

# تفکیک دگرسانی‌های کانسار مس سونگون با استفاده از شبکه‌های عصبی مصنوعی

اردشیر هزارخانی<sup>۱\*</sup>، پژمان طهماسبی<sup>۱</sup> و امید اصغری<sup>۲</sup>

<sup>۱</sup>دانشکده مهندسی معدن، متالورژی و نفت، دانشگاه صنعتی امیرکبیر، تهران، ایران.  
<sup>۲</sup>دانشکده مهندسی معدن، دانشگاه کاشان، کاشان، ایران.

تاریخ دریافت: ۱۳۸۷/۰۶/۲۳ تاریخ پذیرش: ۱۳۸۸/۰۴/۲۷

## چکیده

جدایش مناطق دگرسانی یکی از مراحل مهم در ارزیابی و شناسایی کارهای معدنی به شمار می‌رود که به داشتن دید بهتری از منطقه و شناخت نواحی کانی‌ساز کمک شایانی می‌کند. بیشتر روش‌های جدایش دگرسانی‌ها بر اساس مشاهدات سنگ‌شناسی است و کمتر، از روش‌های دیگر استفاده شده است. در این نوشتار، سعی شده است با استفاده از شبکه‌های عصبی نوع RBPNN (Radial Basis Probabilistic Neural Network) این مناطق را جدا نمود. این شبکه‌ها به علت ساختار منحصر به فرد و طراحی آسان آنها، بیشتر در مسائل طبقه‌بندی مورد استفاده قرار می‌گیرند. داده‌های ورودی مورد استفاده در این مطالعه، تجزیه‌های شیمیایی ۱۲ اکسید و ۱۶ عنصر (۲۸ متغیر) مربوط به ۴۵ نمونه ژئوشیمیایی بودند که خروجی آن نیز مناطق دگرسانی (پتاسیک، انتقالی و فلیک) هستند که برای هر کدام از داده‌های ورودی کدگذاری شده‌اند. پس از انتخاب داده‌های آموزشی و تست، شبکه برای آموزش آماده، و داده‌ها همراه با خروجی آنها به شبکه داده شد. بر اساس نتایج به دست آمده از این بررسی، شبکه توانست رابطه فضایی پیچیده مابین ورودی‌ها که یک فضای ۲۸ متغیره است را تشخیص داده و همچنین توانست دگرسانی‌ها را به درستی طبقه‌بندی نماید. به صورتی که مقدار MSE (میانگین مربعات خطا) ۰/۰۱۶۳ به دست آمد که خود حاکی از کارکرد مطلوب شبکه در این امر است.

**کلیدواژه‌ها:** شبکه‌های عصبی مصنوعی، دگرسانی، جدایش، احتمالی، سونگون.

\*نویسنده مسئول: اردشیر هزارخانی

E-mail: Ardehz@cic.aut.ac.ir

## ۱- مقدمه

در کارهای معدنی، بویژه در مراحل ارزیابی پتانسیل‌های آن، شناخت و تفکیک مناطق دگرسانی و نیز دانستن ویژگی‌های آن نقش کلیدی دارد. بیان گسترش مناطق دگرسانی به اطلاعاتی نیازمند است که همراه با حفر گمانه‌های مختلف، بررسی‌های آزمایشگاهی و تجزیه نمونه‌های زیاد وابسته است. تمام این عوامل، خود هر کدام معلول شرایط اقتصادی و هزینه تمام شده پروژه معدنی هستند. انجام این فعالیت‌ها وقت‌گیر و هزینه‌بر است. اگر چه نتایج به دست آمده هم در بعضی موارد همراه با شک و ابهاماتی است. به تازگی شبکه‌های عصبی استفاده‌های گسترده‌ای را در کارهای معدنی پیدا کرده‌اند (Arbogast, 1999; Ke, 2002; Koiek, 2002; Yama, 1999). در کارهای انجام شده پیشین به وسیله این متخصصان بر روی جدایش و تفکیک دگرسانی‌ها تأکیدی نشده و کاری بر روی آن صورت نگرفته است.

دلیل اصلی رشد سریع شبکه‌های عصبی در زمینه‌های مختلف علوم و مهندسی، توانایی آنها در برآورد و شناخت الگوهای موجود در بین داده‌ها است. شبکه عصبی با داشتن ویژگی دینامیکی و غیرخطی بودن آن، دارای این توانایی است که در بیشتر زمینه‌ها به کار برده شود. اگر این ساختارهای پیچیده همراه با آگاهی از شناخت و نحوه کارکرد آنها باشد، می‌تواند کاربردهای وسیعی داشته باشد. طراحی شبکه نیز بسته به کاربرد آن متفاوت بوده و در بیشتر مواقع به تجربه کاربر بستگی دارد تا فرد بتواند به ساختار بهینه شبکه مورد استفاده دست بیاید.

هدف از جدایش دگرسانی‌ها، شناسایی بهتر مناطق کانی‌زایی و ارائه راهکارهای اکتشافی مؤثر برای شناخت آن است به طوری که بدون جدایش دگرسانی‌ها در یک کانسار امکان نسبت دادن منطقه کانی‌زایی به بخشی از آن وجود ندارد. با شناخت بهتر از شیوه پراکندگی دقیق دگرسانی‌ها و تشخیص نمونه‌های مربوطه، بدون اتلاف هزینه و زمان که از پارامترهای مؤثر در کارهای اکتشافی هستند، می‌توان به عملیات اکتشافی شتاب بیشتری داد. هدف این نوشتار استفاده از شبکه‌های عصبی نوع PNN برای تفکیک و طبقه‌بندی مناطق مختلف دگرسانی واقع در کانسار مس پورفیری سونگون است که می‌توان با توجه به نتایج به دست آمده در این بررسی، تعلق نمونه‌های دیگر را به مناطق آنها بدون صرف وقت و هزینه‌های بیشتر انجام داد. در

واقع، در این نوشتار، با استفاده از ۲۸ متغیر به بررسی دگرسانی‌های موجود در کانسار مس سونگون پرداخته و سعی در جدایش آنها شده است. تفاوت اصلی این روش با روش‌های رایج در جدایش، استفاده از تعداد متغیرهای زیادتر و به نوعی در نظر گرفتن تمام عوامل موجود است. شبکه موجود توانسته این ارتباط پیچیده موجود در بین متغیرها را شناخته و منجر به جدایش دگرسانی‌ها شود.

