

مقایسه کار آیی شبکه‌های عصبی MLP، RBF، PNN و GRNN در مطالعات اکتشافی ذخایر مسی پورفیری به منظور تعیین نقاط حفاری در GIS

متین فروتن^۱، علی منصوریان^۱، مژگان زارعی نژاد^۲ و محمود رضا صاحبی^۱

^۱گروه GIS، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران.

^۲گروه GIS، سازمان زمین‌شناسی و اکتشافات معدنی کشور، تهران، ایران.

تاریخ دریافت: ۱۳۸۸/۰۵/۲۸ تاریخ پذیرش: ۱۳۸۸/۱۲/۱۹

چکیده

حفاری در اکتشاف معادن، فرایندی پرهزینه و زمان‌بر بوده و با مشکلات بسیاری همراه است. از این رو تعیین نقاط حفاری در مطالعات تفصیلی اکتشاف ذخایر معدنی اهمیت ویژه‌ای دارد. تعیین نقاط بهینه حفاری به منظور کاهش هزینه و ریسک فرایند حفاری از راه در نظر گرفتن کلیه شرایط پیچیده حاکم بر شکل‌گیری ذخایر معدنی و تلفیق فاکتورهای مؤثر بر کانی‌سازی انجام می‌شود. با توجه به اینکه روش‌های متداول تلفیق فاکتورهای کانی‌سازی مانند روش‌های همپوشانی و همپوشانی شاخص، بر دانش کارشناسی و داده‌های موجود استوار است، دقت این روش‌ها با افزایش حجم اطلاعات پردازش شده و وجود نوفه (Noise) در داده‌ها به نحو قابل توجهی کاهش می‌یابد. بنابراین برای حل مشکلات موجود، به ابزارهای قوی در پردازش حجم عظیم اطلاعات و با انعطاف‌پذیری زیاد نیاز است. شبکه‌های عصبی با ساختار موازی و انعطاف‌پذیر، توانایی بالایی در مدیریت حجم عظیم اطلاعات و استخراج الگوها از میان داده‌های نوفه‌دار دارند. از آنجا که این شبکه‌ها برحسب نوع توابع عملکرد ساختارهای بسیار متنوعی دارند، لازم است کارآیی هریک از این ساختارها در تعیین نقاط بهینه حفاری بررسی شود. بنابراین، در این مقاله به بررسی کارآیی چهار نوع شبکه عصبی با ساختار متفاوت شامل MLP، RBF، GRNN و PNN در تعیین نقاط حفاری ذخایر معدنی مس پورفیری در منطقه چاه فیروزه استان کرمان با بهره‌گیری از روش cross correlation پرداخته شده است. به همین منظور پس از شناسایی فاکتورهای کانی‌سازی و جمع‌آوری داده‌های مورد نیاز، نقشه‌های عامل در محیط GIS تهیه و بردارهای آموزشی شبکه عصبی استخراج شد و شبکه‌های عصبی یاد شده توسط داده‌های آموزشی، آموزش داده و به وسیله نقاط آزمون و بر اساس معیار درجه مطلوبیت گمانه‌های اکتشافی، ارزیابی شدند. نتایج پیاده‌سازی این چهار نوع شبکه عصبی، نشان می‌دهد که در میان چهار ساختار مختلف شبکه عصبی، شبکه‌های GRNN و RBF از کارآیی بهتر با دقتی در حدود ۸۰ تا ۸۳ درصد برای مدل‌سازی مکان‌یابی نقاط بهینه حفاری دارند. با استفاده از شبکه GRNN نقشه میزان مطلوبیت برای حفاری چاه‌های اکتشافی تولید شده است.

کلیدواژه‌ها: شبکه‌های عصبی، مس پورفیری، نقاط حفاری، سیستم اطلاعات مکانی.

*نویسنده مسئول: متین فروتن

E-mail: matin_f_m@yahoo.com

۱- مقدمه

نتایج مناسبی برای تعیین مکان‌های بهینه نقاط حفاری دست یافت (Porwal, 2006). شبکه‌های عصبی توانایی بالایی در استخراج الگوها از میان داده‌ها و همچنین حل مسائل پیچیده با ماهیت طبیعی دارند. دقت اجرای این شبکه‌ها در حالت وابستگی متغیرهای ورودی و حتی وجود نوفه در داده‌ها مناسب بوده و با امکان آموزش‌پذیری دوباره در هنگام ورود داده‌های جدید، انعطاف‌پذیری بالایی دارند. این شبکه‌ها قادرند با مدیریت حجم عظیم داده‌های ورودی و پردازش آنها، تحلیل درستی از ارتباط میان آنها و شواهد زمینی استخراج کنند و الگوها را تشخیص دهند (Bishop, 1995). بنابراین شبکه‌های عصبی با قابلیت‌های یادشده، می‌توانند به عنوان روشی قابل اعتماد در تعیین نقاط بهینه حفاری مورد استفاده قرار گیرند.

در زمینه استفاده از شبکه‌های عصبی، در مطالعات معدنی تاکنون پژوهش‌های مختلفی صورت پذیرفته است. (Singer & Kouda, 1997) از شبکه‌های عصبی برای برآورد فاصله از رگه‌های معدنی استفاده کرده‌اند. این پژوهشگران همچنین به استفاده از شبکه‌های عصبی احتمالاتی، برای رده‌بندی رگه‌های معدنی پرداختند (Singer & Kouda, 1997). آنها همچنین در سال ۱۹۹۹ به مقایسه نقشه پتانسیل معدنی تهیه شده توسط شبکه‌های عصبی و وزن‌های نشانگر پرداختند. نتایج این پژوهش نشان می‌داد که میزان خطا (با مقدار ۲٪) در رده‌بندی رگه‌های معدنی در نقشه تهیه شده به روش شبکه عصبی برای هر دو سری نقاط آزمایش و آموزش، به مراتب کمتر از میزان خطا (با مقدار ۲۳٪) در رده‌بندی رگه‌های معدنی در نقشه تهیه شده به روش وزن‌های نشانگر است (Singer & Kouda, 1999).

