

## بررسی رفتار ژئوشیمیایی عنصر مس به روش کا- میانگین و پیش‌بینی آن با شبکه عصبی مصنوعی در منطقه کیوی، استان اردبیل عادل شیرازی<sup>۱</sup>، منصور ضیایی<sup>۲\*</sup>، اردشیر هزارخانی<sup>۳</sup>

۱. دانشجوی دکترای معدن، دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود، Adel.Shirazy@gmail.com

۲. دانشیار، دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود، M.Ziaii47@gmail.com

۳. استاد، دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، ardehez@aut.ac.ir

(دریافت: ۱۳۹۸/۰۴/۰۲ - پذیرش: ۱۳۹۸/۱۲/۱۰)

### چکیده

این پژوهش بر روی برگه یک‌صد هزارم ژئوشیمیایی منطقه کیوی انجام شد. منطقه کیوی در استان اردبیل قرار دارد. این ناحیه شامل سه واحد سنگی رسوبی، آذرین و دگرگونی است. قدیمی‌ترین واحد رسوبی موجود، سنگ‌های قبل از کرتاسه و جدیدترین آن، مربوط به کواترنر و عهد حاضر است. با توجه به استعداد کانی‌سازی فلزی، به ویژه عنصر مس در این منطقه، بررسی دقیق آن با اهمیت است. بر این اساس، یافتن اطلاعاتی در مورد ارتباط و رفتار عناصر طلا، نقره و مولیبدن نسبت به عنصر مس در این منطقه اهمیت می‌یابد؛ هدف از این بررسی، رفتارسنجی هاله‌های ژئوشیمیایی در منطقه است. در پژوهش حاضر با هدف رفتارسنجی عناصر نام برده، از روش مشهور و مفید کا میانگین استفاده شد. این روش از روش‌های خوشه‌بندی است که بر کمینه کردن مجموع فواصل اقلیدسی هر یک از نمونه‌ها از مرکز دسته‌هایی که به آن تخصیص می‌یابد، استوار است. در این پژوهش از تابع کیفیت خوشه‌بندی و میزان مطلوبیت نمونه در خوشه مورد نظر (S(i)) برای تشخیص تعداد خوشه بهینه استفاده شد، سپس با در نظر گرفتن مراکز خوشه‌ها و نتایج حاصل، معادلاتی برای پیش‌بینی مقدار عنصر مس بر حسب چهار پارامتر عیار طلا، نقره، مولیبدن، طول و عرض نقاط نمونه‌برداری با نگاه ویژه بر روش یاد شده ارائه شد. این نتایج نشان داد که در روش خوشه‌بندی کا- میانگین تعداد خوشه بهینه برای رفتارسنجی مس در مقابل هر یک از عناصر طلا، نقره و مولیبدن با توجه به موقعیت نمونه‌برداری آن‌ها تعداد ۳ خوشه است که مشخصات آن‌ها ارائه شد. پس از بررسی‌های رفتاری عناصر، آزمایش شبکه عصبی مصنوعی برای تخمین میزان مس با استفاده از روش‌های رگرسیون عمومی و پس انتشار خطا انجام شد. مقدار صحت (R) تخمین در داده‌های آزمایشی در شبکه عصبی مصنوعی رگرسیون عمومی و پس انتشار خطا به ترتیب ۰/۷۷ و ۰/۷۴ گزارش شد. در انتها مشخص شد که روش شبکه عصبی مصنوعی رگرسیون عمومی در تخمین بهینه عنصر مس در منطقه مورد مطالعه ارجحیت دارد.

### کلمات کلیدی

منطقه کیوی، مس شبکه عصبی مصنوعی، خوشه‌بندی کا- میانگین، رفتارسنجی ژئوشیمیایی.

## ۱- مقدمه

برای تحلیل رفتار داده‌ها و آنالیزهای موجود نسبت به یکدیگر عبارتند از تقسیم‌بندی عوارض زمین‌شناسی [۷]، تقسیم‌بندی تاثیر پوشش گیاه و بازیابی سلامتی آب در جنگل‌های ساحل مدیترانه [۸]، ارایه برنامه شناسایی الگوهای ژئوشیمیایی در مناطق معدنی [۹]، پیشگویی در مورد ارگانیک‌های کربن در سیستم‌های هوشمند [۱۰] و تعیین اثر پخش‌شوندگی گاز در محیط شهری [۱۱].

روش نوین بعدی در تخمین که پژوهش‌های زیادی در مورد آن منتشر شده روش شبکه عصبی مصنوعی است. کاربردهای متفاوت شبکه‌های عصبی مصنوعی در دهه‌های اخیر در زمینه‌های گوناگون، حاکی از قابلیت زیاد آن‌ها در مهندسی معدن برای تخمین‌های گوناگون است [۱۲، ۱۳، ۱۴، ۱۵]. شبکه عصبی مصنوعی از نظر عملکرد دارای روش‌های متفاوتی است که می‌توان به شبکه پرکاربرد پرسپترون<sup>۲</sup> چندلایه با الگوریتم پس انتشار خطا اشاره کرد. از آنجا که شبکه‌های عصبی به خوبی قادرند تا روابط غیرخطی مجهول بین داده‌های گوناگون را با دقت زیاد برآورد کنند [۱۶]؛ در سال‌های اخیر در دنیا سعی شده است تا از شبکه‌های عصبی پرسپترون با الگوریتم پس انتشار خطا و دیگر روش‌های شبکه عصبی مصنوعی برای پیش‌بینی مقادیر عناصر با استفاده از مختصات و سایر عناصر استفاده شود [۱۷، ۱۸، ۱۹].

یکی از دیگر روش‌های شبکه عصبی، شبکه عصبی رگرسیون عمومی یا در واقع نوعی شبکه شعاعی با ساختار موازی است. این شبکه با توجه به سرعت زیاد برآورد و همچنین پارامترهای کمتر قابل تنظیم نسبت به شبکه پس انتشار خطا، در بسیاری از موارد ارجحیت دارد. در زمینه استفاده از این شبکه می‌توان به مدل‌سازی و تشخیص الگوی زمین‌شناسی با شبکه عصبی رگرسیون عمومی، برآورد پارامترهای تاثیرگذار در کانی‌سازی و پیش‌بینی عناصر بر حسب سایر عناصر و پدیده‌های ساختاری اشاره کرد [۲۰، ۲۱، ۲۲].

در این پژوهش در نظر است با اجرای یک رشته کدنویسی در محیط نرم‌افزاری متلب<sup>۳</sup> و همچنین استفاده از نرم‌افزار SPSS توانمندی‌های هر یک از روش‌های یاد شده، بررسی شده و با توجه به نتایج به دست آمده روندی را برای بهبود اکتشاف این منطقه نمایان ساخت.

در سال‌های اخیر به علت وابستگی زیاد پروژه‌های معدنی به تعیین دقیق‌تر تناژ و عیار ماده معدنی، روش‌های گوناگونی برای تخمین عیار به وجود آمده است که از آن جمله می‌توان به روش‌های هندسی، مبتنی بر فاصله و زمین آماری اشاره کرد.

هر یک از روش‌ها معایب و محدودیت‌هایی دارند که بر روی دقت تخمین اثر می‌گذارد [۱]. یکی از روش‌های نوین تخمین عیار به کمک روش خوشه‌بندی است. روش‌های تحلیل خوشه ای کاربرد وسیعی در علوم زمین دارند. گروه‌بندی خوشه‌ای، روشی است که برای دسته‌بندی داده‌های ژئوشیمیایی به کار می‌رود.

تحلیل خوشه‌ای، مشاهداتی که با هم شباهت زیاد دارند را به یکدیگر مرتبط می‌کند، سپس به طور متوالی مشاهداتی را که بیشترین شباهت نسبت به مشاهدات قبلی را دارند به آن‌ها متصل می‌کند [۲]. به عبارتی در خوشه‌بندی سعی می‌شود تا داده‌ها به خوشه‌هایی تقسیم شوند که شباهت بین داده‌های درون هر خوشه حداکثر و شباهت بین داده‌های درون خوشه های متفاوت، حداقل شود [۳]. در روش خوشه‌بندی هیچ دسته‌ای از قبل وجود ندارد و در واقع متغیرها به صورت مستقل و وابسته تقسیم نمی‌شوند، بلکه در این جا جستجو برای دستیابی به گروه‌هایی از داده‌ها انجام می‌شود که به هم شباهت دارند و با کشف این شباهت‌ها می‌توان رفتارها را بهتر شناسایی کرد و بر مبنای آن‌ها، طوری عمل کرد که نتیجه بهتری حاصل شود [۴]. روش خوشه‌بندی یک روش غیر مستقیم است، بدین معنی که این روش را می‌توان حتی هنگامی که هیچ نوع اطلاعات قبلی از ساختار داخلی پایگاه داده‌ها وجود ندارد، استفاده کرد. از این روش می‌توان برای کشف الگوهای پنهان و بهبود عملکرد روش‌های مستقیم نیز استفاده کرد [۵].

