

کاربرد شبکه‌های عصبی در تهیه نقشه پتانسیل معدنی: مطالعه موردی کانی‌زایی

پروتروزوییک در منطقه ساغند- چادرمالو، ایران مرکزی

نوشته : دکتر پوران بهنیا*

Application of Neural Networks to Mineral Potential Mapping; a Case Study on Proterozoic Mineralization in Saghand-Chadormalu Area, Central Iran

By : Dr. P. Behnia*

چکیده

ایران مرکزی دارای کانسارهای متعددی از آهن، آپاتیت و اورانیم به سن پروتروزوییک است. در این مطالعه، به منظور تهیه نقشه پتانسیل معدنی برای کانی‌زایی تپ اکسید آهن (Cu-U-Au-REE) پروتروزوییک، از سامانه شبکه‌های عصبی استفاده شد. سامانه استفاده شده نوعی شبکه عصبی به اسم RBFLN است که شکل تغییر یافته‌ای از شبکه عصبی بر پایه تابع شعاعی (RBFNN) می‌باشد. در این مطالعه داده‌های چینه شناسی، ساختاری، ژئوفیزیکی و ژئوشیمیایی به عنوان بردارهای چند بعدی وارد شبکه عصبی شدند. به منظور یادگیری شبکه از ۵۸ کانسار و ۵۸ غیرکانسار استفاده شد. برای تهیه نقشه‌های ورودی از دو روش استفاده شد. در روش اول تلفیقی از نقشه‌های چند کلاسه و دو کلاسه وارد شبکه عصبی شد. در روش دوم تمام نقشه‌های نشانگر به نقشه‌های دو کلاسه دسته بندی شدند. اعمال RBFLN بر روی داده‌های ورودی مختلف نشان داد که افزایش تعداد نقشه‌های ورودی و در نتیجه افزایش تعداد کلاسها منجر به بالا رفتن خطای مجموع مربعا (SSE) دسته بندی می‌شود. به طور کلی تکرار دفعات یادگیری باعث بهبود خطای SSE در حین یادگیری می‌شود. نتیجه این مطالعه همچنین نشان داد که پراکندگی مناسب نقاط کانساری و غیر کانساری و فراوانی آنها نسبت به هم تاثیر زیادی در نتیجه دسته بندی می‌گذارد.

کلید واژه‌ها: شبکه‌های عصبی، نقشه پتانسیل معدنی، GIS، RBFLN

Abstract

The metallogeny of Central Iran is mainly characterized by the presence of several iron, apatite, and uranium deposits of Proterozoic age. Neural network method is used as a data-driven method for GIS-based predictive mapping of Proterozoic iron oxide (Cu-U-Au-REE) mineralization in Central Iran. The radial based function link network (RBFLN) which is a modification of radial basis function neural networks (RBFNN) is employed as a neural network system. The evidential maps comprising of stratigraphic, structural, geophysical, and geochemical maps are used as n-dimensional vectors input to the RBFLN. A number of 58 deposits and 58 non-deposits are employed to train the network. The operations for the application of neural networks applied in this study involve both multiclass and binary representation of evidential maps. Running RBFLN on different input data shows that the increase in the number of evidential maps and classes leads to higher classification sum of squared error (SSE). As a whole the increase in the number of iterations results in the improvement of training SSE. The results of applying RBFLN show that a successful classification depends on the existence of well distributed deposit and non-deposit sites through the study area.

Key words: Neural Networks, Mineral Potential Map, RBFLN, GIS

مقدمه

نام وزنه‌های سینوئسی برای ذخیره دانش به کار می‌روند. شبکه‌های عصبی، توان زیادی در حل مسائل پیچیده‌ای دارند که عوامل متعددی در فرایند و نتیجه آن تأثیر می‌گذارند. وجود یک کانسار، به وسیله متغیرهای زمین

شبکه‌های عصبی سامانه‌هایی رایانه‌ای هستند که از روی سامانه مغز انسان طراحی شده‌اند و از دوجنبه شبیه مغز انسان هستند. اول این که دانش در آنها از راه یادگیری کسب می‌شود و دوم این که توانهای ارتباطی بین نرونی به

Darken & Moody (1988) و Lowe & Broomhead (1988) مطرح شد. همان طور که از نام آن برمی آید، این شبکه از توابع شعاعی به عنوان تابع محرک استفاده می کند (شکل ۱). ساختار این شبکه ساده و یادگیری آن سریع تر از شبکه های پرسپترون چند لایه (MLP) است. این شبکه ها به عنوان حد واسط بین سامانه های استنتاجی فازی (FIS) و شبکه های عصبی در نظر گرفته می شوند. یک تابع شعاعی با مرکزیت v و پارامتر انتشار σ بر روی بردارهای N -بعدی x معمولاً به صورت زیر بیان می شود:

$$y = f(x; v) = \exp[-\|x-v\|^2 / (2 \sigma^2)] \quad (1)$$

تمام نقاط هم فاصله از v مقادیر y یکسانی را به دست می دهند. در شکل ۲ یک شبکه RBFNN که در آن لایه ورودی دارای N گره، لایه مخفی دارای M گره و لایه خروجی دارای J گره است، نشان داده شده است (Looney, 2002). با فرض اینکه x بردار ورودی با مولفه های x_1, \dots, x_N باشد، خروجیهای قابل قبول از m امین گره لایه مخفی و j امین گره لایه خروجی برای q امین بردار ورودی $x^{(q)}$ به صورت زیر است:

$$y_m^{(q)} = \exp[-\|x^{(q)} - v^{(m)}\|^2 / (2 \sigma_m^2)] \quad (\text{الف})$$

$$z_j^{(q)} = (1/M) \left[\sum_{m=1, M} u_{mj} y_m^{(q)} + b_j \right] \quad (\text{ب})$$