(Brown et al. (2000, 2003) تلفیق GIS و شبکه‌های عصبی را در تهیه نقشه پتانسیل معدنی در مقیاس ۱:۱۰۰۰۰۰ در منطقه تترفیلد مدنظر قرار دادند. آنها برای

مدل‌سازی شکل و موقعیت توده‌های معدنی در مطالعات اکتشاف تفصیلی مواد معدنی، اهمیت ویژه‌ای دارد. برای نیل به این مقصود، یکی از روش‌های مؤثر، حفر چاه‌های اکتشافی و سپس بررسی نمونه‌های استخراج شده از ژرفای زمین از نظر عیار ماده معدنی است. از طرفی، حفر چاه‌های اکتشافی، عملیاتی بسیار پرهزینه است و در عین حال به علت تعدد و تنوع عوامل مؤثر بر شکل‌گیری توده‌های معدنی که بیشتر متأثر از رفتارهای غیرقابل پیش‌بینی طبیعت نیز هستند تاکنون مدل و الگوی مشخص و دقیقی برای تعیین نقاط بهینه حفر چاه‌های اکتشافی گسترش داده نشده است. به همین دلیل، حفر چاه‌های اکتشافی بیشتر به صورت تجربی یا بر اساس تحلیل‌های ساده مکانی انجام می‌پذیرد که ممکن است (غالباً با احتمال پایین) منجر به دستیابی داده‌های مناسب برای مدل‌سازی توده معدنی شود.

با توجه به مطالب یادشده، وجود مدلی برای تعیین نقاط بهینه حفاری چاه‌های اکتشافی یکی از نیازهای اساسی مطالعات تفصیلی مواد معدنی است که نه تنها می‌تواند منجر به کاهش هزینه‌ها شود، بلکه مدل‌سازی شکل و موقعیت توده‌های معدنی را نیز آسان می‌کند. تعیین نقاط بهینه حفاری نیازمند تلفیق اطلاعات زمینی و فاکتورهای مؤثر بر کانی‌سازی و استخراج الگوهای صحیح نحوه شکل‌گیری ذخایر معدنی از میان این اطلاعات است. این اطلاعات که شامل اطلاعات زمین‌شناسی، ژئوفیزیک و ژئوشیمی هستند، به عنوان پیشگویی کننده‌ها در شکل‌گیری ذخایر معدنی به کار می‌روند و ارتباط میان این اطلاعات و شکل‌گیری ذخایر آن قدر پیچیده است که امکان دست‌یابی به آن از راه مطالعات آماری و تقریب‌زن‌های خطی وجود ندارد. از سوی دیگر، وجود اطلاعات جامع زمینی، حجم بسیاری از داده‌ها را به وجود می‌آورد که بدون در اختیار داشتن ابزارهای مناسب پردازش و مدیریت داده‌ها نمی‌توان به

اکتشاف معدنی به شمار می‌روند. تفاوت ساختارهای مختلف شبکه‌های عصبی در اختلاف توابع محرک است.

۱-۲. شبکه پرسپترون چندلایه (MLP; Multi Layer Perceptr)

برای شبکه‌های پرسپترون چند لایه از قانون یادگیری پس انتشار خطا که مبتنی بر قانون یادگیری اصلاح خطا (حرکت در سوی منفی شیب لحظه‌ای تابع عملکرد تابع خطا) که سبب کاهش خطای مدل می‌شود) است، استفاده می‌شود. قانون پس انتشار خطا از دو مسیر اصلی تشکیل می‌شود. در مسیر اول، بردار ورودی به شبکه M اعمال می‌شود و تأثیراتش از طریق لایه‌های میانی به لایه‌های خروجی انتشار می‌یابد. بردار خروجی تشکیل یافته در لایه خروجی، پاسخ واقعی شبکه MLP را تشکیل می‌دهد. در مسیر دوم که به مسیر برگشت موسوم است، پارامترهای شبکه MLP تغییر و تنظیم می‌شوند. این تنظیم مطابق با قانون اصلاح خطا انجام می‌گیرد. بدین ترتیب که سیگنال خطا که برابر با اختلاف میان پاسخ مطلوب و پاسخ واقعی شبکه عصبی است، در لایه خروجی تشکیل و مقدار خطا پس از محاسبه، در مسیر برگشت از لایه خروجی و به وسیله لایه‌های شبکه عصبی در کل شبکه پراکنده می‌شود (Hagan et al., 1996). شکل ۲ ساختار یک شبکه پرسپترون چند لایه را نمایش می‌دهد. در این شکل بردار معرف بردار ورودی شبکه عصبی است. همچنین ماتریس $IW^{1,1}$ وزن بردار ورودی شبکه عصبی و b^1 بایاس لایه اول هستند. n^1 از مجموع بردار $IW.P$ و بردار بایاس حاصل می‌شود. پس از نگاشت n^1 به وسیله تابع محرک لایه اول که یک تابع TANSIG است، a^1 که همان ورودی لایه دوم است به دست می‌آید. $LW^{2,1}$ معرف وزن میان لایه اول و دوم نورون‌ها و b^2 بایاس لایه دوم هستند. a^2 نشان‌دهنده خروجی شبکه عصبی است که پس از نگاشت n_2 به وسیله تابع محرک لایه دوم که یک تابع pureline است، حاصل می‌شود.

۲-۲. شبکه‌های شعاع مبنا (RBF; Radial Basis Function)

تفاوت اساسی شبکه‌های شعاع مبنا (RBF) با شبکه‌های پرسپترون چندلایه، در بردار ورودی و تابع محرک است. در شبکه‌های RBF، ابتدا بردار فاصله میان بردار وزن و بردار ورودی به کمک یک ضرب اسکالر محاسبه می‌شود. سپس بردار حاصل در بردار بایاس ضرب و حاصل ضرب آن به عنوان بردار ورودی شبکه در نظر گرفته می‌شود (Chen et al., 1991). شکل ۳ یک شبکه شعاع مبنا را نشان می‌دهد. افزون بر پارامترهای بیان شده در شبکه پرسپترون چند لایه، در شکل ۳، لایه شعاع مبنا با نماد dist نمایش داده شده است. همچنین تابع محرک لایه اول یک تابع از نوع گوسین است. در این پژوهش دو نوع شبکه RBF مورد استفاده قرار گرفته است. شبکه RBF از نوع exact که در آن تعداد نورون‌های لایه ورودی برابر با تعداد بردارها در ماتریس ورودی است. در حالی که در حالت دیگر شبکه RBF تعداد نورون‌ها بر اساس تابع خطا در هر تکرار متغیر است، به طوری که تعداد نورون‌ها تنها به شرط کاهش میزان خطا در هر تکرار، افزایش می‌یابد.