روش کا- میانگین<sup>۱</sup> یکی از روش‌های خوشه‌بندی داده‌ها در داده کاوی است. این روش، روشی انحصاری و مسطح محسوب می‌شود که به طور وسیعی توسط پژوهشگران مختلف مورد بررسی قرار گرفته است و در تلاش است که به خوشه‌بندی تعدادی نمونه با تعداد دسته مشخص (k) بپردازد، به نحوی که مجموع فواصل اقلیدسی هر یک از نمونه‌ها از مرکز دسته‌ای که به آن تخصیص یافته است، کمینه شود [۶]. مواردی چند از کاربرد روش کا- میانگین،

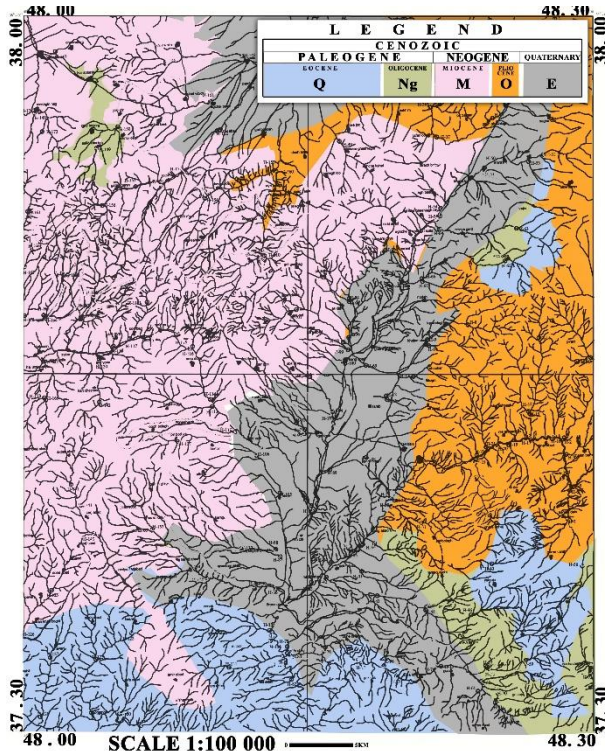
۲- Perceptron

۳- Matlab

۱- k-means

## ۲- منطقه مورد مطالعه

مسیر حرکت این زمین لغزش‌ها از بین رفته‌اند [۲۳]. نقشه ساده شده زمین‌شناسی، همراه با موقعیت آبراهه‌ها و نمونه‌های واقع در آن در شکل ۱ نشان داده شده است [۲۴].



شکل ۱- موقعیت نمونه‌ها و آبراهه‌ها در نقشه زمین‌شناسی ساده شده یک صد هزارم کیبوی، اردبیل.

## ۱-۲- زمین‌شناسی

منطقه کیبوی شامل سه واحد رسوبی، آذرین و دگرگونی است. قدیمی‌ترین واحد رسوبی موجود سنگ‌های قبل از کرتاسه و جدیدترین آن مربوط به کواترنر و عهد حاضر است [۲۵].

## ۱-۲-۱- زمین‌شناسی عمومی منطقه

در مسیر جاده سنگ‌آباد به میانه رخنمون‌هایی از سنگ‌های دگرگونی با ترکیب فلدسپات، کلدیریت، میکاشیست، فیلیت دیده می‌شود. رخنمون‌های آهک‌های کرتاسه فقط در نواحی جنوب شرقی منطقه مورد مطالعه دیده می‌شود که گسترش آن‌ها به سوی شرق بیشتر است. این واحد به صورت آهک سیلیسی توده‌ای تا ضخیم لایه است و گاهی میان لایه های آهک شیلی، شیل‌های آهکی و شیل‌های پیریت‌دار داخل آن دیده می‌شود. رنگ آن خاکستری و گاهی گلی پررنگ است. در منطقه به صورت واحدهای رسوبی و آذرین است که قسمت

برگه زمین‌شناسی ۱:۱۰۰,۰۰۰ کیبوی در استان اردبیل بین شهرهای اردبیل، خلخال و میانه و در قطعه شمال غربی چهارگوش زمین‌شناسی بندر انزلی و در مختصات جغرافیایی ۳۷° ۳۰' - ۳۸° ۳۰' طول شرقی و ۴۸° ۳۰' عرض شمالی واقع است [۲۳].

قسمت بیشتر آب‌های منطقه به وسیله سه رودخانه کیبوی‌چای، سنگورچای و هرسین‌چای که از شمال به جنوب جریان دارند، زهکشی شده و در آخر به وسیله رودخانه قزل‌اوزن به دریاچه خزر ریخته می‌شود. آب‌های قسمت شمال غربی این منطقه با رودخانه‌های بالخلوچای و گروچای زهکشی شده و پس از عبور از دشت اردبیل در نهایت به رودخانه آستارا ریخته و به دریاچه خزر تخلیه می‌شود [۲۳].

به دلیل اینکه بیشتر سطح منطقه از سنگ‌های آتشفشانی ائوسن و جوان تشکیل شده است، بنابراین منطقه دارای مورفولوژی خشن است، تنها در بخش‌های شمال غربی و در حاشیه جاده اردبیل- کیبوی به علت رخنمون‌هایی از رسوبات مارنی سست نئوژن، زمین‌های مسطح و تپه ماهورمانندی ایجاد شده است. به طور کلی دو رشته کوه عمده در این ورقه دیده می‌شود. کوه‌های بخش غربی منطقه که بیشترین بلندای آن‌ها به بیش از ۲۶۰۰ متر می‌رسد و مجموعه کوه‌های بخش غربی که بیشترین بلندای آن حدود ۲۵۰۰ متر است. ارتفاعات بخش شرقی بیشتر از سنگ‌های آتشفشانی ائوسن و ارتفاعات بخش غربی بیشتر از سنگ‌های آتشفشانی جوان تشکیل شده اند، احتمالاً عملکرد گسل شمال شرقی - جنوب غربی فیروزآباد- مجدر در بالا آوردن این مجموعه موثر بوده است. بزرگترین گودی منطقه که رودخانه سنگورچای در آن جاری است نیز در حاشیه این گسل به وجود آمده است و به نظر می‌رسد در شکل‌گیری این دره که در بستر رسوبات مارنی نئوژن ایجاد شده نیز گسل فوق موثر بوده است [۲۳].

مساله مورد توجه در این ناحیه وجود زمین لغزش‌های بزرگ و کوچک فراوان در همه جای منطقه است. این زمین لغزش‌ها اغلب در داخل رسوبات ماسه‌سنگی و کنگلومرای پالئوژن و یا بر روی بخش‌های هوازده سنگ‌های آتشفشانی ائوسن و در محل همبری این دو واحد انجام گرفته و در بسیاری موارد باعث خسارات جانی و مالی برای ساکنان ناحیه شده است، به طوری که برخی از جاده‌های منطقه مانند جاده سنگ‌آباد به میانه مرتب به وسیله این زمین لغزش‌ها مسدود می‌شود. برخی از روستاهای منطقه مانند قزل‌دره قدیم در

اعظم منطقه را پوشانده است [۲۵].

پس از ولکانیسم گسترده ائوسن و احتمالاً با یک وقفه زمانی که ممکن است معادل فاز پیرنن باشد، فعالیت الیگوسن با پدیده‌های آتشفشانی به صورت خروج گدازه‌های ریولیتی و آندزیتی شروع شده و با رسوبگذاری کنگلومرا، ماسه سنگ و مارن ادامه می‌یابد.

سنگ‌های آذرین رخنمون شده در این منطقه شامل سنگ‌هایی با ترکیب داسیتی، میانه و بازیک است. سنگ‌های اسیدی و میانه فقط در جنوب غربی منطقه دیده می‌شود. در حالی که سنگ‌های گابرویی در بخش‌های شرقی و شمال این منطقه رخنمون دارد. با توجه به اینکه تمام توده‌های نفوذی منطقه، سنگ‌های آتشفشانی ائوسن را قطع کرده‌اند، احتمالاً خروج آن‌ها می‌تواند در ارتباط با فاز کوهزایی پیرنن (ائوسن- اولیگوسن) باشد [۲۵].

سنگ‌های گرانیتی در جنوب غربی روستای کمبنا و در حاشیه رودخانه قزل اوزن دیده می‌شود. رنگ اصلی سنگ گلی روشن و دارای فلدسپات و کوارتز، در متن است. بافت سنگ میکروگرانولار و گرافیک، کانی‌های تشکیل‌دهنده آن فلدسپات آلکالن، پلاژیوکلاز، کوارتز و مسکویت است. این توده نفوذی کوچک در داخل سنگ‌های آتشفشانی ائوسن تزریق شده و اثرات دگرسانی را روی این سنگ‌ها به جا گذاشته است. بنابراین می‌توان گفت که این سنگ‌ها جوان‌تر از سنگ‌های ائوسن‌اند.

در کنار رخنمون گرانیت دو بیرون‌زدگی کوچک نیز از یک توده نفوذی با ترکیب کوارتز مونزونیت دیده می‌شود. بافت سنگ گرانولار و کانی‌های آن پلاژیوکلاز، فلدسپات آلکالن، کوارتز، آمفیبول، کلریت، اپیدوت و سریسیت است [۲۵].

در جنوب روستای النگش در داخل آندزیت‌های پورفیری و مگاپورفیری ائوسن، دایک‌های متعدد و ضخیمی دیده می‌شود که دارای راستای شمال شرقی - جنوب غربی‌اند.