که در آن $M = 1, \dots, M$ و $J = 1, \dots, J$ است. u_{mj} وزنه های به دست آمده در روی خطوطی است که از لایه مخفی به لایه خروجی کشیده شده اند. RBFNN برای تبدیل ورودی به خروجی از مدل غیر خطی استفاده می کند.

Looney (2002) ساختار تغییر یافته ای از RBFNN را به نام RBFLN معرفی کرد. اختلاف اساسی RBFLN با RBFNN وجود خطوط رابط اضافی است که مستقلاً لایه ورودی را به لایه خروجی وصل می کنند (شکل ۳). در نتیجه RBFLN گذشته از مدل غیر خطی RBFNN، شامل یک مدل خطی اضافی نیز است. این خطوط و وزنه های اضافی، کار قسمت خطی تبدیل ورودی - خروجی را انجام می دهد و در نتیجه نیازی نیست که این قسمت توسط بخش غیر خطی به تقریب محاسبه شود. مؤلفه های خروجی RBFLN در معادله (ب) متفاوت با RBFNN بوده و به صورت زیر داده می شود:

$$z_j^{(q)} = [1/(M+N)] \left\{ \sum_{m=1, M} u_{mj} y_m^{(q)} + \sum_{n=1, N} w_{nj} x_n^{(q)} \right\} \quad (3)$$

یادگیری کامل RBFLN شامل دو مرحله است: اول تشکیل اولیه مراکز، پارامترهای انتشار و وزنها و دوم اصلاح پارامترها و وزنها برای کمینه کردن خطای کل مجموع مربعا (TSSE) که جمع کل خطاهای SSE بخشی

شناختی متعدد و مرتبطی کنترل می شود در نتیجه یکی از کاربردهای شبکه عصبی می تواند در زمینه تهیه نقشه های پتانسیل معدنی باشد. شبکه های عصبی معمولاً شامل یک دسته لایه های مرتبط هستند که هر یک از لایه ها دارای واحدهای پردازش اصلی به نام نورون (سلول عصبی) می باشند. بر اساس یک مدل پذیرفته شده (Pan & Harris, 2000) هر نورون از سه قسمت اساسی تشکیل شده است: ۱) مجموعه ای از سیناپسها یا حلقه های مرتبط که هر کدام یک ورودی را به یک وزن سیناپسی مرتبط می کند، ۲) یک افزایشگر (جمع کننده) که ورودیهای وزن دار را جمع می کند و ۳) تابع محرکی که ورودیهای جمع شده را به خروجیها تبدیل می کند. در این مدل، یک نورون p ورودی دریافت می کند $z_i, i=1, \dots, p$ ، هر یک از ورودیها را در یک وزن سیناپسی، w_i ضرب می کند و سپس این ورودیهای وزن دار را جمع کرده و $s = \sum_i w_i z_i$ را به دست می دهد. این حاصل جمع وزن دار، سپس وارد یک تابع محرک $f(s; T)$ شده و خروجی y را به دست می دهد.

شبکه های عصبی بر حسب تعداد نورونها، روش ارتباط نورونها، شکل تابع محرک و الگوریتم یادگیری با یکدیگر متفاوت هستند. یک شبکه قبل از تفسیر اطلاعات جدید باید ابتدا مورد آموزش یا یادگیری قرار گیرد. در الگوریتم پس انتشار (Back Propagation) یادگیری شبکه به این صورت است که داده ها در طول شبکه پردازش می شوند تا این که به لایه خروجی برسند (گذر رو به جلو) در این لایه، خروجی به دست آمده با مقدار خروجی اندازه گیری شده (واقعی) مقایسه می شود. اختلاف یا خطای بین این دو، مجدداً در جهت عکس پردازش می شود (گذر رو به عقب) و وزنه های ارتباطی و بایاس (bias) هر یک از نورونها تجدید می شود. این فرایند برای تمام داده های ورودی و خروجی تا آنجا تکرار می شود که خطای شبکه به یک حد آستانه کمینه که معمولاً خطای مجموع مربعا (SSE) است، نزدیک شود.

در مطالعه حاضر از شبکه عصبی RBFLN (Radial Basis Functional Link Nets) (Looney, 2002) که شکل تغییر یافته ای از شبکه عصبی بر پایه تابع شعاعی (Radial Basis Function Neural Networks: RBFNN) است، برای تهیه نقشه پتانسیل معدنی استفاده شده است. GIS مورد استفاده شامل ArcView، Arc/Info و Spatial Analyst از محصولات ESRI است. به علاوه از Arc-SDM (Kemp et al., 2001) که قابل اجرا در ArcView است، برای مدل سازی و تحلیل شبکه عصبی استفاده شده است.