۳-۲. شبکه‌های تعمیمی رگرسیونی (GRNN; Generalized Neural Network)

شبکه‌های GRNN مجموعه‌ای از شبکه‌های RBF از نوع exact به همراه یک لایه خطی هستند (شکل ۴). در این شبکه‌ها تعداد نورون‌ها در لایه‌های پنهان و خروجی شبکه مساوی و برابر با تعداد تارگت‌ها است (Chen et al., 1991). همان گونه که در شکل ۴ دیده می‌شود در شبکه عصبی GRNN در لایه دوم ابتدا بردارهای $LW^{2,1}$ و a^2 توسط nprod بهنجار و سپس در یکدیگر ضرب می‌شوند.

۴-۲. شبکه‌های احتمالی (PNN; Probablistic Neural Network)

شبکه‌های PNN در مسائل رده‌بندی کاربرد فراوان دارند، این شبکه‌ها شامل یک لایه شعاع مبنا به همراه یک لایه با تابع محرک از نوع رقابتی است. این لایه رقابتی مقدار محتمل‌ترین رده را برای عضویت یک ورودی خاص، بر اساس قوانین احتمال بیزین بر می‌گزیند و ورودی یاد شده را در آن رده خاص قرار می‌دهد (Chen et al., 1991). در شکل ۵ یک شبکه عصبی احتمالی با تابع محرک رقابتی در لایه دوم نشان داده شده است.

تهیه نقشه‌های پتانسیل معدنی از شبکه پرسپترون چند لایه استفاده کردند و دقت نقشه تهیه شده ۶۸٪ ارزیابی شد (Brown et al., 2000 & 2003). با توجه به این که فرایند شکل‌گیری ذخایر معدنی ماهیت طبیعی دارد و استفاده از شبکه‌های عصبی، یکی از بهترین گزینه‌ها در مدل‌سازی پدیده‌ها با ماهیت طبیعی به شمار می‌رود، استفاده از شبکه عصبی MLP به منظور تهیه نقشه پتانسیل معدنی، از برتری‌های روش به کار گرفته شده توسط آنها بود. با این حال یکی از ضعف‌های این روش وابستگی دقت مدل‌سازی به تعداد داده‌های آموزشی بود و دقت نقشه پتانسیل معدنی تهیه شده توسط شبکه عصبی، تحت تأثیر عامل کم بودن تعداد داده‌های آموزشی قرار گرفت. Hosseinali & Alesheikh (2008) به وزن‌دهی لایه‌های اطلاعاتی در کانسار مس علی‌آباد توسط شبکه پرسپترون چند لایه و تهیه نقشه‌های پتانسیل معدنی در این کانسار پرداختند. کمترین میزان خطا برای نقاط آزمایش برابر ۲۸٪ و مربوط به یک شبکه پرسپترون سه لایه با ۸ نورون در لایه پنهان اول و ۳ نورون در لایه پنهان دوم ارزیابی شد (Hosseinali & Alesheikh, 2008). با توجه به حجم عظیم فاکتورهای مؤثر بر کانی‌سازی در شکل‌گیری کانسارهای مس پورفیری و ماهیت طبیعی این مسئله، از مزایای این روش استفاده از شبکه عصبی به منظور حل مسئله شکل‌گیری ذخائر معدنی بود. با این وجود با توجه به این که در این روش، وزن فاکتورهای کانی‌سازی از شبکه عصبی استخراج شده و برای تهیه نقشه پتانسیل معدنی، این لایه‌های اطلاعاتی توسط روش همپوشانی شاخص تلفیق شده‌اند، این روش ایرادهای اساسی دارد. زیرا برای تهیه نقشه پتانسیل معدنی منطقه لازم است که مدل‌سازی پیکسل‌های کل منطقه توسط شبکه عصبی صورت گیرد؛ نه این که وزن تلفیق فاکتورهای کانی‌سازی از شبکه عصبی استخراج شود.

(Harris & Pan (1999 از شبکه‌های عصبی احتمالاتی و روش‌های رگرسیونی در پیش‌بینی رگه‌های معدنی استفاده کردند که در ارزیابی و مقایسه این روش‌ها، بهترین دقت مربوط به روش شبکه عصبی احتمالاتی بود (Harris & Pan, 1999). برخی از پژوهش‌ها نیز به استفاده تلفیقی از شبکه‌های عصبی و دیگر روش‌ها برای تهیه نقشه‌های پتانسیل معدنی پرداخته‌اند. مثلاً Sanchez et al. (2003) شبکه‌های عصبی و اطلاعات سنجنش از دور را تلفیق کردند. پژوهش‌های محدودی نیز به ارائه راه‌کارهایی برای رفع محدودیت‌های شبکه‌های عصبی با استفاده از قوانین احتمال پرداخته‌اند (Skabar, 2005). با مروری بر پژوهش‌های مرتبط، می‌توان دریافت که بیشتر آنها به استفاده از شبکه‌های عصبی در تهیه نقشه پتانسیل معدنی در مطالعات پی‌جویی محدود بوده‌اند و تاکنون مطالعات کاملی در زمینه اکتشاف تفصیلی و هدایت حفاری انجام نگرفته است. از سوی دیگر، شبکه‌های عصبی انواع مختلفی دارند، که لازم است برای هر مسئله، نوع مناسب شبکه انتخاب شود. با توجه به مطالب یاد شده، هدف از این پژوهش بررسی کارایی و مقایسه چهار نوع شبکه عصبی MLP, RBF, PNN و GRNN در تعیین نقاط بهینه حفاری به منظور اکتشاف مس پورفیری و سپس استفاده از شبکه مناسب برای تولید نقشه مکان‌های بهینه حفاری است.