این دایک‌ها اغلب در ستیغ کوه‌ها مشاهده می‌شوند. بافت این سنگ‌ها میکروگرانولار و دارای کانی‌های پلاژیوکلاز در حد لابرادوریت، کلینوپیروکسن از نوع اوژیت، الیوین تجزیه شده و کانی‌های کدرند. حداکثر پهناي این دایک‌ها ۳۰ متر است و طول آن‌ها گاهی به بیش از ۲۰۰۰ متر می‌رسد.

رخنمون‌هایی از سنگ‌های گابرویی و الیوین گابرو در غرب روستای النگش و جنوب روستای سیاه پوش دیده می‌شود. این گابروها نیز سنگ‌های آتشفشانی ائوسن را قطع

کرده‌اند. بافت این سنگ‌ها میکروگرانولار است. کانی‌های تشکیل‌دهنده سنگ شامل پلاژیوکلاز، اوژیت، الیوین تجزیه شده به کلریت، سرپانتین و ایدنگسیت، آپاتیت و کانی‌های فلزی است. این سنگ‌ها نیز جوان‌تر از سنگ‌های آتشفشانی ائوسن‌اند [۲۵].

## ۲-۱-۲- زمین‌شناسی اقتصادی منطقه

اندیس‌های فراوانی از کانی‌های فلزی و غیرفلزی در منطقه به چشم می‌خورد که در ادامه از آن‌ها برای پیش‌بینی و بررسی استفاده شده است. برخی از مواد معدنی مانند مس، زغال سنگ، تراورتن، سنگ ساختمانی و آهن، شن و ماسه یا قبلا استخراج شده‌اند و یا در حال حاضر نیز مورد بهره‌برداری قرار دارند.

آهن‌های اسپارایتی کرتاسه بالا، رنگ مناسب برای استفاده در سنگ نما را دارند ولی اغلب به علت عملکرد گسل‌ها خرد شده‌اند. در داخل سنگ‌های آتشفشانی ائوسن آثاری از کانی‌سازی مس به صورت پراکنده و رگه‌ای دیده می‌شود. مس در این منطقه بسیار مورد اهمیت است. از بازالت‌های تحتانی ائوسن نیز به عنوان سنگ ساختمانی مورد استفاده قرار می‌گیرد.

در جنوب شرقی روستای سنجبدله و در داخل بخش آتشفشانی- رسوبی ائوسن، آثاری از زغال‌سنگ نامرغوب وجود دارد که با توجه به ذخیره کم و نامرغوب بودن آن نمی‌تواند به عنوان یک اندیس خوب در نظر گرفته شود [۲۵].

در داخل سنگ‌های آتشفشانی نفوژن، سنگ‌هایی با بافت پرلیتی و سیاه رنگ دیده می‌شود که از نظر ترکیب شیمیایی مشابه پرلیت است و برای استفاده صنعتی نیاز به مطالعات بیشتری دارد. مارن‌های قرمز نیز به ویژه در مناطق شمال شرقی روستای فاراب برای تهیه آجر ساختمانی مناسب است زیرا مقدار گچ و نمک خیلی پایینی دارد و درصد کانی‌های رسی آن بالا است.

در منطقه مورد مطالعه چشمه‌های آهن‌ساز نسبتاً زیادی فعال‌اند و تراورتن‌های متنوعی را به وجود آورده‌اند که بعضی از آن‌ها با توجه به رنگ و ضخامت مناسب می‌تواند مورد بهره‌برداری قرار گیرد. همچنین بستر رودخانه‌های موجود، مانند کیوی‌چای و سنگورچای می‌تواند محل مناسبی برای استخراج شن و ماسه باشد. تیپ‌های شاخص کانی‌زایی مس در این برکه IOCG یا همان اکسید آهن، مس و طلا و همچنین تیپ دیگر ماسیو سولفید است [۲۶].

### ۳-۱- الگوریتم کا- میانگین

الگوریتم کا- میانگین با مقداری مشخص برای  $K$  (تعداد دسته‌ها) شروع می‌شود و سعی در تخمین موارد زیر دارد:

به دست آوردن نقاطی به عنوان مراکز خوشه‌ها که این نقاط در واقع همان میانگین نقاط متعلق به هر خوشه‌اند.

نسبت دادن هر نمونه داده به یک خوشه که آن داده کمترین فاصله تا مرکز آن خوشه را دارد [۶].

در نوع ساده‌ای از این روش ابتدا به تعداد خوشه‌های مورد نیاز، نقاطی به صورت تصادفی انتخاب می‌شود. سپس داده‌ها، با توجه به میزان نزدیکی (شباهت) به یکی از این خوشه‌ها نسبت داده می‌شوند و بدین ترتیب خوشه‌های جدیدی حاصل می‌شود. با تکرار همین مراحل می‌توان در هر تکرار با میانگین گیری از داده‌ها، مراکز جدیدی برای آن‌ها محاسبه کرد و مجدد داده‌ها را به خوشه‌های جدید نسبت داد [۲۸]. مراحل مهمی که در این الگوریتم طی می‌شود به طور خلاصه به شرح زیر است [۳۰، ۲۹]:

۱- ابتدا  $k$  عضو ( $k$  تعداد خوشه‌هاست)، به صورت تصادفی از میان  $n$  عضو به عنوان تعداد خوشه‌ها انتخاب می‌شود.

۲- محاسبه بردار  $Z_j$  بر اساس رابطه ۱ که نشان‌دهنده مرکز یا نماینده هر دسته  $C_j$  است.

$$z_j = \frac{\sum_{x \in C_j} x}{\#C_j} \text{ for } j = 1, \dots, k \quad (1)$$

که در آن:

$x$  بردار نمونه‌ای که در  $C_j$  عضو است.

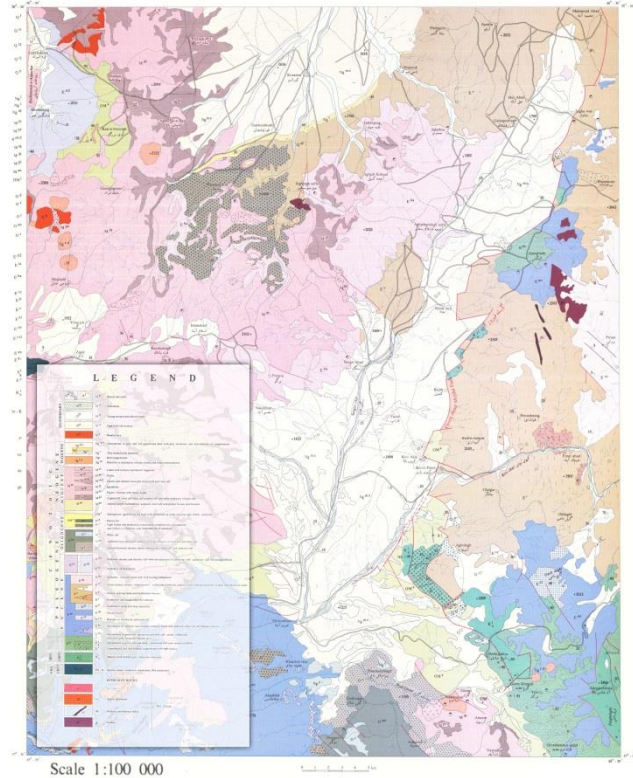
$\#C_j$  تعداد نمونه‌هایی که در کلاس  $C_j$  عضوند.

رابطه ۱ برای محاسبه مرکز هر دسته در حین حل استفاده می‌شود و در شروع الگوریتم معمولاً به صورت تصادفی،  $k$  نمونه انتخاب شده و به عنوان مرکز هر دسته در نظر گرفته می‌شوند [۲۰].

محاسبه تابع هدف ناشی از دسته‌بندی  $\{C_1, C_2, \dots, C_k\}$  بر اساس رابطه ۲ است که به محاسبه مجموع فاصله نمونه‌ها از مرکز دسته‌ها می‌پردازد.

$$f(c_1, c_2, \dots, c_k) = \sum_{j=1}^k \sum_{x \in C_j} |x - z_j|^2 \quad (2)$$

کمینه کردن تابع هدف رابطه ۲ و یافتن دسته‌بندی مناسب روی مجموعه  $M$  با تعداد دسته  $K$  انجام می‌گیرد [۳۰].



شکل ۲- نقشه زمین‌شناسی ۱:۱۰۰,۰۰۰ کیوی، اردبیل بدون ساده سازی [۲۶].

### ۳- روش مورد مطالعه

از منطقه کیوی تعداد ۷۱۴ نمونه رسوبات آبراه‌های جمع آوری و به روش ICP-MS تجزیه شده است که در این پژوهش برای تخمین عیار مس و بررسی رفتار آن نسبت به عناصر طلا، نقره و مولیبدن، تنها این سه عنصر، به دلیل پارازیت بودن و همچنین با توجه به مقدار ضریب همبستگی‌شان، مورد بررسی و پردازش قرار گرفته‌اند.

همان‌طور که در جدول ۱ مشاهده می‌شود، مقادیر ضریب همبستگی اسپیرمن [۲۷] این سه عنصر خوب بوده و نشان دهنده ارتباط این سه عنصر با یکدیگر است.

جدول ۱- ضرایب همبستگی اسپیرمن برای عناصر مس، طلا، نقره و مولیبدن.