## ۲- موقعیت زمین‌شناسی معدن سونگون

معدن مس پورفیری سونگون در ۷۵ کیلومتری شمال باختری شهرستان اهر در استان آذربایجان قرار دارد و شامل یک استوک دیوریت/گرانودیوریت تا کوارتز مونزونیتی با سن میوسن است (شکل ۱). استوک شامل دو توده اصلی نفوذی، یکی مونزونیت/کوارتز مونزونیتی (قدیمی‌تر) در بخش باختری و دیگری دیوریت/گرانودیوریت (جدیدتر) در بخش خاوری است. فعالیت‌های آذرین در این ناحیه به جایگزینی دایک‌های آندزیتی حجیمی در بخش خاوری منتهی می‌شود. بیشترین ژرفای تزریق ۲۰۰۰ متر برآورد شده است (Etmnan, 1977; Hezarkhani, 2006).

## ۳- دگرسانی

مشخص‌ترین سیمایی که در مورد بیشترین ذخایر گرمایی وجود دارد، بخش‌های دگرسانی است که به طور عمده توسط سیال‌های گرمایی ایجاد می‌شود و در بسیاری از موارد همراهی مشخصی بین این بخش‌ها و توده کانسار وجود دارد (Beane, 1995, 1981). در کانسارهای مس پورفیری تشکیل منطقه‌بندی در بخش‌های دگرسانی، مرهون اثرگذاری و فرایند مشترک محلول‌های گرمایی بالارونده و نیز آب‌های نفوذکننده جوی است (Burnham, 1979).

## ۳-۱. دگرسانی پتاسیک

دگرسانی پتاسیک یا به عبارت دیگر دگرسانی سیلیکات پتاسیم در اثر فرایند متاسوماتیسم پتاسیم به وجود می‌آید. در این نوع از دگرسانی، کمایش شسته شدن کلسیم و سدیم از سنگ‌های دارای کانی‌های آلومینوسیلیکاتی، امری رایج است. از

این صورت است که مجموعه‌ای از ورودی‌ها و خروجی‌های درست به شبکه داده می‌شود و شبکه عصبی با استفاده از این ورودی‌ها (مثال‌ها) مدل ریاضی پیچیده‌ای می‌سازد که در صورت دادن ورودی‌های جدید، پاسخ درستی را تولید می‌کند.

در حال حاضر تعداد بسیار زیادی قاعده یادگیری برای شبکه‌های عصبی وجود دارد که هیچ کس به طور دقیق تعداد آنها را نمی‌داند. اول باید دانسته شود که زمانی به فرایند یادگیری نیاز است که اطلاعات کامل در مورد اهداف، موجود نباشد. جایی که می‌دانیم به علت نبود قطعیت در شرایط محیطی، سامانه‌ای که دارای خواص یا پارامترهای ثابت باشد به طور کامل عمل کند رفتار سیستم‌های یادگیری توسط الگوریتم‌های بازگشتی بیان می‌شود. به همین خاطر به این الگوریتم‌ها، قوانین یادگیری اطلاق شده و عموماً توسط معادلات دیفرانسیلی بیان می‌شوند. طبقه‌بندی‌های مختلفی برای شبکه‌های عصبی وجود دارد ولی در حالت کلی دو نوع یادگیری موجود است که شامل (۱) تحت نظارت و (۲) بدون نظارت هستند.

در یادگیری نظارتی، به شبکه آموخته می‌شود که بین داده‌های آموزشی و خروجی‌های مربوطه ارتباط برقرار کند. در واقع یک معلم وجود دارد که در مرحله یادگیری به شبکه می‌گوید چقدر خوب کار می‌کند (تقویت یادگیری) یا می‌گوید رفتار صحیح چه باید باشد (یادگیری کاملاً نظارتی). در یادگیری بدون نظارت، شبکه خودکار عمل می‌کند. در این حالت شبکه فقط به داده‌هایی که به آن داده می‌شود نگاه می‌کند، سپس بعضی از ویژگی‌های مجموعه داده‌ها را پیدا کرده و یاد می‌گیرد که این ویژگی‌ها را در خروجی خود منعکس کند. این که این ویژگی‌ها به طور دقیق چه هستند، به مدل خاص شبکه و روش یادگیری بستگی دارد. نوع دیگر طبقه‌بندی بر اساس توپولوژی سلول‌ها به یکدیگر، در داخل شبکه است که به دو دسته تقسیم می‌شوند؛ شبکه‌های با تغذیه پیشرو و شبکه‌های با تغذیه برگشتی. در شبکه پیشرو، اطلاعات ورودی (Input) را وارد کرده و به لایه میانی (Hidden) و در نهایت به لایه خروجی (Output) می‌رود که جواب ما در آنجا دیده می‌شود. در این نوع توپولوژی، لایه‌ها عیناً به هم متصل هستند و حتماً باید یک پل ارتباطی بین آنها وجود داشته باشد و پرسشی نداریم. در این حالت، همیشه جهت اطلاعات از ورودی به خروجی است. در حالی که در شبکه برگشتی جهت جریان به صورت یک طرفه نیست بلکه چرخشی است. بیشتر شبکه‌های عصبی که امروز مورد استفاده قرار می‌گیرند از نوع اول یعنی تغذیه پیشرو هستند (Menhaj, 1379).

