554.
- Brown, W.M., Gedeon, T., Groves, D. and Barnes, R., 2000. Artificial neural networks: a new method for mineral prospectivity mapping. *Australian Journal of Earth Sciences*, 47(4): 757-770.
- Chatterjee, S., Bandopadhyay, S. and Rai, P., 2008. Genetic algorithm-based neural network learning parameter selection for ore grade evaluation of limestone deposit. *Mining Technology*, 117(4): 178-190.
- Jorjani, E., Chelgani, S.C. and Mesroghli, S., 2008. Application of artificial neural networks to predict chemical desulfurization of Tabas coal. *Fuel*, 87(12): 2727-2734.
- Leite, E.P. and de Souza Filho, C.R., 2009. Artificial neural networks applied to mineral potential mapping for copper-gold mineralizations in the Carajás Mineral Province, Brazil. *Geophysical Prospecting*, 57(6): 1049-1065.
- Monjezi, M. and Dehghani, H., 2008. Evaluation of effect of blasting pattern parameters on back break using neural networks. *International Journal of Rock Mechanics and Mining Sciences*, 45(8): 1446-1453.
- Porwal, A., Carranza, E. and Hale, M., 2003. Artificial neural networks for mineral-potential mapping: a case study from Aravalli Province, Western India. *Natural Resources Research*, 12(3): 155-171.
- Porwal, A., Carranza, E. and Hale, M., 2004. A hybrid neuro-fuzzy model for mineral potential mapping. *Mathematical Geology*, 36(7): 803-826.
- Smirnoff, A., Boisvert, E. and Paradis, S.J., 2008. Support vector machine for 3D modelling from sparse geological information of various origins. *Computers & Geosciences*, 34(2): 127-143.