	طلا	نقره	مولیبدن
مس	۰/۱۱۹	۰/۲۹۱	۰/۰۱۱
طلا		۰/۱۲۰	۰/۰۲۱
نقره			۰/۴۹۵

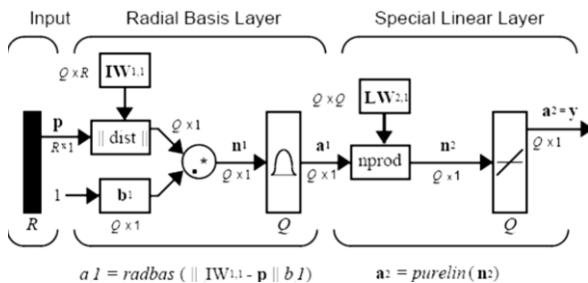
### ۳-۲- الگوریتم شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی یا به زبان ساده‌تر شبکه‌های عصبی، سیستم‌ها و روش‌های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده‌اند. ایده اصلی این گونه شبکه‌ها تا حدودی الهام گرفته از روش کارکرد سیستم عصبی زیستی برای پردازش داده‌ها و اطلاعات برای یادگیری و ایجاد دانش است. عنصر کلیدی این ایده، ایجاد ساختارهایی جدید برای سامانه پردازش اطلاعات است [۳۱].

این سیستم از تعداد زیادی عناصر پردازشی فوق‌العاده به هم پیوسته با نام نورون<sup>۱</sup> تشکیل شده که برای حل یک مساله با هم هماهنگ عمل کرده و به وسیله سیناپس‌ها<sup>۲</sup> (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب ببیند، بقیه سلول‌ها می‌توانند نبود آن را جبران کنند و نیز در بازسازی آن سهیم باشند. این شبکه‌ها قادر به یادگیری‌اند. به عنوان مثال با اعمال سوزش به سلول‌های عصبی لامسه، سلول‌ها یاد می‌گیرند که به طرف جسم داغ نروند و با این الگوریتم سیستم می‌آموزد که خطای خود را اصلاح کنند [۳۲]. یادگیری در این سیستم‌ها به صورت تطبیقی انجام می‌گیرد، یعنی با استفاده از مثال‌ها وزن سیناپس‌ها به گونه‌ای تغییر می‌کند که در صورت دادن ورودی‌های جدید، سیستم پاسخ درستی تولید کند [۳۳]. ساختار شماتیک یک شبکه عصبی مصنوعی تک لایه‌ای را می‌توان در شکل ۳ مشاهده کرد.

### ۳-۲-۱- شبکه عصبی مصنوعی رگرسیون عمومی


الگوریتم این شبکه را می‌توان در حکم یک شبکه شعاعی نرمال شده در نظر گرفت [۳۵] که برای هر واحد آموزشی یک نرون پنهان دارد [۳۶]. این شبکه الگوریتم یادگیری تک گذر با ساختار موازی که اسپچت در سال ۱۹۹۰ میلادی آن را اختراع کرد قادر به تولید خروجی‌های پیوسته است [۳۷، ۳۸]. این شبکه‌ها بر اساس تابع چگالی احتمال پایه‌گذاری شده‌اند و از ویژگی‌های بارز آن، زمان آموزش سریع و مدلسازی توابع غیرخطی است. این شبکه حتی با داده‌های پراکنده در یک فضای اندازه‌گیری چند بعدی، تغییرات همواری از داده مشاهده‌ای را برای دیگر داده‌ها فراهم می‌کند. صورت الگوریتمی این شبکه برای هر مساله رگرسیونی در جایی که هیچ‌گونه فرضیاتی برای قضاوت خطی بودن وجود نداشته باشد، می‌تواند مورد استفاده قرار گیرد. این شبکه پارامترهای شبکه پس انتشار خطا را ندارد و با توجه به اینکه فاقد فاکتور هموارساز خطا است، در عوض در آن، فاکتور هموارساز با توجه به میانگین مربعات خطا به دست می‌آید [۳۸]. ساختار این شبکه شبیه به ساختار کلی شبکه شعاعی است، فقط تفاوت جزئی در لایه دوم دارد (شکل ۴).



شکل ۴- ساختار کلی شبکه عصبی رگرسیون عمومی [۳۹].

### ۳-۲-۲- شبکه عصبی مصنوعی پس انتشار خطا

نوعی شبکه عصبی چند لایه با تابع انتقال غیرخطی و قاعده یادگیری ویندو- هاف<sup>۳</sup> است [۴۰]. از بردار ورودی و هدف در راستای آموزش این نوع شبکه برای تقریب زدن یک تابع، یافتن رابطه بین ورودی و خروجی و دسته‌بندی ورودی‌ها استفاده می‌شود [۴۱]. این شبکه با دارا بودن بایاس<sup>۴</sup>، یک لایه سیگموئید<sup>۵</sup> و یک لایه خروجی خطی، توانایی تخمین هر تابعی با تعداد نقاط ناپیوستگی محدود را دارد [۴۲].



شکل ۳- نمایش شماتیک یک شبکه عصبی مصنوعی تک لایه [۳۴].

۳- Widrow-Hoff


۴- Bias

۵- Sigmoid function

۱- Neuron

۲- Synapse

تابع  $\text{logsig}$  در لایه خطی استفاده می‌شود. شکل ۶ ساختار یک شبکه با توابع انتقال  $\text{purlin}$  و  $\text{tansig}$  را نشان می‌دهد.



شکل ۶- ساختار یک شبکه عصبی مصنوعی پس انتشار خطا [۴۶].

#### ۴- نتایج و بحث

در مطالعات مختلفی مانند رابطه دیوریت دگرسان شده با کانی منیتیت در کمر بند آهنی شیلی [۴۷]، رابطه بین مس و مولیبدن کانسار مس پورفیری [۴۸] و رابطه بین عناصر گروه پلاتین کانسار مس پورفیری [۴۹]، رفتار عناصر به روش‌های گوناگونی نسبت به یکدیگر سنجیده شده است. در مطالعه پیش رو با به کارگیری روش کا- میانگین برای خوشه‌بندی داده‌های رسوبات آبراهه‌ای منطقه کیوی، با چهار مقدار عبار عناصر مس، طلا، نقره و مولیبدن (با در نظر گرفتن مختصات نقاط نمونه‌برداری)، مقدار بهینه  $k$  در هر مورد محاسبه شده است زیرا که عناصر طلا و نقره و مولیبدن از عناصر مهم در تعیین هاله‌های ژئوشیمیایی عنصر مس به حساب می‌آیند [۵۰].

در این پژوهش برای مشخص کردن مقدار مناسب  $k$  برای تعیین تعداد خوشه‌ها، از دو معیار مناسب استفاده شده است. اولین معیار به کار گرفته شده معیار  $S(i)$  است که بر اساس آن، تعداد خوشه‌ها از ۳ تا ۱۰ تغییر داده می‌شوند و سپس به کمک معیار یاد شده، نتایج به دست آمده، مورد تحلیل قرار می‌گیرند تا  $k$  بهینه انتخاب شود [۵۱].

معیار مناسب برای تعیین  $k$  بهینه مطابق با رابطه ۳ تعیین شده است که بر اساس آن، دسته‌بندی‌های انجام شده مورد سنجش قرار می‌گیرد.


$$s(i) = \frac{\text{Min}(\text{Aveg\_Between}(i, k)) - \text{Aveg\_Within}(i)}{\text{Max}[\text{Aveg\_within}(i), \text{Min}(\text{Aveg\_Between}(i, k))]} \quad (3)$$

که در آن:

$S(i)$  میزان مطلوبیت نمونه  $i$  ام در کلاس مورد نظر خودش  
 $\text{Aveg\_within}(i)$  میانگین فاصله نمونه  $i$  ام از سایر نمونه‌های دیگر در آن کلاسی است که خود نمونه  $i$  ام وجود دارد.

این شبکه یک الگوریتم استاندارد با کاهش شیب است که در آن وزن‌های شبکه در جهت خلاف شیب تابع کارایی، حرکت می‌کنند. لغت پس‌انتشار به رفتار شبکه در محاسبه شیب در شبکه‌های غیرخطی چند لایه اشاره دارد. الگوریتم‌های مختلفی وجود دارند که بر مبنای این الگوریتم استاندارد عمل می‌کنند. از جمله این الگوریتم‌ها می‌توان به الگوریتم گرادیان توام و روش‌های نیوتن اشاره کرد [۴۳].

مرسوم‌ترین معماری برای شبکه پس‌انتشار، شبکه فید فوروارد<sup>۱</sup> است [۴۴]. یک نورون ساده با  $R$  ورودی در شکل ۵ نشان داده شده است.



شکل ۵- شبکه پس انتشار تک نرونی ساده [۴۵].

در شبکه‌های چند لایه اغلب از تابع انتقال  $\text{logsig}$  استفاده می‌شود. این تابع به ازای ورودی دریافتی در بازه مثبت بینهایت تا منفی بینهایت، خروجی بین ۱ و ۰ صفر تولید می‌کند. برای تولید خروجی‌هایی مابین ۱ و -۱ می‌توان از تابع انتقال  $\text{tansig}$  استفاده کرد. اگر آخرین لایه از یک شبکه چند لایه دارای نورون‌هایی با تابع انتقال سیگموئید باشد، خروجی به یک محدوده کوچک محدود می‌شود. در حالی که اگر نورون‌های خطی مورد استفاده قرار گیرند، خروجی می‌تواند هر مقدار را اختیار کند [۴۴].