۲- شبکه‌های عصبی

شبکه‌های عصبی مصنوعی، یک پردازشگر تشکیل شده از واحدهای کوچکی است که به‌طور موازی ساختار یافته‌اند. این پردازشگر که نورون نامیده می‌شود با استفاده از دانش تجربی آموزش داده می‌شود و سپس با تعمیم دانش به دست آمده درک بهتری از محیط به دست می‌آورند. منظور از تعمیم، ارائه خروجی قابل قبول برای ورودی‌هایی است که پیش‌تر وارد سیستم نشده‌اند. شکل ۱ ساختار یک نورون مصنوعی را نمایش می‌دهد که شامل سه بخش وزن‌های ورودی، اضافه‌کننده (adder) و تابع محرک است (Hagan et al., 1996). این شبکه‌ها با دارا بودن قابلیت‌هایی مانند ساختار غیرخطی، تعمیم‌پذیری، یادگیری از الگوهای آموزشی، چشم‌پوشی خطا و رده‌بندی، ابزار توانمندی در علوم

۳- منطقه مطالعاتی

همان گونه که بیان شد، برای هدایت هرچه بهتر حفاری و انتخاب نقاط بهینه لازم است تمامی فرایندهای مؤثر بر شکل گیری ذخایر معدنی و فاکتورهای مؤثر در کانی سازی برحسب نوع ماده معدنی شناسایی شوند. تعیین فاکتورهای تشخیص کانی سازی، نیازمند بررسی دقیق مطالعات زمین شناسی، ژئوفیزیک، ژئوشیمی و مطالعات مربوط به چاه های اکتشافی است. بنابراین برای کارایی هرچه بهتر شبکه های عصبی، منطقه مورد مطالعه باید به گونه ای انتخاب شود که افزون بر وجود شواهد کانی سازی، از لحاظ وجود داده های زمین شناسی، ژئوفیزیک، ژئوشیمی و چاه های اکتشافی از جامعیت لازم برخوردار باشد. اندیس چاه فیروزه که در محدوده طول جغرافیایی $30^{\circ} 23'$ و $30^{\circ} 24'$ شمالی، و محدوده عرض جغرافیایی $55^{\circ} 01'$ و 55° خاوری واقع است، در 35 کیلومتری شهر بابک قرار گرفته است. این محدوده در بخش جنوب خاوری زون فرورانش ارومیه- دختر واقع شده است. با توجه به پتانسیل قوی کانی سازی مس در این زون و وجود کانسارهای بزرگ مس پورفیری مانند سرچشمه، میدوک، دره زار و سونگون، ضرورت پی جویی و اکتشاف در این زون کاملاً منطقی است. همچنین وجود نقشه های جامع GISready زمین شناسی، ژئوفیزیک، ژئوشیمی از ویژگی های آشکار این منطقه است. شکل های ۶ و ۷ موقعیت منطقه مطالعاتی را نشان می دهد.

۴- روش اجرا

با توجه به این که هدف این مقاله بررسی کارآیی شبکه های عصبی مختلف در تعیین نقاط حفاری است، روش شناسی اجرا در شکل ۸ نمایش داده شده است. در ادامه هر یک از مراحل تشریح شده است.

۴-۱. تعیین فاکتورهای تشخیص کانی سازی

در این مرحله لایه های اطلاعاتی مؤثر در شکل گیری ذخایر عنصر مس، که نشانه ای بر وجود این عنصر و خاستگاه اصلی ترکیبات آن هستند، با بررسی مدل مفهومی ذخیره معدنی، دانش کارشناسی و داده ها تعیین شد. مدل مفهومی ذخایر معدنی، برای ایجاد یک چارچوب نظری، به منظور هدایت پتانسیل یابی معدنی در GIS اهمیت دارد. این مدل در انتخاب شواهد کانی سازی، آماده سازی اطلاعات، تعیین اهمیت نسبی این شواهد و انتخاب مدل مناسب به منظور تلفیق شواهد، نقش بسزایی دارد (کریمی، ۱۳۸۱). فاکتورهای تشخیص کانی سازی بر اساس نتایج مطالعات بیان شده در جدول ۱ نمایش داده شده است.

۴-۲. جمع آوری و آماده سازی داده ها

تعیین نقاط بهینه حفاری به وسیله تلفیق لایه های اطلاعاتی فاکتورهای کانی سازی و با توجه به نحوه تأثیر این لایه ها و نوع ذخیره معدنی خاص انجام می شود. بنابراین لازم است با انجام یکسری پردازش ها، نقشه فاکتور هر لایه اطلاعاتی در محیط GIS تهیه شود و این نقشه ها باهم تلفیق شوند. به همین منظور، پس از شناسایی فاکتورهای کانی سازی و جمع آوری داده ها، جلسات مختلفی با کارشناسان شرکت ملی صنایع مس ایران برگزار و بر اساس نظرات آنها، لایه های اطلاعاتی وزن دهی و نقشه فاکتور هر لایه اطلاعاتی در محیط GIS و با استفاده از نرم افزار ARCGIS تهیه شد. چگونگی وزن دهی لایه های اطلاعاتی و تهیه نقشه های فاکتور در جدول های ۲ تا ۱۱ مشخص شده است. نقشه های فاکتور تهیه شده، برای تشکیل بردارهای ورودی به شبکه عصبی در شکل های ۹ تا ۱۲ نمایش داده شده اند. مرحله بعدی، تبدیل نقشه های فاکتور به بردارهای آموزش شبکه است. بردارهای آموزش شبکه به دو دسته داده های آموزشی ورودی، داده های آموزشی خروجی تقسیم می شوند.

– **آماده سازی داده های آموزشی ورودی:** داده های آموزشی ورودی شبکه عصبی، فاکتورهای کنترل کننده کانی سازی هستند که در قالب نقشه های فاکتور در محیط GIS تهیه شدند. در این مرحله کلیه نقشه های فاکتور در محیط GIS به حالت رستری با اندازه پیکسل یکسان و سپس از حالت رستری به فرمت ASCII تبدیل شد.

– **آماده سازی داده های آموزشی خروجی:** یکی از ویژگی های کانسار چاه فیروزه، وجود ۴۱ حلقه چاه اکتشافی است که کلیه اطلاعات این گمانه ها شامل ژرفا، عیار عنصر مس نسبت به ژرفا و مختصات مکان مرجع گمانه ها موجود است. برای استخراج بردار خروجی شبکه عصبی، نیاز به معیاری است که به وسیله آن بتوان میزان مطلوب بودن گمانه اکتشافی مورد نظر برای حفاری را سنجید. به همین منظور در هر گمانه، از میانگین درصد عیار عنصر مس نسبت به ژرفای گمانه استفاده شد. به این صورت که ابتدا، نمودارهای ژرفا نسبت به درصد عیار عنصر مس در هر گمانه رسم شد و درجه مطلوب بودن کیفی هر گمانه با توجه به میزان میانگین درصد عیار مس، تعیین شد. درجه مطلوب بودن کیفی گمانه های اکتشافی در جدول ۱۲ نشان داده شده است.