#### ۴-۱. شبکه عصبی RBPNN

– شبکه‌های عصبی RB: شبکه‌های عصبی RB به نسبت شبکه‌های پس انتشار نیاز به نرون‌های بیشتری دارند. اما حسن آنها، زمان طراحی کوتاه‌تر نسبت به شبکه‌های استاندارد پس انتشار است. این شبکه‌ها زمانی که بردارهای آموزشی بسیار زیاد هستند، دارای بهترین کارایی هستند.

این شبکه‌ها عموماً بر دو نوع کلی هستند: ۱- شبکه‌های رگرسیون (GRNN) و ۲- شبکه‌های احتمالی (PNN). البته توجه شود که نمی‌توان همیشه به جای شبکه‌های پس انتشار از شبکه‌های RB استفاده کرد زیرا تعداد نرون‌های شبکه RB بیشتر از شبکه‌های پس انتشار است.

چون شبکه‌های پس انتشار از توابع سیگموییدی به عنوان تابع انتقال استفاده می‌کنند به طوری که این توابع می‌توانند بر روی محدوده گسترده‌ای از فضای ورودی عمل نمایند، اما نرون RB می‌تواند روی فضای محدودی عکس‌العمل نشان داده و در نتیجه برای گسترش این فضا نیاز به نرون‌های بیشتری خواهد داشت. (Benediksson, 1990). از سوی دیگر، طراحی این شبکه‌ها نسبت به شبکه‌های پس انتشار، به زمان کمتر و حتی گاهی اوقات به تعداد نرون کمتری نیاز دارد.

نظر موقعیت، دگرسانی پتاسیک و بخش مربوطه در کانسار سونگون در هسته سیستم پورفیری منطقه و در واقع در زیر بخش فلیک قرار گرفته است (Hezarkhani, 1999). دگرسانی پتاسیک با کانی‌های فلدسپار پتاسیک، بلورهای نامنظم بیوتیت غنی از منیزیم و اندریت شناخته می‌شود. این دگرسانی ارتباط نزدیکی با کانی‌زایی دارد و شاید بیش از ۸۰٪ از مس و تمامی مولیبدن در نتیجه این دگرسانی جایگزین می‌شوند. به طور میانگین دگرسانی سنگ‌های پتاسیک شامل: ۲۸٪ پلاژیوکلاز، ۳۵٪ ارتوکلاز، ۲۰٪ کوارتز، ۱۵٪ کانی‌های مختلف دیگر (به طور عمده بیوتیت، سریسیت و کلریت) و ۲٪ کالکوپیریت، پیریت، تیتانیت، زیرکن، ثنلیت، بیسموتیت و روتیل می‌شود (Hezarkhani, 2006).

#### ۳-۲. دگرسانی فلیک

دگرسانی فلیک یا کوارتز سریسیت به صورت تأخیری، جایگزین بخش‌هایی از دگرسانی پتاسیک می‌شود. از ویژگی‌های این بخش، افزایش در میزان مسکوویت، احاطه شدن دانه‌های کوارتز به وسیله سریسیت، وجود پیریت (که بیش از ۵٪ حجم سنگ را تشکیل می‌دهد) و جایگزینی پیریت (بخشی از آن) توسط کالکوپیریت است. همزمان با دگرسانی فلیک، عمل سیلیسی شدن انجام می‌گیرد. تغییراتی که هنگام اعمال این دگرسانی در کانی‌ها رخ می‌دهد، به این صورت است که فلدسپارها در اثر دگرسانی فلیک به سریسیت و مقدار کمی رس دگرسان می‌شوند. در طی این دگرسانی، کانی‌های مافیک (بیوتیت و آمفیبول) به مسکوویت و سریسیت تبدیل می‌شوند. در بخش فلیک، پولک‌ها و ورقه‌های بیوتیت به طور کامل به مسکوویت تبدیل شده و آهن آزاد شده از آنها به صورت سولفیدی در امتداد رخ آنها همراه با روتیل آزاد شده از بیوتیت دیده می‌شوند (Calagari, 2004).

بخش فلیک سونگون با حضور کانی‌های کوارتز ثانویه، سریسیت و پیریت و پتاسیم فلدسپار و آلپیت ثانویه شناخته می‌شود. کلسیت به مقدار فراوان و کلریت به مقدار کم در این بخش یافت می‌شود. مسکوویت کانی فرعی دیگری است که بیشتر، از دگرسانی آمفیبول و کمتر از دگرسان شدن پلاژیوکلاز و پتاسیم فلدسپار اولیه تشکیل شده است. این کانی، بیشتر در همراهی با سریسیت دیده می‌شود (Emami, 1991) (شکل ۲).

#### ۳-۳. بخش هیپوزن سونگون

کانسار سونگون شامل چهار نوع دگرسانی هیپوزن است: ۱- پتاسیک ۲- پتاسیک - فلیک ۳- فلیک ۴- پروپلیک (معمولاً در پایین‌ترین محل (از نظر ژرفا) در بین دگرسانی‌ها قرار می‌گیرد) (Hezarkhani, 1999). کانی‌های موجود در این بخش، شامل سولفیدها (پیریت، کالکوپیریت، مولیبدنیت)، کوارتز، کلسیت و اندریت (به صورت ژپس) است. کالکوپیریت کانه چیره مس است و مولیبدنیت، برنیت، کالکوسیت و تتراهدريت در مقادیر خیلی کم وجود دارند. حدود ۲ تا ۳٪ از حجم سولفیدها، در این بخش قرار دارد. کانی‌زایی هیپوزن مس به‌طور عمده در طول دگرسانی پتاسیک و به‌طور کمتر در طول دگرسانی فلیک انجام شده است (Hezarkhani, 1999). هیپوزن مولیبدن به طور عمده در بخش‌های ژرف استوک تشکیل شده و بیشتر با دگرسانی پتاسیک در ارتباط است (شکل ۲).