شبکه عصبی مصنوعی پس انتشار خطا اغلب دارای یک یا چند لایه مخفی از نورون‌های سیگموئیدی است و از یک لایه پایانی خطی استفاده می‌کند. وجود چند لایه از نورون‌ها با یک تابع انتقال غیرخطی به شبکه اجازه می‌دهد که توانایی یادگیری رابطه خطی و غیرخطی را بین ورودی‌ها و خروجی‌ها داشته باشد. لایه خروجی خطی، به شبکه این امکان را می‌دهد که خروجی خارج از محدوده داشته باشد. البته اگر خروجی در بازه مورد نظر باشد، از

<sup>۱</sup>- Feed Forward

$Aveg\_Between(i,k)$  میانگین فاصله نمونه  $i$  ام از سایر نمونه‌هایی که در دسته دیگری مانند  $k$  قرار دارد [۵۱].

با محاسبه میزان مطلوبیت با عنوان میانگین مطلوبیت به تحلیل نتایج پرداخته می‌شود. مقدار مطلوبیت بین  $-1$  تا  $+1$  تغییر می‌کند که هرچه این مقدار به  $+1$  نزدیک‌تر باشد، نمونه مورد نظر در دسته‌بندی مناسب‌تر و هرچه به  $-1$  نزدیک‌تر باشد دارای دسته‌بندی نامناسبی است و عدد صفر به این معنی است که وجود نمونه مورد نظر در دسته فعلی و یا دسته دیگر اهمیت چندانی ندارد، بنابراین برای هر نمونه مقدار رابطه ۸ محاسبه می‌شود و سپس با محاسبه میانگین اعداد حاصل شده با عنوان میانگین مطلوبیت دسته‌بندی انجام شده، به تحلیل نتایج پرداخته می‌شود [۳۰] و [۵۲].

دومین معیار استفاده شده، تابع کیفیت است. بر اساس دانسته‌ها، بهترین خوشه‌بندی به صورتی است که در آن مجموع تشابه بین مرکز خوشه و همه اعضای خوشه، حداکثر و مجموع تشابه بین مراکز خوشه‌ها، حداقل باشد. برای انتخاب بهترین خوشه، ابتدا یک محدوده پیشنهادی برای تعداد خوشه‌ها مشخص می‌شود [۵۲] که در این پژوهش محدوده بین ۳ تا ۱۵ کلاس پیشنهاد شده است، سپس  $p(k)$  برای هر یک از مقادیر  $k$  محاسبه می‌شود.

مقداری از  $k$  که در آن  $p(k)$  حداکثر شود، به عنوان تعداد بهینه خوشه‌ها انتخاب می‌شود. به این ترتیب می‌توان تعداد خوشه‌ای را انتخاب کرد که به ازای آن فاصله بین مراکز خوشه‌ها و شباهت مراکز خوشه با اعضای درون هر خوشه حداکثر است. کیفیت نتایج خوشه‌بندی با  $k$  خوشه به صورت زیر تعریف می‌شود [۵۳، ۵۴]:

$$O = \{c^n | n = 1, \dots, k\} \quad (4)$$

$$O^n = \{c_i | i = 1, \dots, \|T^c - O\|\} \quad (5)$$

$$\rho(k) = \frac{1}{k} \sum_{n=1}^k (m_i n \left\{ \frac{\eta_n + \eta_m}{\delta_{nm}} \right\}) \quad (6)$$

$$\eta_n = \frac{1}{\|\sigma^n\|} \sum_{c_i \in \sigma^n} Sim(c_i, c^n) \quad (7)$$

$$\eta_m = \frac{1}{\|\sigma^m\|} \sum_{c_j \in \sigma^m} Sim(c_j, c^m) \quad (8)$$

$$\delta_{nm} = Sim(c^n, c^m) \quad (9)$$

که در این روابط:

$O$  مجموعه مراکز خوشه‌ها

$C^n$  مراکز خوشه‌ها

$O^n$  مجموعه عناصری که به عنوان مراکز خوشه انتخاب نشده‌اند  
 $T^c$  مجموعه کلیه عناصری که خوشه‌بندی روی آن‌ها انجام شده است.

$\eta_n$  میانگین شباهت بین مرکز خوشه  $C^n$  و همه عناصر خوشه  $O^n$

$\eta_m$  میانگین شباهت بین مرکز خوشه  $C^m$  و همه عناصر خوشه  $O^m$

$\delta_{nm}$  شباهت  $C^n$  و  $C^m$


#### ۴-۱- رفتارسنجی طلا، نقره و مولیبدن نسبت به مس

برای بررسی رفتار عناصر نسبت به یکدیگر در ابتدا نیمرخ خوشه‌ها و میزان مطلوبیت هر نمونه برای دسته‌بندی‌های  $k=3$  و  $k=15$  برای عناصر طلا و نقره و مولیبدن نسبت به مس انجام و نتایج میزان مطلوبیت دسته‌ها با هم مقایسه شده است و بهترین دسته بر اساس میزان مطلوبیت دسته‌ها مشخص شده و سپس مراکز خوشه‌های هر دسته با توجه به آن مشخص می‌شود.


همان‌طور که در شکل ۷ مشاهده می‌شود، مطابق با نمودارهای منتخب نیمرخ کلاس و با توجه به مقادیر مطلوبیت بهترین کلاس برای دو عنصر مس و طلا، کلاس ۳ به عنوان بهترین دسته انتخاب می‌شود زیرا هر چه میزان مطلوبیت به مقدار ۱ نزدیک باشد، نمونه‌ها به درستی در کلاس قرار گرفته‌اند. با توجه به نمودار، مقادیر منفی تقریباً کمی در این دسته‌بندی نیز دیده می‌شود.

مقدار متوسط مطلوبیت در این دسته‌بندی برابر با  $0.7239$  است که نسبت به مقدار متوسط مطلوبیت در دسته‌های دیگر این مقدار بیش‌تر است و به همین روال و با توجه به شکل‌های ۸ و ۹ برای دیگر عناصر، بهترین دسته بندی با توجه به نیمرخ خوشه‌ها و مقدار متوسط مطلوبیت انتخاب می‌شود که برای دو عنصر مس و نقره کلاس ۳ با مقدار متوسط مطلوبیت  $0.7252$  و برای دو عنصر مس و مولیبدن نیز کلاس ۳ با مقدار متوسط مطلوبیت  $0.7182$  به عنوان بهترین دسته‌بندی انتخاب می‌شود. برای اطمینان بیشتر و با توجه به نوسانات موجود در مقادیر مطلوبیت، مقدار  $k$  تا عدد ۵۰ افزایش داده شده است اما مقدار مطلوبیت از مقدار مطلوبیت بهترین دسته‌بندی هر گروه فراتر نرفته و به ازای دسته‌بندی با تعداد ۱۵ کلاس به بعد، روند کاهشی شدید داشته است.







دسته‌بندی با ۳ کلاس با مقدار متوسط ۰٫۷۳۵۲




دسته‌بندی با ۳ کلاس با مقدار متوسط ۰٫۷۲۳۹



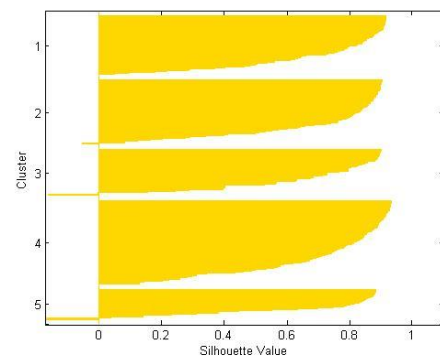
دسته‌بندی با ۴ کلاس با مقدار متوسط ۰٫۷۰۰۳




دسته‌بندی با ۴ کلاس با مقدار متوسط ۰٫۷۰۰۹




دسته‌بندی با ۵ کلاس با مقدار متوسط ۰٫۶۹۵۰



دسته‌بندی با ۵ کلاس با مقدار متوسط ۰٫۶۹۶۷



دسته‌بندی با ۶ کلاس با مقدار متوسط ۰٫۷۱۵۴

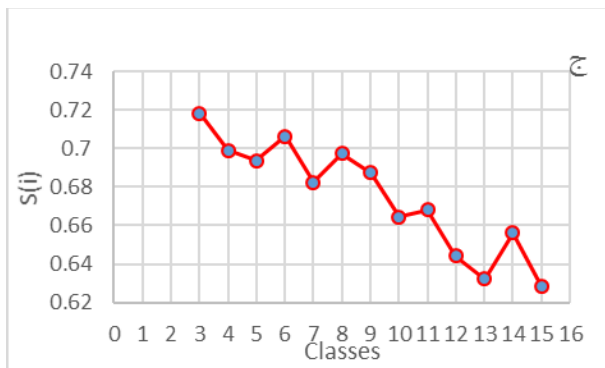




دسته‌بندی با ۶ کلاس با مقدار متوسط ۰٫۷۱۵۸

شکل ۸ - نیمرخ خوشه‌ها و مقادیر مطلوبیت با کلاس‌های ۳ تا ۶ کلاس مربوط به دو عنصر مس و نقره.


شکل ۷ - نیمرخ خوشه‌ها و مقادیر مطلوبیت با ۳ تا ۶ کلاس مربوط به دو عنصر مس و طلا.