۴-۳. استخراج بردارهای آموزشی شبکه عصبی

همان گونه که بیان شد، برای استخراج بردارهای آموزشی خروجی شبکه، از میزان میانگین عیار مس نسبت به ژرفا در هر گمانه استفاده شد و با تشکیل جدول ارزیابی مقادیر کیفی گمانه ها، گمانه ها برحسب درجه مطلوب بودن به دو دسته مطلوب و نامطلوب تقسیم شدند و درجه مطلوب بودن هر یک از آنها به صورت عددی تعیین شد. در شکل ۱۳، بردار درجه مطلوب بودن گمانه ها در لایه رستری گمانه های اکتشافی، نمایش داده شده است.

برای استخراج بردارهای آموزشی ورودی هم، ابتدا کلیه نقشه های فاکتور به حالت رستری با اندازه پیکسل یکسان تبدیل شدند (شکل ۱۳). سپس به ازای هر درایه از بردار گمانه های اکتشافی (X_i)، درایه متناظر X_{ij} از نقشه های فاکتور استخراج شد. بردار حاصل یک بردار شامل ۱۰ درایه از عامل های کنترل کننده کانی سازی، در هر گمانه اکتشافی است که به عنوان بردار آموزشی ورودی متناظر با درجه مطلوب بودن هر گمانه در فرایند آموزش مورد استفاده قرار می گیرد.

۴-۴. ورود داده ها به شبکه عصبی و آموزش شبکه عصبی

پس از آماده سازی بردارهای آموزشی ورودی و خروجی شبکه عصبی، چهار شبکه عصبی MLP، RBF، PNN و GRNN به وسیله داده های آموزشی در محیط نرم افزار MATLAB، آموزش داده شدند. با توجه به کم بودن تعداد داده های آموزشی، برای آموزش این چهار شبکه عصبی از روش cross correlation بهره برده شد. در روش cross correlation داده های آموزشی به چندین بخش به صورت تصادفی تقسیم بندی می شوند (Bishop, 1995). در هر مرحله یکی از این بخش ها از شبکه عصبی خارج شده و شبکه عصبی با دیگر داده ها، آموزش داده می شود و از داده های خارج شده به عنوان داده هایی برای آزمایش کارآیی شبکه عصبی استفاده می شود. با تکرار این فرایند، در هر تکرار بخش دیگر داده های آموزشی از میان داده ها خارج می شود و آموزش شبکه عصبی به همان روش یادشده، انجام می گیرد.

در این پژوهش، ۴۲ زوج ورودی/خروجی آموزشی وجود داشت که از این تعداد، ۵٪ داده ها به عنوان داده های آزمایش و بقیه به عنوان داده های آموزش مورد استفاده قرار گرفتند. معیار توقف آموزش شبکه های عصبی MLP و RBF، دو معیار تعداد اپاک های آموزش (epochs) و خطای هدف (Error Goa) هستند. در این پژوهش آموزش شبکه عصبی MLP پس از ۱۸ اپاک و رسیدن مقدار حد آستانه خطای هدف به عدد 0.012 متوقف شد. همچنین آموزش شبکه عصبی RBF پس از ۲۵ اپاک و رسیدن مقدار حد آستانه خطای هدف به $6/206$ متوقف شد.

۵- ارزیابی کارآیی شبکه های عصبی و تحلیل نتایج

پس از آموزش شبکه عصبی، مدل سازی مقادیر درجه مطلوب بودن نسبت داده شده به گمانه ها، توسط شبکه عصبی انجام می پذیرد و بر اساس مقایسه مقادیر خروجی و مقادیر اولیه، میزان کارآیی شبکه عصبی در برآورد مکان های بهینه برای حفاری مشخص می شود. شکل های ۱۴ تا ۱۶ مقادیر درجه مطلوب بودن پیش بینی شده برای گمانه ها توسط شبکه های MLP، RBF، PNN و GRNN را نشان می دهند. در این


حاکم بر شکل‌گیری ذخایر معدنی است تا با استفاده از آن بتوان افزون بر کاهش ریسک و هزینه‌های فرایند هدایت حفاری، شکل و موقعیت توده‌های معدنی را نیز مدل‌سازی کرد. تعیین نقاط بهینه حفاری، مستلزم تلفیق اطلاعات زمینی و فاکتورهای مؤثر بر کانی‌سازی و استخراج الگوهای صحیح نحوه شکل‌گیری ذخایر معدنی از میان این اطلاعات است. شبکه‌های عصبی با انعطاف‌پذیری بالا، تشخیص الگوها از میان داده‌ها را با دقت بالایی فراهم می‌کنند. در این مقاله به بررسی و مقایسه کارایی چهار نوع شبکه عصبی در تعیین نقاط بهینه حفاری برای هدایت هر چه بهتر حفاری در منطقه چاه‌فیروزه استان کرمان پرداخته شده است. با توجه به تحلیل مدل‌سازی به‌وسیله شبکه‌های عصبی بیان شده نتایج زیر به دست آمد.

در شبکه‌های عصبی پرسپترون چند لایه با توجه به متفاوت بودن میزان خطا بر اساس تعداد متفاوت نورون‌ها در لایه میانی، بهترین آرایش شبکه عصبی برای مدل‌سازی مکان‌های بهینه حفاری، بر اساس نقاط آزمایش تعداد ۷ نورون در لایه پنهان ارزیابی شد. با این وجود به‌نظر می‌رسد تعداد این نورون‌ها تابع شرایطی مانند نوع کانی، فاکتورهای کانی‌سازی و شرایط منطقه مطالعاتی باشد. اختلاف قابل توجه RMSE نقاط آزمایش دو شبکه RBF و GRNN با دیگر شبکه‌های MLP و PNN، قابلیت بالای این شبکه‌های عصبی در مدل‌سازی و تعیین نقاط بهینه حفاری را نشان می‌دهد. همچنین اختلاف کم ۲٪ در میزان خطا در شبکه‌های RBF و GRNN نشان می‌دهد که با توجه به میزان خطا در نقاط آزمایش، شبکه GRNN در منطقه مطالعاتی کارایی بهتری دارد. اما در دیگر مناطق مطالعاتی هر دو شبکه باید مورد ارزیابی قرار گیرند. با توجه به نتایج حاصل و میزان RMSE ۱۷٪ برای شبکه GRNN می‌توان ادعا کرد که شبکه‌های عصبی بدون پذیرفتن پیش‌شرط قادر به مدل‌سازی مکان‌های بهینه نقاط حفاری تا دقت ۸۳٪ در منطقه مطالعاتی هستند.