#### ۴- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی در واقع از ساختارهای بسیار پیچیده مغز انسان الهام گرفته شده است که در آن میلیون‌ها سلول عصبی از طریق ارتباطی که با هم دارند به حل مسائل یا ذخیره‌سازی اطلاعات می‌پردازند. وظیفه شبکه عصبی یادگیری است. در این فرایند ابتدا از طریق آموزش یا همان مرحله کسب تجربه که به کمک یک سری داده‌های ورودی و خروجی مطلوب انجام می‌پذیرد، اجرا می‌شود. آموزش به

شبکه وارد می‌شود و شبکه با این داده‌ها به بررسی ساختار داده‌ها پرداخته و ارتباط فضایی آنها را بررسی می‌کند. در این حالت تعداد دوره‌های آموزشی ۱۵۰۰ دوره در نظر گرفته شد که بیانگر تعداد دوره‌های ارائه داده‌ها و آموزش شبکه است. در این نوع خاص، شبکه فاصله میان ورودی‌ها و خروجی‌ها را محاسبه کرده و بر حسب مقادیر به دست آمده ارزش‌های احتمالی را محاسبه می‌کند. پس از آموزش و حصول از کارکرد شبکه، می‌توان شبکه را برای ۲۰٪ داده باقیمانده امتحان کرد.

در مرحله امتحان، شبکه توانست حدود ۹۸٪ داده‌ها را به درستی طبقه‌بندی کرده و بتواند کلاس آنها را تشخیص بدهد. نتایج به دست آمده دارای مقدار MSE برابر با ۰/۱۶۳ است. با توجه به نتایج به دست آمده می‌توان گفت که شبکه طوری ایجاد شده است که بتواند عکس‌العمل مناسبی به داده‌هایی غیر از داده‌های آموزشی نشان بدهد و در اصطلاح، شبکه دارای عمومیت مناسبی است.

## ۶- بحث و نتیجه‌گیری

بر اساس نتایج به دست آمده از تفکیک بخش‌های دگرسانی، شبکه توانست حدود ۹۸٪ داده‌های آموزشی را به درستی طبقه‌بندی کند. در مورد احتمال کلاس‌بندی نادرست که مربوط به بخش دگرسانی انتقالی می‌باشد، به این علت است که این بخش دگرسانی منطقه‌ای بین دو دگرسانی پتاسیک و فلیک قرار داشته و تجزیه نمونه‌های مربوطه می‌تواند در بعضی از عناصر مشابه بخش‌های بالایی یا پایینی آن دگرسانی باشد. بنابراین در طبقه‌بندی این بخش ممکن است مشکل پیش بیاید.

همان‌طور که می‌دانیم، در تبدیل دگرسانی‌ها به هم، یک مرز مشخص و بارزی که آنها را از هم جدا کند وجود ندارد. به طور کلی در بین بخش پتاسیک و فلیک، یک بخش بینایی یا انتقالی را در نظر می‌گیرند. در شکل ۴ می‌توان جواب شبکه را برای امتحان داده‌های امتحان و خروجی آن را برای دو ورودی که به صورت تصادفی انتخاب شده اند، دید.

در شکل‌های بالا، به علت گسترده بودن فضای داده‌های ورودی، سعی شده است با تغییر مقیاس محورهای مختصات بیشترین داده‌های ورودی را نمایش داد. بعضی از داده‌ها که خارج از این بازه بوده‌اند در شکل مشخص نیستند که البته به علت عدم تأثیر آن نمونه نیست بلکه خارج کردن آن به منظور نمایش بیشترین تعداد نمونه‌ها است. علت این امر، تعداد زیاد داده‌های ورودی است که منجر به چندبعدی بودن فضای ورودی‌ها شده است. بنابراین فقط برای تجسم شیوه پراکندگی کلاس‌های مختلف، از نمودار دوبعدی استفاده شده است. ویژگی آماری داده‌های مورد استفاده در این نوشتار، در جدول ۱ آورده شده است که بیانگر بیشینه، کمینه، میانگین و واریانس داده‌های ورودی است.

پس از اطمینان از کارکرد مناسب شبکه، می‌توان محیط مورد بررسی را برای داده‌های ورودی از لحاظ تقسیم‌بندی فضایی بررسی کرد. بدین صورت که با رسم سه‌بعدی توزیع عناصر در این حالت می‌توان پراکندگی آنها را دید. این نمودارها را در شکل ۵ می‌بینید. این نمودارها بر اساس نتایج حاصل از خروجی شبکه عصبی و تفکیک دگرسانی‌ها رسم شده است. همان‌طور که دیده می‌شود، شبکه بر اساس داده‌های موجود توانسته است مناطق دگرسانی را به خوبی جداسازی نماید که باز به علت چندبعدی بودن داده‌های ورودی در سه شکل اول فقط سه‌بعد و در شکل ۵- در نیز فقط دو بعد در نظر گرفته شده است. همان‌طور که اشاره شد اصولاً طراحی شبکه‌های عصبی بر اساس تجربه کاربر و سعی و خطا است که پس از طی این مراحل و رسیدن به مقادیر مطلوب یاد شده می‌توان از شبکه آموزش دیده به نحو مطلوب استفاده کرد.

بر اساس مطالعات انجام شده در این نوشتار، در استفاده از شبکه‌های عصبی

– **ساختار شبکه PNN:** از شبکه‌های عصبی PNN در مورد مسائل طبقه‌بندی شده استفاده می‌شود. زمانی که بردار ورودی به شبکه اعمال می‌شود، لایه اول فاصله‌برداری را از ورودی‌های آموزشی محاسبه می‌کند و به این ترتیب برداری را فراهم می‌آورد که عناصر آن تعیین کننده میزان فاصله بین ورودی و ورودی آموزشی هستند. لایه دوم با استفاده از خروجی لایه اول برداری از احتمال‌ها را به عنوان خروجی شبکه تولید می‌کند. در نهایت، تابع انتقالی رقابتی (Compete) موجود در لایه دوم بیشترین مقدار احتمال‌ها را از بردار احتمال‌ها انتخاب می‌کند و به ازای آن خروجی ۱ و به ازای بقیه احتمال‌ها خروجی صفر را تولید می‌کند. ساختار این نوع شبکه در شکل ۳ نشان داده شده است (Yiu, 1999).