شبکه های عصبی با تابع شعاعی (RBFNN) و شبکه های RBFLN

شبکه های عصبی بر پایه تابع شعاعی (RBFNN) توسط

۱۶۱ و ردیفهای ۳۷ و ۳۸ اخذ شده در تاریخ ۱۴ اوت ۲۰۰۰، نتایج تجزیه شیمیایی ۱۳۸۴ نمونه آبرفتی برای عناصر Ba, Cu, Co, As, Ag, Au, Zn و Pb (سازمان زمین شناسی کشور) و اطلاعات مربوط به کانسارها و رخدادهای شناخته شده در منطقه است. بر روی داده‌های یاد شده با توجه به مدل مفهومی کانسار برای به دست آوردن معیارهای اصلی کانی‌زایی پردازشهای مختلف صورت گرفته (بهینا، ۲۰۰۴) و آماده مدل سازی در محیط GIS شدند. نقشه‌های نشانگری که به عنوان ورودی در شبکه عصبی از آنها استفاده شد، شامل نقشه‌های زمین‌شناسی بستر، نزدیکی به ساختارهای عمیق حاصل از تفسیر داده‌های مغناطیس هوایی، نزدیکی به گسلها و شکستگیهای حاصل از تفسیر تصاویر ماهواره‌ای، مغناطیس هوایی، نسبتهای پرتوسنجی Th/K, U/Th, U/K و نقشه‌های بی‌هنجاری ژئوشیمیایی برای عناصر Au, Ag, As, Co, Cu, Ba, Pb, Zn است. برای تهیه نقشه پتانسیل معدنی از دو روش استفاده شد. در روش اول تلفیقی از نقشه‌های چند کلاسه و دو کلاسه به عنوان نقشه‌های نشانگر مورد استفاده قرار گرفتند. نقشه زمین‌شناسی براساس مدل کانساری به ۷ کلاس طبقه‌بندی شد (شکل ۴-د) و داده‌های ژئوفیزیکی (نسبت U/Th, U/K و نقشه مغناطیس برگردان به قطب) به کلاسهایی با فاصله یک انحراف معیار از میانگین طبقه‌بندی شدند (شکل ۴-الف، ب و ج). داده‌های دیگر یعنی داده‌های ژئوشیمیایی، نقشه نزدیکی به ساختارهای عمیق حاصل از تفسیر داده‌های مغناطیس هوایی و نقشه نزدیکی به گسلها و شکستگیهای حاصل از تفسیر تصاویر ماهواره‌ای به صورت دو کلاسه طبقه‌بندی شدند (شکل ۵. و، الف و ب). نقشه‌های مجاورت از ایجاد زونهای بافر در اطراف عوارض خطی انتخاب شده ایجاد شدند. در روش دوم تمام نقشه‌های نشانگر به صورت نقشه‌های دو کلاسه طبقه‌بندی شدند (شکل ۵). برای تبدیل نقشه‌های چند کلاسه به حالت دوتایی از مقادیر حدی که در روش وزنه‌های نشانگر به دست آمده بود (بهینا، ۲۰۰۴)، استفاده شد. برای به دست آوردن نقشه عامل پرتوسنجی، نقشه‌های مربوط به نسبتهای U/Th, Th/K و U/K به وسیله عملگر OR منطقی با هم‌دیگر تلفیق شدند (شکل ۵.د). نقشه‌های دو کلاسه مغناطیس کل و نقشه برگردان به قطب آن با استفاده از عملگر AND تلفیق شده و نقشه مغناطیس را به وجود آوردند (شکل ۵.ه). برای به دست آوردن نقشه نشانگر ژئوشیمیایی نقشه‌های بی‌هنجاری مربوط به عناصر Au, Ag, As, Co, Cu, Ba, Pb, Zn با استفاده از عملگر OR تلفیق شدند (شکل ۵. و).

شبکه RBFLN احتیاج به دو سری نقاط آموزشی دارد: سری اول نقاطی هستند که دال بر حضور عوارض یا شرایط پیش‌بینی شده هستند (برای مثال محل کانسارها یا رخدادهای معدنی). سری دوم نقاطی هستند که نبود این عوارض را نشان می‌دهند (برای مثال مناطقی که کانی‌زایی مورد

است. (Looney (2002) با استفاده از سه سری داده، عملکرد RBFLN را با شبکه‌های RBFNN و MLP مقایسه کرده و نتیجه گرفت که RBFLN در عین حال که بسیار دقیق است، سریع‌تر از دو شبکه دیگر نیز عمل می‌کند. یکی از مزایای RBFLN نسبت به RBFNN این است که تعداد گره مخفی کمتری را می‌توان با این شبکه به کار برد.