با توجه به قابلیت‌های شبکه‌های عصبی در مدل‌سازی مکان‌های بهینه حفاری و ماهیت طبیعی فرایند شکل‌گیری ذخایر معدنی، می‌توان این شبکه‌ها را در مناطق مطالعاتی دیگر به‌منظور اکتشاف تفصیلی مس پورفیری به کار برد. همچنین می‌توان با تغییر ماده معدنی مورد نظر، این شبکه‌ها را برای اکتشاف مواد معدنی دیگر با فاکتورهای کانی‌سازی متفاوت آزمایش و نقشه مکان‌های بهینه حفاری برای عناصر مختلف را رسم کرد. ارزیابی کارایی شبکه‌های عصبی با ساختارهای مختلف در مناطق مطالعاتی مختلف و برای اکتشاف کانی‌های گوناگون با شرایط شکل‌گیری متفاوت و فاکتورهای کانی‌سازی متفاوت، می‌تواند موضوع مطالعات بعدی قرار گیرد. همچنین امکان‌سنجی گسترش یک مدل جامع برای تعیین نقاط بهینه حفاری با استفاده از داده‌های موجود از کل کشور، کارهای آینده نگارندگان را تشکیل می‌دهد.

سپاسگزاری

نگارندگان این مقاله از کارشناسان محترم شرکت ملی صنایع مس ایران و همچنین از جناب آقای مهندس نادر صاحب زمانی، جناب آقای مهندس امیر عادل سرچشمه و جناب آقای مهندس امین مهرمنش، به‌دلیل همکاری صمیمانه‌شان در تهیه نقشه‌های موجود سپاسگزاری می‌شود.



شکل ۱- نورون مصنوعی.

شکل‌ها نمودارهای آبی رنگ نمایانگر مقادیر تعیین شده برای درجه مطلوب بودن گمانه‌ها با توجه به نمودارهای ژرفا نسبت به درصد عیار مس در هر گمانه هستند و علامت + نمایانگر مقادیر پیش‌بینی شده برای هر گمانه توسط شبکه عصبی است. لازم به یادآوری است که هر چه انطباق + با نمودارها بیشتر باشد، شبکه عصبی کارایی مطلوب‌تری دارد. برای مثال از مقایسه شکل‌های ۱۴-الف و ب، نتیجه می‌شود که چون در شکل ۱۴-ب مقادیر + با مقادیر کارشناسی درجه مطلوب بودن گمانه‌ها انطباق بیشتری دارند، شبکه RBF کارایی بالاتری نسبت به شبکه MLP دارد که مقایسه مقادیر RMSE در جدول ۱۴ نیز گواه این مطلب است.

پس از آموزش شبکه و مدل‌سازی مقادیر درجه مطلوب بودن گمانه‌ها به وسیله شبکه عصبی، مقادیر مدل‌سازی شده با مقادیر کارشناسی اولیه در بردار آموزشی خروجی مقایسه شد و بر اساس تفاضل بردار مدل‌سازی شده درجه مطلوب بودن گمانه‌ها و بردار آموزشی خروجی اولیه، میزان کارایی شبکه عصبی در بردار مکان‌های بهینه برای حفاری مشخص شد. جدول‌های ۱۳ و ۱۴ میزان مقادیر RMSE را برای چهار شبکه عصبی نمایش می‌دهند. با توجه به این که در شبکه MLP، مدل‌سازی بر اساس ساختارها و تعداد نورون‌های متفاوت در هر لایه، متفاوت است، جدول مربوط به شبکه MLP برای یک شبکه پرسپترون دو لایه، بر اساس تعداد نورون‌ها در لایه پنهان، به‌صورت جدا آورده شده است. آرایش در این شبکه‌ها به‌صورت A.B.C است که در آن A تعداد نورون‌های ورودی (تعداد فاکتورهای مؤثر در کانی‌سازی)، B تعداد نورون‌های لایه پنهان اول و C برابر با عدد یک، یعنی خروجی مدل‌سازی شده برای هر گمانه توسط شبکه عصبی است. لازم به یادآوری است که در شبکه‌های پرسپترون چند لایه، تعداد نورون‌های لایه ورودی جزء لایه‌های شبکه عصبی به شمار نمی‌رود.

همان گونه که در جدول ۱۳ دیده می‌شود، بهترین آرایش برای شبکه‌های پرسپترون دو لایه بر اساس RMSE نقاط آزمایش به صورت ۱، ۷ و ۱۰ است. در میان شبکه‌های عصبی آزمایش شده بهترین شبکه برای مکان‌یابی نقاط حفاری، با در نظر گرفتن RMSE نقاط آزمایش، شبکه GRNN است. در شکل ۱۶ نیز مطلوب بودن این ساختار شبکه عصبی برای تعیین نقاط حفاری، با توجه به نزدیکی مقادیر درجه مطلوب بودن مدل‌سازی شده و مقادیر اولیه درجه مطلوب بودن در منطقه مطالعاتی نمایش داده است.


مرحله بعد تهیه یک نقشه در محیط GIS است که نمایانگر مکان‌های بهینه حفاری در منطقه مطالعاتی باشد. به همین منظور، پس از تعیین بهترین ساختار شبکه به منظور تعیین نقاط بهینه حفاری، نقشه‌های فاکتور کل منطقه به حالت ASCII تبدیل شد. خروجی این مرحله ماتریس‌هایی است که درایه‌های آنها شامل مقادیر فاکتورهای کنترل کننده کانی‌سازی در تمام پیکسل‌های منطقه مطالعاتی است. با توجه به این که تعداد فاکتورهای کنترل کننده کانی‌سازی ۱۰ فاکتور بود، خروجی این مرحله، ۱۰ ماتریس با مقادیر فاکتورهای کانی‌سازی در منطقه مطالعاتی بود.

سپس ماتریس‌های یادشده، به‌عنوان ورودی، وارد شبکه عصبی GRNN شدند و مقادیر درجه مطلوب بودن برای حفاری در کل منطقه مطالعاتی مدل‌سازی و پیش‌بینی شد. در پایان، ماتریس حاصل در محیط GIS از حالت ASCII به حالت رستری تبدیل شد و نقشه مکان‌های بهینه حفاری با استفاده از شبکه عصبی GRNN در محیط ARCGIS، رسم شد. این نقشه در شکل ۱۷ نشان داده شده است.


شکل ۱۷، منطقه مطالعاتی را بر اساس مطلوب بودن حفر گمانه‌های اکتشافی تقسیم‌بندی می‌کند. همچنین روی این نقشه، لایه اطلاعاتی گمانه‌های اکتشافی که بر اساس جدول ۱۲ به‌صورت کیفی مطلوب ارزیابی شدند، نیز نمایش داده شده است. همان گونه که دیده می‌شود این گمانه‌ها همخوانی خوبی با نقشه تهیه شده دارند.