در اینجا فرض می‌شود که بردارهای ورودی دارای L کلاس متفاوت هستند. بنابراین، هر بردار هدف دارای L عنصر است که یکی از آنها ۱ و بقیه صفر هستند. وزن‌های ورودی لایه اول  $IW^{11}$  برابر ترانهاده ماتریس Q قرار داده می‌شود. ماتریس Q از زوج‌های آموزشی (ورودی / هدف) تشکیل شده است. زمانی که یک بردار ورودی به جعبه  $||dist||$  اعمال می‌شود فاصله آن از کلیه بردارهای آموزشی تعیین می‌شود و مشخص می‌شود که ورودی به کدام یک از این بردارهای آموزشی نزدیک‌تر است. حاصل کار، به صورت عنصر به عنصر در بایاس ضرب شده و به تابع انتقال radbas اعمال می‌شود. در نتیجه به ازای بردار ورودی نزدیک به بردار آموزشی مقدار ۱ توسط این تابع تولید می‌شود. در صورتی که ورودی دارای فاصله یکسانی با چند ورودی آموزشی باشد، به این ترتیب خروجی  $a^1$  دارای چند ۱ خواهد بود.

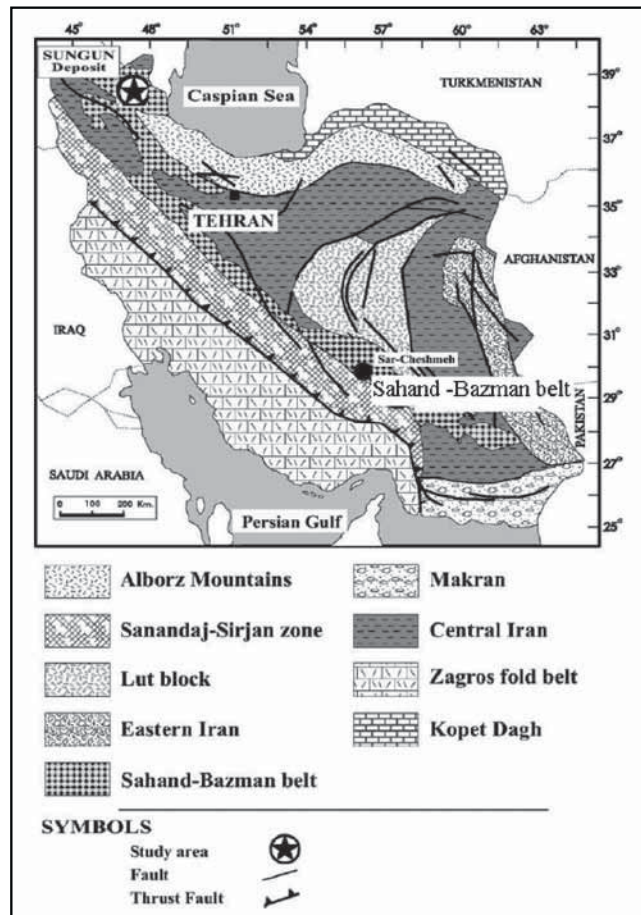
وزن‌های لایه دوم  $(LW^{12})$  برابر ماتریس T از بردارهای هدف قرار داده می‌شود. هر بردار تنها دارای یک مقدار ۱ متناظر با کلاس مربوط به آن است و بقیه مقادیر صفر هستند. مقدار  $n^2$  در لایه دوم از ضرب T در  $a^1$  به دست می‌آید و در نهایت  $n^2$  به تابع انتقال رقابتی لایه دوم اعمال می‌شود. این تابع به ازای بزرگ‌ترین مقدار موجود در  $n^2$  مقدار ۱ و به ازای بقیه مقادیر صفر تولید می‌کند. بنابراین شبکه بردارهای ورودی را به یکی از L کلاس موجود که دارای بیشترین احتمال است نظیر می‌کند (Leszek, 2004).