همچنین می‌توان برای انتخاب تعداد خوشه بهینه، نمودار تغییر ملاک اعتبارسنجی  $S(i)$  را بر اساس تغییر تعداد خوشه‌ها به صورت شکل ۱۰ نشان داد که مقایسه آن راحت‌تر و ساده‌تر است. به عبارتی هر خوشه که بیشترین مقدار  $S(i)$  را داشته باشد، به عنوان تعداد خوشه بهینه انتخاب می‌شود. شکل (۱۰-الف) مقدار  $S(i)$  برای دو عنصر طلا و آرسنیک و شکل (۱۰-ب) برای دو عنصر طلا و آنتیموان تعداد خوشه ۹ دارای بیشترین مقدار و در شکل (۱۰-ج) تعداد خوشه ۳ برای دو عنصر آرسنیک و آنتیموان،  $S(i)$  دارای بیشترین مقدار است.




شکل ۱۰- مقدار ملاک اعتبارسنجی  $S(i)$  بر اساس تعداد خوشه‌ها، مس در مقابل: (الف- طلا، ب- نقره و ج- مولیبدن).


همچنین با توجه به تابع کیفیت و با استفاده از مقدار  $p(k)$  تعداد خوشه مناسب تعیین می‌شود. برای تعیین تعداد




دسته‌بندی با ۳ کلاس با مقدار متوسط ۰٫۷۱۸۲



دسته‌بندی با ۴ کلاس با مقدار متوسط ۰٫۶۹۹۰



دسته‌بندی با ۵ کلاس با مقدار متوسط ۰٫۶۸۷۸



دسته‌بندی با ۶ کلاس با مقدار متوسط ۰٫۷۰۶۴

شکل ۹- نیم‌رخ خوشه‌ها و مقادیر مطلوبیت با کلاس‌های ۳ تا ۶ مربوط به دو عنصر مس و مولیبدن.

بنابراین مناسب‌ترین تعداد خوشه برابر با سه است و به همین ترتیب برای دو عنصر مس و نقره و همچنین مس و مولیبدن تعداد خوشه بهینه برابر با ۳ و برای عناصر مس، طلا، نقره و مولیبدن با توجه به موقعیت نمونه‌برداری آن، تعداد خوشه برابر با ۳ مناسب‌ترین تعداد خوشه است. همان‌طور که مشهود است، تعداد خوشه مناسب به دست آمده از تابع کیفیت با نتایج معیار  $S(i)$  مطابقت دارد.

خوشه‌ها، مقدار  $p(k)$  با استفاده از رابطه ۶ برای مقادیر مختلف  $k$  محاسبه شده است. همان‌طور که بیان شد، مقدار حداکثر تابع کیفیت  $p(k)$  نشان‌دهنده تعداد مناسب خوشه‌ها است [۵۲].

جدول ۲ مقادیر تابع کیفیت  $p(k)$  به دست آمده متناظر با تعداد خوشه‌ها در جدول ۲ ارائه شده است. در رفتارسنجی دو عنصر مس و طلا، ۰/۷۰۶۴ بیشترین مقدار تابع کیفیت است،

جدول ۲- مقادیر  $p(k)$  برای تعداد خوشه‌های مختلف.

عناصر	تعداد خوشه	$p(k)$	عناصر	تعداد خوشه	$p(k)$		
دو عنصر مس و طلا	۳	۰/۷۰۶۴	دو عنصر مس و نقره	۳	۰/۶۹۳۷		
	۴	۰/۶۵۴۱		۴	۰/۶۱۹۸		
	۵	۰/۶۱۹۵		۵	۰/۵۹۹۸		
	۶	۰/۶۱۹۹		۶	۰/۵۸۴۵		
	۷	۰/۵۲۶۱		۷	۰/۵۰۴۶		
	۸	۰/۵۲۷۹		۸	۰/۵۷۷۴		
	۹	۰/۵۴۸۱		۹	۰/۵۴۹۰		
	۱۰	۰/۵۱۲۵		۱۰	۰/۵۴۵۲		
	دو عنصر مس و مولیبدن	۳		۰/۶۸۸۱	۴ عنصر مس، طلا و نقره و مولیبدن (با توجه به موقعیت نمونه‌ها)	۳	۰/۷۰۴۲
		۴		۰/۵۲۹۲		۴	۰/۶۳۲۱
۵		۰/۶۱۱۴	۵	۰/۶۷۰۱			
۶		۰/۶۳۸۳	۶	۰/۶۷۷۵			
۷		۰/۶۵۰۶	۷	۰/۶۷۶۷			
۸		۰/۵۲۱۵	۸	۰/۶۸۴۳			
۹		۰/۵۲۹۰	۹	۰/۶۱۱۶			
۱۰		۰/۵۲۰۱	۱۰	۰/۶۱۷۶			


تا حدود PPM ۹۰ عیار عنصر نقره کاهش می‌یابد و پس از گذر از این مرز روند معکوس می‌شود. بر اساس این تغییرات، بهترین برازش به آن، منحنی با تقعر مثبت است و معادله منحنی به صورت  $y = 1E-05x^2 - 0.0025x + 0.2917$  به دست آمده است.

با توجه به رفتار مس نسبت به طلا و نقره، رفتاری غیرقابل انتظاری پیش رو است که این عناصر رابطه مشخص مطلق ندارند، بر اساس دسته‌بندی که در شکل ۱۳ مشاهده می‌شود، به ازای افزایش عیار عنصر مس، ابتدا عیار عنصر مولیبدن افزایش یافته و سپس روند کاهشی دارد. معادله خط برازش شده به صورت  $y = -2E-06x^2 + 0.0005x + 2.209$  و ضریب همبستگی معادله برازش شده نیز برابر با  $R^2 = 1$  است.


مراکز دسته‌های تعیین شده به ازای بهترین دسته‌بندی که برای دو عنصر مس و طلا در شکل ۱۱ و به ازای ۳ کلاس برای دو عنصر مس و نقره در شکل ۱۲ و برای دو عنصر مس و مولیبدن در شکل ۱۳ به صورت نمودار نشان داده می‌شود.

بر اساس این دسته‌بندی که در شکل ۱۱ مشخص است، به ازای افزایش عیار عنصر مس، عیار عنصر طلا، ابتدا افزایش و سپس با رسیدن به حدود PPM ۹۰ کاهش می‌یابد. با توجه به این افزایش و کاهش، بهترین منحنی درجه دو با تقعر منفی است. خط برازشی به معادله  $y = -2E-08x^2 + 4E-06x + 0.0021$  و ضریب همبستگی  $R^2 = 1$  به دست آمده است.

برای مس و نقره (شکل ۱۲)، به ازای افزایش عیار عنصر مس




دسته‌بندی با ۳ کلاس با مقدار متوسط ۰٫۷۱۸۲.




دسته‌بندی با ۴ کلاس با مقدار متوسط ۰٫۷۰۵۷.

شکل ۱۴- نیمرخ خوشه‌ها و مقادیر مطلوبیت با کلاس‌های ۳ و ۴ مربوط به مس و طلا و نقره و مولیبدن (همراه مختصات).


با توجه به شکل ۱۵، بیشترین مقدار  $S(i)$  متعلق به ۳ کلاس است. برای اطمینان بیشتر و با توجه به نوسانات موجود در مقادیر مطلوبیت، مقدار  $K$  تا عدد ۵۰ افزایش داده شده است اما مقدار مطلوبیت از کلاس فوق فراتر نرفت و به ازای دسته‌بندی بالاتر از ۱۵ کلاس نیز روند کاهشی داشت.




شکل ۱۵- تغییر مقدار ملاک اعتبارسنجی  $S(i)$  بر اساس تعداد خوشه‌ها (برای عناصر مس، طلا، نقره و مولیبدن و مختصات).



شکل ۱۱- بهترین خط برازش شده به مراکز دسته‌ها برای مس و طلا.



شکل ۱۲- بهترین خط برازش شده برای عناصر مس و نقره.



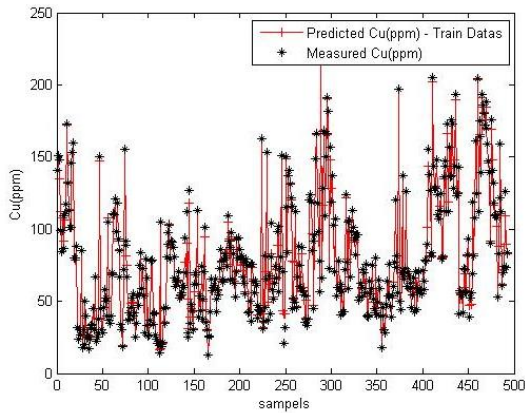
شکل ۱۳- منحنی برازشی به مراکز دسته‌های مس و مولیبدن.

۲-۴- بررسی رفتار ساختاری مس با توجه به عناصر طلا، نقره و مولیبدن


نیمرخ خوشه‌ها و میزان مطلوبیت دسته‌بندی‌های انجام شده با توجه به مقدار  $K=3$  و  $K=4$  در مورد عناصر مس، طلا، نقره و مولیبدن (با در نظر گرفتن طول و عرض نقاط) در شکل ۱۴ آورده شده است.

بر اساس نتایج به دست آمده به ازای مقادیر متفاوت برای  $K$  از ۳ و ۴، همان‌طور که مشاهده شد، دسته‌بندی روی نمونه‌های تعریف شده با مشخصه‌های عیار عنصر مس، طلا، نقره و مولیبدن و همچنین طول و عرض نمونه‌های برداشت شده، به ازای ۳ کلاس دارای بهترین دسته‌بندی است.