۶- نتیجه‌گیری


تعیین نقاط بهینه حفاری، عملی هوشمندانه و نیازمند در نظر گرفتن کلیه شرایط پیچیده




شکل ۴- شبکه GRNN.




شکل ۲- شبکه پرسپترون چندلایه.



شکل ۵- شبکه PNN.




شکل ۳- شبکه RBF.




شکل ۸- روش شناسی (Methodology) اجرا.




شکل ۷- موقعیت جغرافیایی.




شکل ۶- راه های دسترسی به محدوده مورد مطالعه.




شکل ۱۰- (الف) نقشه فاکتور دگرسانی، (ب) نقشه فاکتور عیار مولیبدن و (ج) نقشه فاکتور عیار مس (شرکت ملی صنایع مس ایران، ۱۳۸۷).




شکل ۹- (الف) نقشه فاکتور گسل های اصلی، (ب) نقشه زون منشأ حرارت و سنگ میزبان و (ج) نقشه نشانه های معدنی محلی (شرکت ملی صنایع مس ایران، ۱۳۸۷).




شکل ۱۳- روند تشکیل ماتریس‌های ورودی.




شکل ۱۲- نقشه فاکتور فلزی (شرکت ملی صنایع مس ایران، ۱۳۸۷).




الف



شکل ۱۴- الف) مقادیر پیش‌بینی شده توسط شبکه MLP و ب) مقادیر پیش‌بینی شده توسط شبکه RBF.




ب



ج

شکل ۱۱- الف) نقشه فاکتور شارژیابیته، ب) نقشه فاکتور اندیس‌های ادیتیو و ج) نقشه فاکتور مقاومت‌ظاهری (شرکت ملی صنایع مس ایران، ۱۳۸۷).



شکل ۱۵- الف) مقادیر پیش‌بینی شده توسط شبکه PNN و ب) مقادیر پیش‌بینی شده توسط شبکه RBF exact.

جدول ۱- فاکتورهای کنترل کننده کانی سازی.

عامل های کانی سازی	نقشه های موجود
مناطق تأثیر گرمایی	نقشه زون منشأ حرارت و سنگ میزبان
	نقشه دگرسانی گرمایی
	نقشه نشانه های معدنی محلی
گسل ها	نقشه گسل های اصلی
بی هنجاری ژئوشیمی	نقشه عیار یک عنصری (بی هنجاری مس-بی هنجاری مولیبدن)
	نقشه عیار چند عنصری (اندیس های ایتینو مس و مولیبدن)
بی هنجاری ژئوفیزیک	نقشه زون ناهنجاری مقاومت ظاهری
	نقشه زون ناهنجاری فاکتور فلزی
	نقشه زون ناهنجاری شارژ ایلپته

جدول ۲- وزن های اولیه مربوط به بافر های گسل های اصلی.

وزن اولیه	گسل اصلی
۰/۷	بافر ۱۵ متری گسل اصلی
۰/۶	بافر ۳۰ متری گسل اصلی
۰/۳	بافر ۴۵ متری گسل اصلی
۰/۱	بافر ۶۰ متری گسل اصلی
۰/۰۵	بافر ۷۵ متری گسل اصلی

جدول ۳- وزن اولیه مربوط به سنگ میزبان و بافر های سنگ میزبان محتوی سنگ دیواره.

وزن اولیه	سنگ میزبان
۰/۸	داسیت پورفیری دگرسان شده
۰/۶	بافر ۵ متری داسیت پورفیری شامل سنگ دیواره
۰/۴۵	بافر ۱۰ متری داسیت پورفیری شامل سنگ دیواره
۰/۳	بافر ۱۵ متری داسیت پورفیری شامل سنگ دیواره
۰/۲	بافر ۲۰ متری داسیت پورفیری شامل سنگ دیواره
۰/۱	بافر ۲۵ متری داسیت پورفیری شامل سنگ دیواره
۰/۰۵	بافر ۳۰ متری داسیت پورفیری شامل سنگ دیواره

جدول ۵- وزن های اولیه مربوط به نقشه فاکتور فلزی.

وزن اولیه	بی هنجاری ژئوفیزیک
۰/۸	بی هنجاری قطعی
۰/۵۵	بی هنجاری احتمالی
۰/۲	بی هنجاری ممکن
۰/۰۱	دیگر مناطق

جدول ۴- وزن های اولیه مربوط به نقشه شارژ ایلپته.

وزن اولیه	بی هنجاری ژئوفیزیک
۰/۷۵	بی هنجاری قطعی
۰/۵	بی هنجاری احتمالی
۰/۲	بی هنجاری ممکن
۰/۰۱	دیگر مناطق

جدول ۸- وزن های اولیه مربوط به دگرسانی.

وزن اولیه	دگرسانی
۰/۹	پتاسیک
۰/۷	فیلیک شدید
۰/۳۵	فیلیک ضعیف
۰/۲	پروپیلیتیک شدید
۰/۰۱	پروپیلیتیک ضعیف

جدول ۱۱- وزن های اولیه مربوط به نقشه اندیس های ایتینو.

وزن اولیه	بی هنجاری ژئوشیمی
۰/۹	بی هنجاری قطعی
۰/۸	بی هنجاری احتمالی
۰/۳۵	بی هنجاری ممکن
۰/۰۱	دیگر مناطق

جدول ۷- وزن های اولیه مربوط به بافر های نشانه های معدنی محلی.

وزن اولیه	نشانه های معدنی محلی
۰/۹	بافر ۱۵ متری از نشانه معدنی محلی
۰/۷	بافر ۳۰ متری از نشانه معدنی محلی
۰/۵	بافر ۴۵ متری از نشانه معدنی محلی
۰/۲	بافر ۶۰ متری از نشانه معدنی محلی

جدول ۱۰- وزن های اولیه مربوط به نقشه فاکتور مس.


وزن اولیه	بی هنجاری ژئوشیمی
۰/۸۵	بی هنجاری قطعی
۰/۷۵	بی هنجاری احتمالی
۰/۳	بی هنجاری ممکن
۰/۰۱	دیگر مناطق

جدول ۶- وزن های اولیه مربوط به نقشه مقاومت ظاهری.