## ۵- روش کار

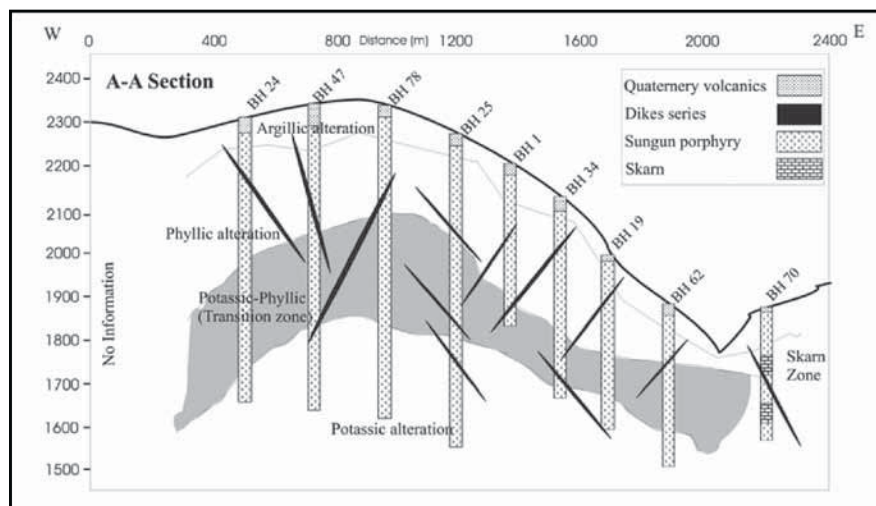
طبق مدل شبکه عصبی مطرح شده، داده‌های مورد استفاده برای انجام طبقه‌بندی آماده شدند. بدین صورت که داده‌های ورودی به شکل ماتریسی حاوی تجزیه شیمیایی ۱۲ اکسید و ۱۶ عنصر (۲۸ متغیر) برای ۴۵ نمونه و در سه نوع دگرسانی پتاسیک، انتقالی و فلیک هستند. داده‌های خروجی نیز، برابر نوع کلاس قرارگیری هر کدام از نمونه‌های مورد استفاده قرار داده شد. در این نوع خاص خروجی، همان طور که پیش‌تر نیز شرح داده شد، ماتریس خروجی شبکه برای هر ورودی دارای سه آرایه بوده که فقط یکی از آنها که مربوط به نوع کلاس دگرسانی است، یک و بقیه آرایه‌ها صفر در نظر گرفته شد. نحوه آموزش شبکه به این صورت بوده که از میان این تعداد نمونه‌ها حدود ۸۰٪ برای آموزش و ۲۰٪ برای تست شبکه مورد استفاده قرار گرفت. لازم به یادآوری است، از آنجایی که بعضی از متغیرهای ورودی دارای واریانس زیادی بوده که این عامل بر کارایی شبکه تأثیرگذار است، بنابراین تمام داده‌های موجود در فاصله [0 1] به‌نجار شدند. البته یکی دیگر از دلایلی که از داده‌های به‌نجار شده برای شبکه استفاده شد این است که با این فرم داده‌ها، شبکه در یافتن ارتباط فضایی بین متغیرها موفق‌تر بوده و فضای جستجو فقط به آن بازه خاص معطوف خواهد شد. شبکه تا رسیدن به کمترین میانگین مربعات خطا (MSE) آموزش داده شد. فاز آموزش شبکه به این صورت بود که ابتدا داده‌های آموزشی به

کرد. این خاصیت شبکه‌های عصبی برای جایگزینی تجربیات و توانایی‌ها طراحی نشده است، بلکه فقط ابزاری است برای راحتی کار و کاهش هزینه، مانند تجزیه و نیز گریز از کارهای اضافی آزمایشگاهی. این سامانه به عنوان وسیله‌ای جدید برای نمایش عددی دگرسانی‌ها و ویژگی‌های آنها است که با گسترش بانک اطلاعاتی آن، می‌تواند در آینده با قطعیت بیشتری مورد استفاده قرار گیرد.

نوع PNN و اثبات توانایی آن در تفکیک دگرسانی‌ها، دگرسانی‌های پیچیده موجود در کانسار مس پورفیری سونگون تفکیک شد. شبکه توانست رابطه فضایی پیچیده بین ورودی‌ها را تشخیص داده و آنها را به درستی طبقه‌بندی کند. بدین صورت که مقدار MSE برابر ۰/۰۱۶۳ به دست آمد که حاکی از کارکرد مطلوب شبکه در این امر است، به طوری که می‌توان از آن برای تعیین کلاس نمونه‌های جدید استفاده

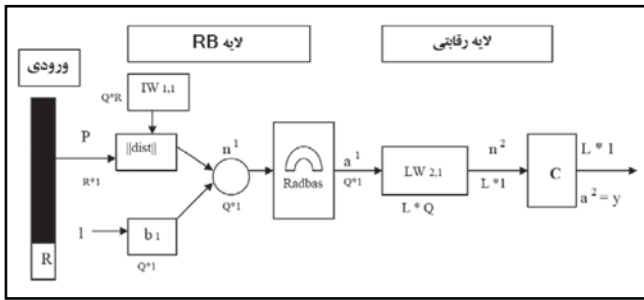


شکل ۱- نقشه زمین‌شناسی ایران و موقعیت کانسار مس پورفیری سونگون (Hezarkhani, 2006)



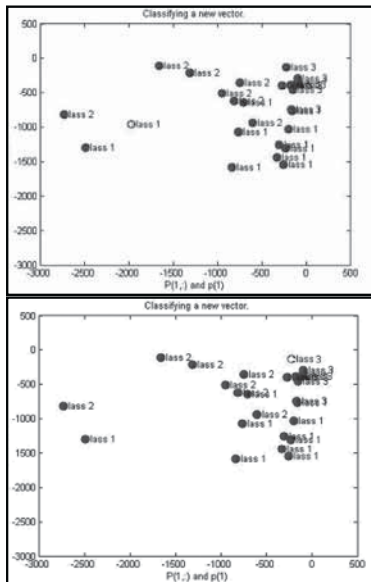
شکل ۲- نمایی از دگرسانی‌های موجود در منطقه از یک مقطع خاص (Asghari, 2008)

جدول ۱- ویژگی‌های آماری داده‌های مورد استفاده در این نوشتار که بیانگر بیشینه، کمینه، میانگین و واریانس داده‌های ورودی است.