زمین‌شناسی و کانی‌زایی

منطقه مورد مطالعه بخشی از زون ایران مرکزی بوده و بین طولهای جغرافیایی ۴۵° ۳۲' - ۴۵° ۵۵' شمالی و عرضهای جغرافیایی ۴۵° ۵۵' - ۵۵° ۵۵' خاوری قرار دارد. منطقه ساغند-چادرمو به طور عمده از کمپلکسهای دگرگونی به سن پروتروزویک پوشیده شده است. ایران مرکزی از نظر فلززایی، به داشتن کانسارهای متعددی از آهن، آپاتیت و اورانیم به سن پروتروزویک شناخته شده است. به دلیل وجود محیط کافتی، ماگماتیسم گوشته‌ای غنی شده و کانی‌زایی اکسید آهن به همراه U, P, Th و REE، به نظر می‌رسد که کانی‌زایی در ایران مرکزی شباهت زیادی با کانی‌زایی تیپ اکسید آهن (Cu-U-Au-REE) پروتروزویک، پیشنهادی هیتزمن و همکاران (۱۹۹۲) دارد. برای به دست آوردن مدل مفهومی کانسار، در کنار مدل هیتزمن از ویژگیهای شاخص کانی‌زایی در کانسارهای شناخته شده منطقه استفاده شد (بهینا، ۲۰۰۴). طبق این مدل، معیارهای اصلی جهت شناسایی زونهای مناسب برای کانی‌زایی به شرح زیر معرفی شد: (۱) حضور سنگ درون‌گیر مناسب یعنی سنگهای سری ساغند، (۲) نزدیکی به گرانیت تیپ زیرگان، (۳) وجود زونهای متاسوماتیت پتاسیک-سدیک-سیلیسی که باعث به وجود آمدن مجموعه‌هایی از کانیهای دگرسان شده‌اند، (۴) نزدیکی به محل تلاقی ساختارهای عمیق پوسته‌ای با روندهای N-S و E- و نزدیکی به گسلهای با روند NE و NW، (۵) بالا بودن میدان مغناطیسی در اطراف زونهای کانه‌دار، (۶) وجود مقادیر بالای U و Th به همراه مقادیر پایین K در زونهای کانه‌دار و (۷) وجود بی‌هنجاریهای بالایی از عناصر Nb, TiO₂, REE, P, Cu, Au, Mo, As, Co, Pb و Zn در سنگهای همراه و رسوبات آبرفتی.

داده‌های ورودی به شبکه عصبی

داده‌هایی که در این مطالعه مورد استفاده قرار گرفت، شامل نقشه‌های زمین‌شناسی ۱:۱۰۰۰۰۰ ورقه‌های آبریز، ساغند، زمان آباد و دو ورقه ۱:۵۰۰۰۰ منتشر نشده از منطقه چادرمو (سازمان زمین‌شناسی)، داده‌های ژئوفیزیک هوایی شامل داده‌های مغناطیسی و پرتوسنجی (طیف سنجی K، U و Th) با ارتفاع پرواز ۱۳۰-۱۰۰ متر و فواصل خطوط پرواز ۵۰۰ متری (سازمان انرژی اتمی)، تصاویر ماهواره‌ای ETM⁺ لندست ۷ با شماره گذر

است که در RBFLN سریهای آموزشی تنها می‌توانند دارای یک مثال برای هر بردار (مناطق هم شرایط) باشند و اگر بیش از یک نقطه در یک منطقه حضور داشته باشد، تنها یک نقطه حفظ شده و بقیه حذف می‌شوند. جدول ۱ نتایج RBFLN برای داده‌های ورودی حاصل از تلفیق مجموعه‌ای از نقشه‌های چند کلاسه و دو کلاسه را نشان می‌دهد. همان طور که پیداست با افزایش در تکرار عملیات، از میزان خطای SSE یادگیری کاسته شده است. طبق آموزشی که در ۱۰۰ امین و ۲۰۰ امین تکرار انجام گرفته، تمام بردارها در کلاس ۱ یعنی کانسار طبقه بندی شده‌اند. یادگیری در ۳۰۰ امین تکرار کمترین خطای آزمون را به دست می‌دهد و به نظر می‌رسد بهترین یادگیری باشد. به رغم بالا بودن خطای طبقه بندی، نتیجه به نظر قابل قبول است، زیرا به جز مرحله ۱۰۰ و ۲۰۰، محدوده طبقه بندی قابل قبول می‌باشد. شکل ۶ الف نقشه پتانسیل کانی زایی پروتوزوویک را برپایه نتیجه طبقه بندی حاصل از ۳۰۰ امین تکرار نشان می‌دهد. ۵۰ درصد از ۵۸ کانسار و رخداد شناخته شده، از نظر ارزش عضویت RBFLN در ۱۰ امین صدک، ۶۲٪ در ۲۰ امین صدک و ۷۰/۶۸٪ در ۳۰ امین صدک بالایی قرار می‌گیرند. حدود ۳/۴٪ از کانسارها به طور ضعیفی طبقه بندی شده‌اند و در ۴۰ امین صدک از پایین قرار می‌گیرند. منطقه معدنی ساغند، معدن چادرملو و کانسار زیرگان به ترتیب اولین، سومین و پنجمین صدک بالایی را دارند.