وزن اولیه	بی هنجاری ژئوفیزیک
۰/۲۵	بی هنجاری قطعی
۰/۱۵	بی هنجاری احتمالی
۰/۰۵	بی هنجاری ممکن
۰/۰۱	دیگر مناطق

جدول ۹- وزن های اولیه مربوط به نقشه فاکتور مولیبدن.

وزن اولیه	بی هنجاری ژئوشیمی
۰/۷	بی هنجاری قطعی
۰/۵	بی هنجاری احتمالی
۰/۲	بی هنجاری ممکن
۰/۰۱	دیگر مناطق



شکل ۱۶- مقادیر پیش بینی شده توسط شبکه GRNN.



شکل ۱۷- نقشه مکان های بهینه حفاری در منطقه چاه فیروزه در محیط GIS.

جدول ۱۲- ارزیابی کیفی گمانه‌های منطقه چاه فیروزه.

شماره گمانه	ارزیابی کیفی	شماره گمانه	ارزیابی کیفی	شماره گمانه	ارزیابی کیفی	شماره گمانه	ارزیابی کیفی	شماره گمانه	ارزیابی کیفی
۱	ضعیف	۹	خ ضعیف	۱۷	خ ضعیف	۲۶	خ ضعیف	۳۳	خ خوب
۲	خ ضعیف	۱۰	خوب	۱۹	خ ضعیف	۲۷	خ خوب	۳۴	متوسط
۳	خ ضعیف	۱۱	خ ضعیف	۲۰	خ ضعیف	۲۸	متوسط	۳۵	خ خوب
۴	خ ضعیف	۱۲	متوسط	۲۱	خ ضعیف	۲۹	ضعیف	۳۶	متوسط
۵	خ ضعیف	۱۳	متوسط	۲۲	خ ضعیف	۳۰	متوسط	۳۷	ضعیف
۶	خ خوب	۱۴	خ ضعیف	۲۳	متوسط	۳۱	خ خوب	۳۸	متوسط
۷	خوب	۱۵	ضعیف	۲۴	خ ضعیف	۳۲	خ خوب	۳۹	ضعیف
۸	خ ضعیف	۱۶	خ ضعیف	۲۵	متوسط	۳۲	خ خوب	۴۰	متوسط

جدول ۱۳- نتایج RMSE داده‌های آموزشی و آزمون شبکه پرسپترون دولایه.

آرایشی	RMSE train	RMSE test	آرایشی	RMSE train	RMSE test	آرایشی	RMSE train	RMSE test
10,1,1	0/1422	0/1708	10,11,1	0/1547	0/1908	10,21,1	0/1361	0/2305
10,2,1	0/1240	0/1707	10,12,1	0/1382	0/2000	10,22,1	0/1399	0/2839
10,3,1	0/1213	0/2021	10,13,1	0/1208	0/1832	10,23,1	0/1587	0/2393
10,4,1	0/1340	0/1844	10,14,1	0/1691	0/2432	10,24,1	0/1422	0/3069
10,5,1	0/1370	0/2211	10,15,1	0/1215	0/2645	10,25,1	0/1248	0/2432
10,6,1	0/1328	0/1511	10,16,1	0/1412	0/2336	10,26,1	0/2131	0/3776
10,7,1	0/1354	0/1360	10,17,1	0/1194	0/2370	10,27,1	0/1177	0/2703
10,8,1	0/1619	0/1905	10,18,1	0/1709	0/2499	10,28,1	0/1616	0/2953
10,9,1	0/1589	0/2173	10,19,1	0/1817	0/2109	10,29,1	0/1332	0/3089
10,10,1	0/1217	0/2194	10,20,1	0/1270	0/2393	10,30,1	0/1611	0/3017

جدول ۱۴- نتایج RMSE داده‌های آموزشی و آزمون شبکه‌های GRNN, RBF, PNN.

نوع شبکه	RMSE train	RMSE test	نوع شبکه	RMSE train	RMSE test
RBF	0/0537	0/1998	PNN	0/1000	0/5365
RBF(exact)	0/0537	0/2284	GRNN	0/0893	0/1793

کتابنگاری

شرکت ملی صنایع مس ایران، ۱۳۸۷ - طرح تحقیق و توسعه اطلاعات جغرافیایی، تدوین متدولوژی تعیین نقاط حفاری با استفاده از GIS. کریمی، م، ۱۳۸۱- طراحی و اجرای یک سیستم اطلاعات مکانی جهت اکتشاف معادن مس در مقیاس تفصیلی، پایان نامه کارشناسی ارشد، دانشکده عمران، دانشگاه خواجه نصیرالدین طوسی.

References

- Bishop, C. M., 1995- Neural networks for pattern recognition, 1st edition. Oxford Clarendon,
- Brown, W. M., Gedeon, T. D. & 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, journal of Natural Resource Research, 12(2) : 141-152.
- Brown, W. M., Gedeon, T. D., Groves, D. I. & Barnes, R. G., 2000- Artificial neural networks: a new method for mineral prospectivity mapping, Australian journal of earth science, 47 : 757-770.
- Chen, S., Cowan, C. F. N. & Grant, P. M., 1991- Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks, IEEE Transactions on Neural Networks, 2(2): 302-309.
- Hagan, M. T., Demuth, H. B. & Beale, M. H., 1996- Neural Network Design, PWS Publishing Company, Boston.
- Haris, D. & Pan G., 1999- Mineral favourability mapping: a comparison of artificial neural networks, logical regression and discriminant analysis, journal of Natural Resource Research, 8: 93-109.
- Hosseinali, F. & Alesheikh, A. A., 2008- Weighting Spatial Information in GIS for copper Mining Exploration, journal of Applied Science, 5(9) : 1187-1198.
- Porwal, A., 2006- Mineral Potential Mapping with Mathematical Geological Models, PHD thesis.
- Sanchez, J. P., Chica-Olmo, M. & Abarca-Hernandez, F., 2003- Artificial Neural Network as a tool for mineral potential mapping with GIS, journal of Remote Sensing, 24(5) : 1151-1156.
- Singer, D. A. & Kouda, R., 1997- Classification of mineral deposits into types using mineralogy with a probabilistic neural network, Nonrenewable Resources, 6: 27-32.
- Singer, D. A. & Kouda, R. A., 1999- comparison of the weights-of-evidence method and probabilistic neural networks, Natural Resources Research, 8(4): 287-298.
- Skabar, A. A., 2005- Mapping Mineralization Probabilities using Multilayer Perceptrons, journal of Natural Resource Research, 14(2), 109-123.