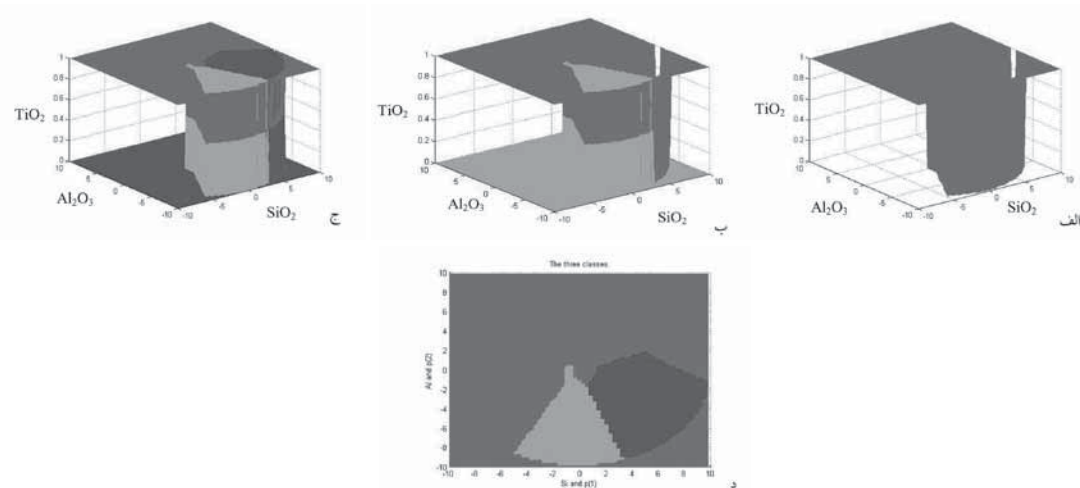


شکل ۳- ساختار شبکه RBPNN (Radial Basis Probabilistic Neural Network) در تعداد عناصر داده‌های ورودی،  $Q$  زوج‌های آموزشی ورودی/هدف یا تعداد نرون‌ها در لایه اول و  $L$  تعداد کلاس‌های داده‌های ورودی یا تعداد نرون‌های لایه دوم (Karayiannis & Weiquan, 1997)

عناصر	بیشینه	کمینه	واریانس	میانگین
SiO <sub>2</sub>	72.38	49.21	30.78	63.23
TiO <sub>2</sub>	0.99	0.39	0.01	0.59
Al <sub>2</sub> O <sub>3</sub>	18.84	12.99	1.20	15.63
Fe <sub>2</sub> O <sub>3</sub>	7.20	0.07	3.88	3.67
MnO	0.14	0.01	0.00	0.05
MgO	5.62	0.66	1.25	2.16
CaO	7.58	0.28	3.69	3.08
Na <sub>2</sub> O	6.03	0.00	3.03	2.23
K <sub>2</sub> O	6.94	1.65	1.77	4.02
P <sub>2</sub> O <sub>5</sub>	0.51	0.12	0.00	0.27
BaO	2044.00	3.63	286722.09	754.41
Ce	215.00	14.00	1408.55	77.92
Co	45.00	0.00	114.69	15.44
Cr <sub>2</sub> O <sub>3</sub>	279.00	26.00	3225.47	83.45
Cu	16024.00	37.00	18338052.43	3232.30
Ni	154.00	12.00	956.74	48.55
Sc	27.00	0.00	68.43	9.44
V	185.00	17.00	1384.47	87.82
Zn	2353.00	0.00	398260.10	426.37
Ga	39.00	0.00	50.15	14.27
Nb	23.00	5.00	21.25	14.31
Pb	35.00	8.80	28.96	15.35
Rb	124.80	34.00	593.06	82.27
Sr	1334.00	49.00	125801.09	509.80
Th	27.00	0.00	42.20	14.28
U	10.00	0.00	4.17	1.05
Y	22.00	2.00	24.11	12.68
Zr	169.00	88.70	469.68	124.67



شکل ۴- نتایج حاصل از داده‌های تست شبکه که آنها را بر حسب ورودی به کلاس‌های تشخیص داده اختصاص می‌دهد. کلاس ۱: پتاسیک، کلاس ۲: انتقالی و کلاس ۳: فیلیک



شکل ۵- توزیع‌های فضایی در حالت سه‌بعدی برای عناصر SiO<sub>2</sub>، TiO<sub>2</sub> و Al<sub>2</sub>O<sub>3</sub>; "الف" برای بخش پتاسیک، "ب" بخش‌های پتاسیک و انتقالی، "ج" سه بخش پتاسیک، انتقالی و فیلیک و "د" حالت دوبعدی توزیع سه دگرسانی بر حسب عناصر SiO<sub>2</sub> و Al<sub>2</sub>O<sub>3</sub>.