اعمال RBFLN بر روی داده‌های ورودی حاصل از تلفیق نقشه‌های مختلف نشان داد که خطای طبقه بندی با افزایش تعداد بردارهای ورودی (مناطق هم شرایط) که خود ناشی از افزایش تعداد نقشه‌ها یا کلاسهای موجود در نقشه‌هاست، افزایش می‌یابد و در نتیجه خلاصه کردن نقشه‌ها به کاهش خطای طبقه بندی می‌انجامد. از طرف دیگر مشاهده شد که طبقه بندی و خلاصه کردن بیشتر باعث به وجود آمدن مناطق هم شرایطی با مساحتی بزرگ‌تر می‌شود. این مسئله باعث می‌شود تعداد بیشتری از نقاط آموزشی (کانساری یا غیر کانساری) درون یک منطقه هم شرایط قرار بگیرد که خود باعث حذف تعداد بیشتری از این نقاط آموزشی می‌شود. در نتیجه با این که تعداد مناطق هم شرایط کاهش می‌یابد، فراوانی نسبی‌شان در مقابل نقاط آموزشی کاهش موثری نمی‌یابد. این کاهش نه تنها SSE طبقه بندی را بهبود نمی‌بخشد، بلکه در صورتی که نقاط آموزشی باقی مانده عمدتاً از یک نوع باشند، منجر به طبقه بندی ضعیف نیز خواهد شد به طوری که بیشتر بردارها در یک گروه طبقه بندی خواهند شد. این مشکل زمانی که شبکه حاصل از تلفیق ۶ نقشه نشانگر دو کلاسه (شکل ۵) با استفاده از همان سری نقاط آموزشی مرحله قبل وارد RBFLN شد، به وجود آمد. تعداد مناطق هم شرایط، در این حالت به ۱۰۴ کاهش یافت. از آنجا که مساحت بعضی از مناطق هم شرایط بخصوص آنهایی که در مناطق کم پتانسیل قرار داشتند، بسیار بزرگ بود، از کل نقاط آموزشی تنها ۲۰ نقطه یعنی ۱۶ کانسار و ۴

نظر در آن مناطق رخ نمی‌دهد). در این مطالعه، از ۵۸ کانسار و رخداد معدنی شناخته شده در منطقه به عنوان نقاط سری اول استفاده شد. انتخاب نقاط سری دوم چندان ساده نیست ولی می‌توان مناطقی که در نقشه‌های ژئوشیمیایی ارزشهای پایینی را برای عناصر مورد نظر نشان می‌دهند یا محل کانسارهایی از تیپ دیگر را انتخاب کرد. در این مطالعه برای به دست آوردن این نقاط نقشه پتانسیل معدنی که به روش وزنه‌های نشانگر (Weights of Evidence) تهیه شده بود (بهینیا، ۲۰۰۴) مورد استفاده قرار گرفت و با استفاده از ابزار ایجاد نقاط تصادفی موجود در Arc-SDM، تعداد ۵۸ نقطه دارای پتانسیل پایین انتخاب شد.

تلفیق نقشه‌های نشانگر

برای به دست آوردن داده‌های اکتشافی ورودی به شبکه RBFLN، تمام نقشه‌های نشانگر با یکدیگر تلفیق شده و شبکه‌ای را تشکیل دادند که در آن سلولهایی با شرایط یکسان، به عنوان یک واحد در نظر گرفته می‌شوند (مناطق هم شرایط). در جدول ویژگیهای مرتبط با این شبکه برای هر کدام از مناطق هم شرایط یک رکورد و برای هر کدام از نقشه‌های نشانگر یک فیلد وجود دارد. همچنین برای نقاط آموزشی کانسار و غیر کانسار نیز به ترتیب یک فیلد اختصاص دارد که وضعیت هر رکورد را از نظر حضور یا عدم حضور کانسار مشخص می‌کند. شبکه حاصل که هر یک از رکوردهای آن به عنوان یک بردار n - بعدی (تعداد نقشه‌های نشانگر = n) به شمار می‌آید، وارد شبکه عصبی RBFLN شد. مراحل کار RBFLN شامل سه مرحله یادگیری، آزمون و طبقه بندی است. شبکه ابتدا به وسیله داده‌های شناخته شده که شامل بردارهای ورودی و بردارهای هدف است، مورد یادگیری قرار می‌گیرد و خطای کل مجموع مربعا (SSE) ثبت می‌شود. سپس بردارهای آزمون وارد شبکه می‌شوند و خطای SSE آزمون محاسبه می‌شود. در مرحله آزمون یک دسته بردار شناخته شده مورد طبقه بندی قرار می‌گیرند تا مشخص شود آیا یادگیری رضایتبخش بوده است یا نه. این بردارها بخشی از بردارهای شناخته شده‌اند که در مرحله یادگیری مورد استفاده قرار نگرفته و برای مرحله آزمون کنار گذاشته شده‌اند. دو مرحله یادگیری و آزمون تا آنجا تکرار می‌شوند تا بهترین یادگیری و رضایتبخش‌ترین نتیجه از آزمون عاید شود. در این مرحله RBFLN با استفاده از پارامترهای وزنی مربوط به یادگیری و آزمون، شروع به پردازش و طبقه بندی بردارهای مجهول می‌کند.