صحت (R) این برآوردها در داده‌های آموزشی برابر ۰/۹۹ و برای داده‌های آزمایشی ۰/۷۷ تعیین شد.



شکل ۱۶- خط تخمین مس همراه مقادیر واقعی در داده‌های آموزشی.



شکل ۱۷- خط تخمین مس همراه مقادیر واقعی داده‌های آزمایشی.



شکل ۱۸- رگرسیون داده‌های تخمینی در مقابل واقعی (آموزشی).

مشخصات مراکز خوشه‌ها با پنج کلاس در جدول ۳ ارائه شده است.

جدول ۳- مشخصات مراکز خوشه‌ها.

دسته	مس	طلا	نقره	مولیبدن	عرض	طول
اول	۲/۲۰۱	۰/۲۰۲۳	۰/۰۰۲۲	۴۸/۶۲۷	۳۷/۷۰	۴۸/۲۰
دوم	۲/۲۵۷	۰/۱۷۶	۰/۰۰۲۲	۹۳/۸۱۵	۳۷/۷۴	۴۸/۲۷
سوم	۲/۲۶۵	۰/۲۳۱۲	۰/۰۰۲۱	۱۵۸/۶۵	۳۷/۸۳	۴۸/۳۵

#### ۵- پیش‌بینی عیار طلا

در این قسمت با استفاده از رشته کدهای شبکه عصبی مصنوعی رگرسیون عمومی و پس‌انتشار خطا در نرم‌افزار متلب به تعیین توانایی تخمین مس توسط طلا، نقره و مولیبدن با توجه به طول و عرض نمونه‌های برداشت شده با استفاده از ۷۰ درصد نمونه‌ها که به صورت تصادفی انتخاب شده و همچنین تعیین اعتبار تخمین با ۳۰ درصد نمونه باقی مانده پرداخته شده است. برای تخمین هر چه بهتر، مقادیر در بازه صفر تا یک مطابق فرمول [۵۵]، استانداردسازی شده است.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (10)$$

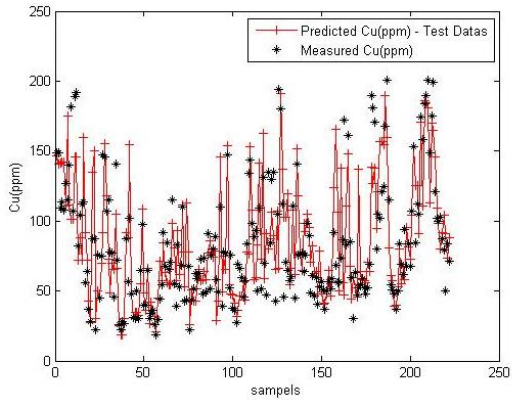
مقادیر عنصر مس به عنوان متغیر خروجی و مقادیر عنصر طلا، نقره و مولیبدن همراه طول و عرض نقاط به عنوان متغیرهای ورودی برای تعیین الگوریتم تخمین به نرم‌افزار معرفی می‌شوند.

#### ۵-۱- تخمین با شبکه عصبی مصنوعی رگرسیون عمومی


با توجه به نیاز تعیین شعاع بهینه [۵۶] برای تخمین هر چه بهتر در این روش، مقادیر مختلفی از صفر تا ۱ به صورت تجربی انتخاب شد. مقدار بهینه ۰/۰۱۵ برای شعاع تاثیر انتخاب شد.

در شکل ۱۶ می‌توان میزان خطا پیوسته تخمینی و عیارهای نقطه‌ای واقعی را در داده‌های آموزشی مشاهده کرد و همچنین شکل ۱۷ نشان‌دهنده همین موضوع بر داده‌های آزمایشی است.


نظریه دید بهتر در مورد صحت تخمین از قراردادن مقادیر تخمینی در مقابل مقادیر واقعی در هر مختصات در دو دسته داده آموزشی و آزمایشی به صورت رگرسیونی به ترتیب در شکل‌های ۱۸ و ۱۹ ارائه شده است.



شکل ۲۲- خط تخمین مس همراه مقادیر واقعی داده‌های آزمایشی.



شکل ۱۹- رگرسیون داده‌های تخمینی در مقابل واقعی (آزمایشی).




شکل ۲۳- رگرسیون داده‌های تخمینی در مقابل واقعی (آموزشی).


### ۲-۵- تخمین با شبکه عصبی مصنوعی پس انتشار خطا

در روش پس انتشار خطا، پارامترهایی مانند نوع آموزش، انتخاب تعداد نرون‌ها در لایه‌های مختلف و نوع نرون‌ها اهمیت دارد [۵۷]. در نتایج زیر نوع آموزش با مقررات باینری است، همچنین کارایی شبکه با میانگین مجذور خطاها برآورد شده و نوع و تعداد نرون‌ها و نظایر آن در شکل ۲۰ نشان داده شده است.


نتیجه خط تخمینی همراه نقاط واقعی در داده‌های آموزشی و آزمایشی به ترتیب شکل‌های ۲۱ و ۲۲ و همچنین صحت در داده‌های آموزشی و آزمایشی که مقادیر ۰٫۸۱ و ۰٫۷۴ برآورد شده در شکل‌های ۲۳ و ۲۴ مشهود است.



شکل ۲۰- شماتیک شبکه عصبی مصنوعی از لایه‌ها و تعداد نرون‌ها.



شکل ۲۴- رگرسیون داده‌های تخمینی در مقابل واقعی (آزمایشی).



شکل ۲۱- خط تخمین مس همراه مقادیر واقعی در داده‌های آموزشی.

## ۶- نتیجه گیری

با توجه به وجود شواهد کانی‌سازی مس در منطقه کیوی واقع در استان اردبیل، بررسی وسعت هاله‌های ژئوشیمیایی و رفتار عناصر پاراژنز مس در منطقه اهمیت می‌یابد بدین منظور با استفاده از روش کا- میانگین به بررسی رفتار عناصر طلا و نقره و مولیبدن در محدوده کیوی نسبت به مس پرداخته شده و رابطه‌ها و معادله‌های همراه با ضریب همبستگی ارایه شد. سپس با استفاده از روش یاد شده، رابطه عناصر با در نظر گرفتن طول و عرض جغرافیایی نمونه‌ها به منظور برآورد دقیق‌تر از پیدایش و وسعت هاله‌های ژئوشیمیایی در محدوده مورد مطالعه تعیین شد. در انتها با ارزیابی شبکه عصبی مصنوعی عمومی و پس انتشار خطا برای تخمین عیار عنصر مس بر حسب پنج پارامتر عیار طلا، عیار نقره، عیار مولیبدن، طول و عرض نقاط نمونه‌برداری انجام گرفت و صحت (R) تخمین در داده‌های آزمایشی در شبکه عصبی مصنوعی رگرسیون عمومی برابر با ۰/۷۷ و شبکه عصبی مصنوعی پس انتشار خطا ۰/۲۴ گزارش شد. این نتایج علاوه بر نشان دادن قدرتمندی روش کا- میانگین بر رفتارسنجی، روش شبکه عصبی مصنوعی رگرسیون عمومی را در تخمین بهینه عنصر مس در منطقه ارجح دانست.

## منابع

- Abolhassani, B., Salt, J. E. (2005). *A Simplex Kmeans Algorithm for Radio-Port Placement in Cellular Networks*. In Canadian Conference on Electrical and Computer Engineering.
- Chen, T. W., Chien, S. Y. (2009). *Bandwidth Adaptive Hardware Architecture of K-Means Clustering for Video Analysis*. IEEE Transactions on VLSI Systems.
- Yang, J., Zhuang, Y., Wu, F. (2012). *ESVCbased extraction and segmentation of texture features*. Computers & Geosciences, Elsevier, 49, 238-247.
- Mora, J.L., Armas-Herrera, C.M., Guerra, J.A., Rodríguez-Rodríguez, A., Arbelo, C.D., (2012), *Factors affecting vegetation and soil recovery in the Mediterranean woodland of the Canary Islands (Spain)*. Journal of Arid Environments, Elsevier, 87, 58-66.
- Meshkani, S. A., Mehrabi, B., Yaghubpur, A., Alghalandis, Y. F., (2011). *The application of geochemical pattern recognition to regional prospecting: A case study of the Sanandaj-Sirjan metallogenic zone, Iran*. Journal of Geochemical Exploration, Elsevier, 108, 183-195.
- Sfidari, E., Kadkhodaie-Ilkhchi, A., Najjari, S., (2012), *Comparison of intelligent and statistical clustering approaches to predicting total organic carbon using intelligent systems*. Journal of Petroleum Science and Engineering, Elsevier, 63, 190-205.
- Wegner, T., Hussein, T., Hämeri, K., Vesala, T., Kulmala, M., Weber, S., (2012). *Properties of aerosol signature size distributions in the urban environment as derived by cluster analysis*. Atmospheric Environment, Elsevier, 61, 350-360.
- Moradzade, A., Dowlati Ardejani, F., Rooki, R., Rahimi, M., (2012). *Estimation of permeability of South Pars gas field using general regression neural network*. Journal of Earth and Space Physics, Volume 37, No 4, 51-65.
- Mohaghegh, S. and Ameri, S., 1995, *Artificial Neural Network As A Valuable Tool For Petroleum Engineers*, SPE29220, Proceedings, SPE, West Virginia.
- Balan, B., Mohaghegh, S., & Ameri, S. (1995). *State-of-the-art in permeability determination from well log data: Part 1-A comparative study, model development*. In
- Majdifar, S., Kamali, GH. (2014). *Iron Grade Estimation Using ANFIS Algorithm at Tappeghermez Anomaly of Sangan Mine*. Journal of Analytical and Numerical Methods in Mining Engineering (ANM). No 5. (in Persian)
- Abbas zadeh, S., Rahimi pour, GH., Najmodini, M. (2013). *Recognition of Cu-Porphyry Mineralization Areas by Using One and multivariate integration methods on drainage geochemical data in Ghale Askar area, Kerman province*. Journal of Analytical and Numerical Methods in Mining Engineering (ANM). No, 6. (in Persian)
- ShayesteFar, M., Rasa, I. (2005). *Multivariate Data Analysis of Qanat Marvan Lead-Zinc Deposit., Kerman*. Geosciences Scientific Quarterly Journal. No, 57. (in Persian)
- Malyszko, D., Wierzchon, S. T. (2007). *Standard and Genetic K-means Clustering Techniques in Image Segmentation*. In 6th International Conference on Computer Information Systems and Industrial Management Applicatins.