## References

- Arbogast, J. & Franklin, M., 1999- Artificial Neural Networks and high speed resistivity modeling software speed reservoir characterization, *Petroleum Engineering International*, 75, 2.
- Beane, R. E. & Bodnar, R. J., 1995- Hydrothermal fluids and hydrothermal alteration in porphyry copper deposits. In: Wahl, P.W., Bolm, J.G. (Eds.), *Porphyry Copper Deposits of the American Cordillera*, Tucson, Arizona, Arizona Geological Society, Arizona, pp. 83–93.
- Beane, R. E. & Titley, S. R., 1981- Porphyry copper deposits, alteration and mineralization, part II. *Economic Geology* 75, 235–269.
- Benediksson, H., Swain, P. H. & Y Ersoy, O. K., 1990- Neural network approach versus statistical method in classification of multisource remote sensing data. *IEEE Transaction on Geoscience and remote sensing*, 28, 540-551.
- Burnham, C. W., 1979- *Magma and hydrothermal fluids: in Geochemistry of Hydrothermal ore deposits*, H. L. Barnes, Jon Wiley & sons, Inc., p. 71- 136.
- Calagari, A. A., 2004- Fluid inclusion studies in quartz veinlets in the porphyry copper deposit at Sungun, East-Azarbaidjan, Iran, *Journal of Asian Earth Sciences* 23, p. 179–189.
- Emami, M. H., Babakhani, A. R., 1991- Studies of geology, petrology, and litho-geochemistry of Sungun Cu–Mo deposit, Iranian Ministry of Mines and Metals, p. 61.
- Etmiman, H., 1977- The discovery of porphyry copper–molybdenum mineralization adjacent to Sungun village in the northwest of Ahar and a proposed program for its detailed exploration. Confidential Report, Geological Report, Geological Survey of Iran, p. 26.
- Guo, J. J., Luh, P. B., 2003- Selecting Input Factors for Clusters of Gaussian Radial Basis Function Networks to Improve Market Clearing Price Prediction, *IEEE Trans. On Power systems Part B: Cybernetics*, Vol. 18, No. 2, pp. 665-672.
- Hezarkhani, A., 2006- petrology of intrusive rocks within the Sungun Porphyry Copper Deposit, Azarbaijan, Iran, *Asian Earth Science* p.p. 329-330.
- Hezarkhani, A., Williams-Jones, A. E. & Gammons, C. H., 1999- Factors controlling copper solubility and chalcopyrite deposition in the Sungun porphyry copper deposit, Iran. *Mineralium deposita*, vol. 34, pp. 770-783.
- Hezarkhani, A., Williams-Jones, A. E., 1998- Controls of alteration and mineralization in the Sungun porphyry copper deposit, Iran: Evidence from Fluid Inclusion and Stable Isotopes. *Economic Geology*, Vol. 93, pp. 651-670.
- Ke, J., 2002- Neural network modeling of placer ore grade spatial variability: Unpublished Doctoral Dissertation, University of Alaska Fairbanks, 251 p.
- Karayiannis, N. B., Weiqun, M. G., 1997- Growing Radial Basis Neural Networks: Merging Supervised and Unsupervised Learning with Network Growth Techniques *IEEE Trans. on Neural Networks*, Vol. 8, No. 6, pp. 1492-1506.
- Koike, K., Matsuda, S., Suzuki, T. & Ohmi, M., 2002- Neural network-based estimation of principal metal contents in the Hokuroku district, Northern Japan, for exploring Kuroko-type deposits: *Nat. Resour. Res.*, v. 11, no. 2, p. 135–156.
- Leszek, R., 2004- Adaptive Probabilistic Neural Networks for pattern Classification in Time-Varying Environment, *IEEE TRANSACTIONS ON NEURAL NETWORKS*, VOL. 15, NO.4, pp. 11-827.
- Menhaj, M. B., artificial intelligent, 1379- Amirkabir university of technology publication, Tehran, first edition.
- Wu, X. & Zhou, Y., 1993- Reserve estimation using neural network techniques: *Comput. Geosci.*, v. 9, no. 4, p. 567–575.
- Asghari, O. & Hezarkhani, A., 2008- The comparison between the alteration zones in the Sungun porphyry copper deposit (based on the Fluid inclusion investigations), *Acta Geologica Hungarica*. (in press).
- Yama, B. R. & Lineberry, G. T., 1999- Artificial neural network application for a predictive task in Mining: *Mining Eng.*, v. 51, no. 2, p. 59–64, .
- Yiu, K. K., Mak, M. W. & Li, C. K., 1999- Gaussian mixture models and probabilistic decision-based neural network for pattern classification: A comparative Study”, *Neural Computing and Applications* 8(3): pp. 235- 45.

## Mesorbitolinas of Dariyan Formation in Dashtak Stratigraphic Section, North of Shiraz

F. Safari<sup>1</sup>, M. Yazdi-Moghadam<sup>2</sup>, F. Sajjadi<sup>\*</sup>

<sup>1</sup> College of Science, Faculty of Geology, Tehran University, Tehran, Iran

<sup>2</sup> N.I.O.C Exploration Directorate, Tehran, Iran

Received: 2008 July 26

Accepted: 2009 February 22

### Abstract

To recognize different species of the genus *Orbitolina* and determine the age of the Dariyan Formation, the upper limy part of the Dariyan Formation in Dashtak section was sampled and studied. Based on the size, shape and complexity of embryonic apparatus, five species belonging to subgenus *Mesorbitolina* were recognized as below: *Orbitolina (Mesorbitolina) lotzei*, *Orbitolina (M.) parva*, *Orbitolina (M.) texana*, *Orbitolina (M.) subconcava*, *Orbitolina (M.) sp. cf. M. pervia*. According to stratigraphic distribution of the mesorbitolinids, the upper part of the Dariyan Formation can be ascribed to the late early Aptian-late Aptian. The early/late Aptian boundary coincides with first occurrence of *O. (M.) parva*

**Keywords:** *Mesorbitolina*, Aptian, Dariyan Formation, Dashtak stratigraphic section, North of Shiraz

For Persian Version see pages 31 to 40

\* Corresponding author: F. Sajjadi; E\_mail: sajjadi@khayam.ut.ac.ir

## Separating the Sungun Copper Deposit Alteration Zones by Applying Artificial Neural Network

A. Hezarkhani<sup>1\*</sup>, P. Tahmasbi<sup>1</sup> & O. Asghari<sup>2</sup>

<sup>1</sup>Mining Engineering Department, Metallurgy and Petroleum, Amirkabir University of Technology, Tehran, Iran.

<sup>2</sup>Faculty of Mining Engineering, University of Kashan, Kashan, Iran.

Received: 2008 September 13

Accepted: 2009 July 18

### Abstract

Separation of alteration zones is one of the important processes in evaluation and identification of mining activities that provide great help to have better view of the region and its mineralization. Most of the alteration separation is based on petrological investigations and the other methods are less applied. Therefore, in this research, there is an attempt by applying RBPNN (Radial Basis Probabilistic Neural Network) to separate these alteration zones. Because of the special structure and easy designing of these networks, they are usually capable to solve the classification problem. The input data were 28 element analyses related to 45 geochemical samples and its outputs were classified alteration zones (potassic, transition, phyllic) that was coding for every inputs data. After selection the training and testing data, the network has been prepared for training and then the data were inputs and the results were outputs. According to the results, the network could distinguish the difficult spatial relation between the inputs, with 28 spatial variables and classify those correctly. The calculated MSE (Mean Square Error) is 0.0163, which shows the good performance of network in this field.

**Key words :** Artificial neural networks, Alteration, Discriminate, Probabilistic, Sungun

For Persian Version see pages 41 to 46

\*Corresponding author: A. Hezarkhani; E- mail: Ardehz@cic.aut.ac.ir