شبکه حاصل از تلفیق نقشه‌های چند کلاسه و دو کلاسه دارای ۲۰۷۴ بردار (مناطق هم شرایط) است که به نسبت تعداد نقاط آموزشی رقم بالایی است. از بین ۱۱۶ نقطه کانسار و غیر کانسار تنها ۷۴ نقطه یعنی ۴۹ کانسار و ۲۵ غیر کانسار به عنوان بردار هدف مورد استفاده قرار گرفت. دلیل این امر این

نتیجه‌گیری

کاربرد شبکه‌های عصبی در زمین شناسی اقتصادی و بخصوص تهیه نقشه پتانسیل معدنی بسیار جدید است. نتایج حاصل از این مطالعه نشان داد که RBFLN برای تلفیق متغیرهای زمین شناسی و تهیه نقشه پتانسیل معدنی قابل اعمال می‌باشد. یکی از مزایای RBFLN این است که تعداد گره مخفی کمتری با این شبکه می‌توان به کار برد. این مسئله برای تهیه نقشه پتانسیل معدنی بسیار مناسب است زیرا در بیشتر مناطق تعداد کانسارهای شناخته شده نسبت به وسعت منطقه مورد مطالعه بسیار کم است. از نتایج دیگر این مطالعه این است که پراکندگی خوب نقاط آموزشی (کانسار و غیرکانسار) در منطقه و فراوانی آنها نسبت به هم تأثیر زیادی در نتیجه طبقه‌بندی دارد. این مطالعه همچنین نشان داد که خطای مجموع مربعا (SSE) نسبت به ابعاد سلول شبکه حساس است، زیرا با کاهش ابعاد سلولی تعداد مناطق هم شرایط افزایش می‌یابد که این خود منجر به افزایش SSE می‌شود. یکی از امتیازهای تحلیل شبکه‌های عصبی توانایی آن در به کار بردن نقشه‌های چندکلاسه است. در بعضی موارد زمین شناسان تمایل زیادی به خلاصه کردن و طبقه‌بندی نقشه‌ها به کلاسهای کمتر را ندارند، چرا که این امر ممکن است منجر به از دست رفتن اطلاعات گردد. مقایسه شکل ۶- الف و ۶- ب نشان دهنده این مسئله است. شکل ۶- الف براساس نقشه‌های چند کلاسه قرار دارد و نسبت به شکل ۶- ب که براساس نقشه‌های دوتایی قرار دارد، حاوی جزئیات بیشتری است و نسبت به کانسارهای شناخته شده نیز نرخ پیش بینی بهتری را نشان می‌دهد.

غیرکانسار باقی ماند. اگرچه حداقل خطای یادگیری و آزمون به ترتیب به ۱/۶۵ و ۷/۳۴ کاهش یافت ولی به دلیل کم بودن تعداد نقاط آموزشی غیرکانساری، تمام بردارهای ورودی به‌عنوان کانسار طبقه بندی شدند. به‌منظور از بین بردن این مشکل و برای به‌دست آوردن پراکندگی خوبی از نقاط غیرکانساری، سعی شد با استفاده از نقشه پتانسیل حاصل از روش وزنهای نشانگر و با استفاده از همان ابزار ایجاد نقاط تصادفی موجود در Arc-SDM، با تکرار کار بهترین پراکندگی از این نقاط به دست آید.

جدول ۲ نتایج RBFLN برای داده‌های ورودی حاصل از تلفیق ۶ نقشه دو کلاسه شامل نقشه‌های زمین‌شناسی، ژئوشیمی، مغناطیس کل، پرتوسنجی، نزدیکی به ساختارهای عمیق و نزدیکی به گسلها و شکستگیها را نشان می‌دهد. تعداد مناطق هم شرایط ۱۰۴ است و ۱۶ کانسار و ۱۹ غیرکانسار به‌عنوان نقاط آموزشی مورد استفاده قرار گرفتند. همان طور که در جدول شماره ۲ دیده می‌شود یادگیری در ۳۵۰ امین تکرار، کمترین SSE را به‌دست داده و می‌تواند به‌عنوان بهترین یادگیری در نظر گرفته شود. شکل ۶. ب نقشه پتانسیل منطقه را براساس این طبقه بندی نشان می‌دهد. از بین ۵۸ کانسار و اندیس معدنی، ۴۶/۵۵٪ از نظر ارزش RBFLN در ۱۰ امین صدک، ۵۵/۱۷٪ در ۲۰ امین صدک و ۶۰/۳۴٪ در ۳۰ امین صدک بالا قرار دارند. ۱/۷٪ به‌طور ضعیف طبقه بندی شده و در ۲۰ امین صدک از پایین قرار می‌گیرند.

جدول ۱- نتایج اعمال RBFLN بر روی داده‌های ورودی حاصل از تلفیق مجموعه‌ای از نقشه‌های چند کلاسه و دو کلاسه. ۷۴ = تعداد گره‌های مخفی و

۲۰۷۴ = تعداد بردارهای ورودی (مناطق هم شرایط)

محدوده تغییر مقادیر خروجی	تعداد بردارهایی که به صورت (0) طبقه بندی شده‌اند	تعداد بردارهایی که به صورت (1) طبقه بندی شده‌اند	خطای آزمون	خطای یادگیری	دفعات تکرار
0.684 - 0.699	0	2074	29.585	3.978	100
0.634 - 0.764	0	2074	29.401	3.728	200
0.214 - 0.774	1947	127	14.859	3.493	250
0.138 - 0.759	2020	54	9.423	3.483	300
0.083 - 0.718	2057	17	12.877	3.494	350
0.233 - 0.712	1984	90	15.068	3.437	400
0.318 - 0.727	1816	258	17.578	3.423	450
0.215 - 0.788	1943	131	14.713	3.409	500
0.232 - 0.725	1936	138	15.332	3.341	700
0.234 - 0.621	1989	85	14.612	3.261	1000
0.389 - 0.865	932	1142	21.680	3.214	1200



۱ = کانسار 0 = غیر کانسار

جدول ۲- نتایج اعمال RBFLN بر روی داده های ورودی حاصل از تلفیق نقشه های دو کلاسه.