- Iran (GSI), *Geochemical Studies Tracking Report on 1:100,000 sheet, kivi*. Code: 5665
26. Geological Survey and Mineral Exploration of Iran (GSI), *Geology 1:100000 map, Kivi, Ardabil*, Code 6356 .
  27. Myers, L., & Sirois, M. J. (2006). *Spearman correlation coefficients, differences between*. Wiley StatsRef: Statistics Reference Online.
  28. Jain, A. K. (2012). *Data clustering: 50 years beyond K-Means*, Pattern Recognition Letters, Elsevier, 31, 651-666.
  29. Saha, S., Bandy opadhyay, S. (2013). *A generalized automatic clustering algorithm in a multi objective framework*. Applied Soft Computing, Elsevier, 13, 89-108.
  30. Ghannadpour, S. S., Hezarkhani, A., & Farahbakhsh, E. (2013). *An investigation of Pb geochemical behavior respect to those of Fe and Zn based on k-Means clustering method*. Journal of Tethys, 1(4), 291-302.
  31. Schalkoff, R. J. (1997). *Artificial neural networks* (Vol. 1). New York: McGraw-Hill.
  32. Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd..
  33. Dayhoff, J. E., & DeLeo, J. M. (2001). *Artificial neural networks*. Cancer, 91(S8), 1615-1635.
  34. Abraham, A. (2005). *Artificial neural networks*. handbook of measuring system design.
  35. Demuth, H., & Beale, M. (1993). *Neural Network Toolbox For Use with Matlab--User'S Guide Verion 3.0*.
  36. Rolon, L. F. (2002). *Developing intelligent synthetic logs: Application to Upper Devonian units in Pennsylvania*.
  37. Specht, D. F. (1991). *A general regression neural network*. IEEE transactions on neural networks, 2(6), 568-576.
  38. Artun, E., Mohaghegh, S. D., Toro, J., Wilson, T., & Sanchez, A. (2005). *Reservoir characterization using intelligent seismic inversion. In SPE Eastern Regional Meeting*. Society of Petroleum Engineers.
  39. Demuth, H., & Beale, M. (2002). *Neural Network Toolbox For Use with Matlab--User'S Guide Verion 4.0*.
  40. Widrow, B., Glover, J. R., McCool, J. M., Kaunitz, J., Williams, C. S., Hearn, R. H., ... *SPE Eastern Regional Meeting*. Society of Petroleum Engineers.
  15. Mohaghegh, S. (2000). *Virtual-intelligence applications in petroleum engineering: Part 1—Artificial neural networks*. Journal of Petroleum Technology, 52(09), 64-73.
  16. HIJANG, Z., & WILLIAMSON, M. A. (1994). *Geological pattern recognition and modelling with a general regression neural network*. Canadian JI of Exploration Geophysics, 30(1), 60-68.
  17. Hasani, H., Shirazi, A., Shirazy, A., (2017), *Estimation of copper values by artificial neural network in the sub-domain of Mashran, East of Iran*, 2nd National Conference on Modern Science and Technology of Iran, Tehran, Association for the Development and Promotion of Basic Sciences and Techniques. (in Persian)
  18. Zhang, L., & Bai, G. (2002). *Application of the artificial neural network to multivariate anomaly recognition in geochemical exploration for hydrocarbons*. Geochemistry: Exploration, Environment, Analysis, 2(1), 75-81.
  19. Lacassie, J. P., Del Solar, J. R., Roser, B., & Hervé, F. (2006). *Visualization of volcanic rock geochemical data and classification with artificial neural networks*. Mathematical Geology, 38(6), 697-710.
  20. Ho, T. L. (2009). *3-D inversion of borehole-to-surface electrical data using a back-propagation neural network*. Journal of Applied Geophysics, 68(4), 489-499.
  21. Lalor, G. C., & Zhang, C. (2001). *Multivariate outlier detection and remediation in geochemical databases*. Science of the total environment, 281(1-3), 99-109.
  22. Pradhan, B., Lee, S., & Buchroithner, M. F. (2010). *A GIS-based back-propagation neural network model and its cross-application and validation for landslide susceptibility analyses*. Computers, Environment and Urban Systems, 34(3), 216-235.
  23. Geological Survey and Mineral Exploration of Iran (GSI), *geology 1:100000 map, Kivi, Ardebil*, Reports. Code: 5665
  24. Geological Survey and Mineral Exploration of Iran (GSI), *Waterway map(1:100,000), kivi*. Code: 5665
  25. Geological Survey and Mineral Exploration of



50. Talesh Hosseini, S., Asghari, O., & Ghavami Riabi, S. R. (2018). Spatial modelling of zonality elements based on compositional nature of geochemical data using geostatistical approach: a case study of Baghqlloom area, Iran. *Journal of Mining and Environment*, 9(1), 153-167.
51. Yaghini, M., Ghannad pour, F., Khadmatlu, S., (2008). *Offering an clustering innovative method in data mining by using genetic algorithms to solve a real case study in the rail transportation industry*, Iran Data Mining Conference. Amirkabir university. Tehran. ( in Persian)
52. Hezarkhani, A. Ghannadpour, S. S. (2015). *Geochemical Behavior Investigation Based on K-Means Clustering: Basics, Concepts and Case Study*. LAP LAMBERT Academic Publishing.
53. Shina, H.W. and Sohn, S.Y. (2004). *Segmentation of Stock Trading Customers According to Potential Value*, Expert Systems with Applications, 27, 27-33
54. Shirazy, A., (2017). Modeling and delineation of copper anomalies using modern methods in Mesgaran cu deposit, East Iran. Msc Thesis. Birjand University of Technology, South Khorasan (in Persian).
55. Mahvash Mohammadi, N., Hezarkhani, A. (2015). *Estimation of grade gold in khooni deposit using the behavior of gold arsenic and antimony by clustering k-mean method*. Journal of analytic and numerical methods in mining engineering 5(10):77-92
56. Specht, D. F. (1996). *Probabilistic neural networks and general regression neural networks*. In Fuzzy logic and neural network handbook (pp. 301-344). McGraw-Hill, Inc..
57. Gaborski, R. S. (1991). *U.S. Patent No. 5,052,043*. Washington, DC: U.S. Patent and Trademark Office.
- & Goodlin, R. C. (1975). *Adaptive noise cancelling: Principles and applications*. Proceedings of the IEEE, 63(12), 1692-1716.
41. Hecht-Nielsen, R. (1992). *Theory of the backpropagation neural network*. In Neural networks for perception (pp. 65-93).
42. Buscema, M. (1998). *Back propagation neural networks*. Substance use & misuse, 33(2), 233-270.
43. Goh, A. T. C. (1995). *Back-propagation neural networks for modeling complex systems*. Artificial Intelligence in Engineering, 9(3), 143-151.
44. Hornik, K., Stinchcombe, M., & White, H. (1989). *Multilayer feedforward networks are universal approximators*. Neural networks, 2(5), 359-366.
45. Hagan, M. T., & Menhaj, M. B. (1994). *Training feedforward networks with the Marquardt algorithm*. IEEE transactions on Neural Networks, 5(6), 989-993.
46. Chen, F. C. (1990). *Back-propagation neural networks for nonlinear self-tuning adaptive control*. IEEE Control systems magazine, 10(3), 44-48.
47. Menard, J. J. (1995). *Relationship between altered pyroxene diorite and the magnetite mineralization in the Chilean Iron Belt, with emphasis on the El Algarrobo iron deposits (Atacama region, Chile)*. Mineral Deposita, Springer-Verlag, 30, 268-274.
48. Leiluo, X., Xianwu, B., Ruizhong, H., Xingchun, Z. (2012). *Relationships between porphyry Cu-Mo mineralization in the Jinshajiang- Red River metallogenic belt and tectonic activity: Constraints from zircon U-Pb and molybdenite Re-Os geochronology*. Ore Geology Reviews, Elsevier, 48, 460-473.
49. Tarkian, M., Stribny, B. (1999). *Platinum group elements in porphyry copper deposits: a reconnaissance study*. Mineralogy & Petrology, Springer-Verlag, 65, 161-183.