تعداد گره های مخفی و ۱۰۴ = تعداد بردارهای ورودی (مناطق هم شرایط)


تکرار	خطای یادگیری	خطای آزمون	تعداد بردارهایی که به صورت (1) طبقه بندی شده اند	تعداد بردارهایی که به صورت (0) طبقه بندی شده اند	محدوده تغییر مقادیر خروجی
200	2.923	5.072	35	69	0.493 - 0.518
300	2.781	5.010	35	69	0.442 - 0.586
350	2.713	4.922	35	69	0.412 - 0.611
360	2.705	4.981	35	69	0.418 - 0.623
380	2.680	4.961	35	69	0.409 - 0.631
400	2.659	5.005	35	69	0.407 - 0.648
450	2.613	5.164	46	58	0.409 - 0.689
500	2.573	5.401	64	40	0.420 - 0.735
600	2.516	6.111	96	8	0.472 - 0.837
800	2.462	8.479	104	0	0.687 - 1.104

۱ = کانسار 0 = غیر کانسار

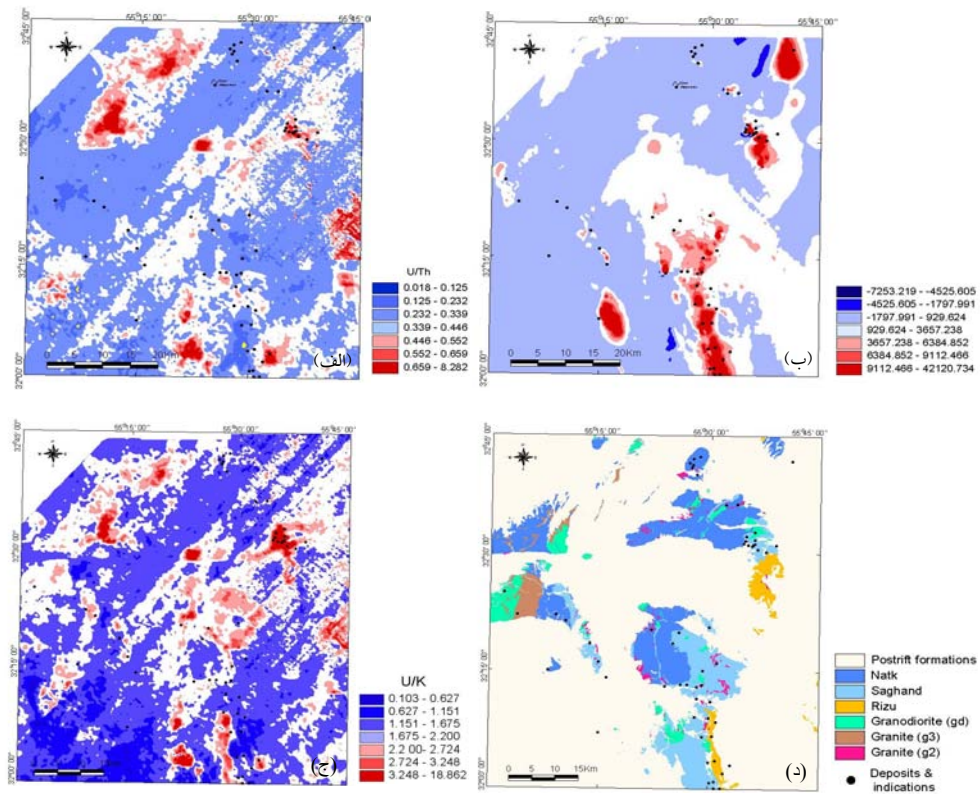


شکل ۲- یک شبکه RBFNN با N گره در لایه ورودی، M گره در لایه مخفی و J گره در لایه خروجی (Looney, 2002)

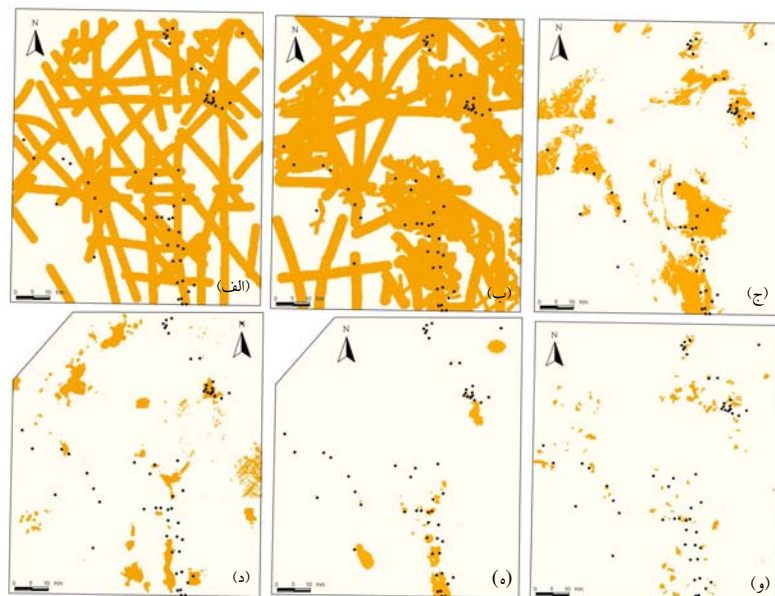
شکل ۱- یک تابع پایه شعاعی (Looney, 2002)



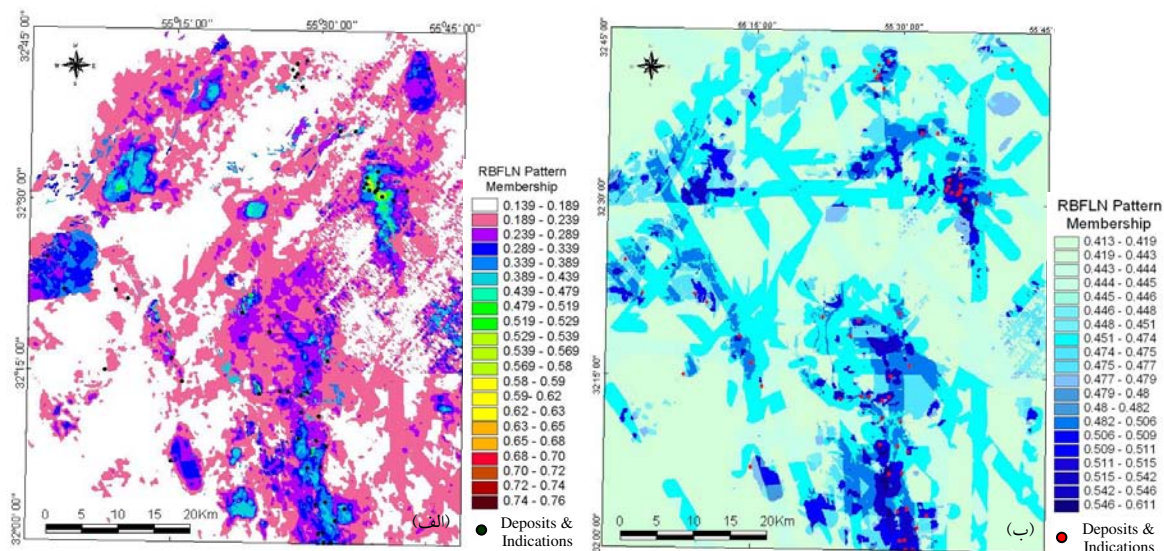
شکل ۳- سه نوع شبکه عصبی پیشخور (الف) یک شبکه پرسپترون چند لایه ای (MLP)، (ب) یک شبکه عصبی با تابع شعاعی (RBFNN) و (ج) یک شبکه RBFLN. نقل از (Looney, 2002)



شکل ۴- نقشه‌های نشانگر چند کلاسه مورد استفاده در مدل سازی: الف) نسبت U/Th، ب) مغناطیس برگردانده به قطب، ج) نسبت U/K و د) نقشه زمین شناسی.



شکل ۵- نقشه‌های نشانگر دوتایی مورد استفاده در مدل سازی: الف) نقشه نزدیکی به ساختارهای عمیق حاصل از تفسیر داده‌های مغناطیس هوایی، ب) نقشه نزدیکی به گسلها و شکستگیهای حاصل از تفسیر تصاویر ماهواره‌ای، ج) نقشه زمین شناسی، د) نقشه پرتوسنجی، ه) نقشه مغناطیسی، و) نقشه ژئوشیمیایی



شکل ۶- نقشه های پتانسیل معدنی حاصل از RBFLN برای کانی زایی پروتروزوییک در منطقه الف) تلفیق نقشه های چند کلاسه و دو کلاسه، ب) تلفیق نقشه های دو کلاسه

References

Behnia, P., 2004 -Geospatial data modeling for mineral exploration in Saghand-Chadormalu area, Central Iran. PhD dissertation, Wuhan University, 184pp.

Broomhead,D.S., Lowe, D.,1988- Multivariable functional interpolation and adaptive networks, *Complex Systems*, 2: 321-355.

Hitzman, M.W., Oreskes, N., Einaudi, M.T., 1992- Geological characteristics and tectonic setting of Proterozoic iron oxide (Cu- U- Au- REE) deposits, *Precambrian Research*, 58: 241-287.

Kemp, L.D., Bonham-Carter, G.F., Raines, G.L., Looney, C. G., 2001- Arc-SDM: Arcview extension for spatial data modeling using weights of evidence, logistic regression, fuzzy logic and neural network analysis, <http://ntserv.gis.nrcan.gc.ca/sdm/>.

Looney, C., 2002- Radial basis functional link nets and fuzzy reasoning. *Neurocomputing*, 48, 489-509.

Moody, J. E., Darken, C. J., 1988- Fast learning in networks of locally-tuned processing units, *Neural Comput.*, 1(2), 281-294.

Pan,G.C., Harris, D. P., 2000- Information Synthesis for Mineral Exploration. Oxford University Press, Inc., New York, 461pp.

*مدیریت ژئوماتیکس سازمان زمین شناسی و اکتشافات معدنی کشور

*Geomatics Management of Geological Survey of Iran