

## بررسی رفتار ژئوشیمیایی بر اساس پیش بینی شبکه عصبی مصنوعی و کا-میانگین برای دو عنصر تیتانیوم و روی در محدوده کیوی، استان اردبیل

عادل شیرازی<sup>۱</sup>، منصور ضیائی<sup>۲\*</sup>، اردشیر هزارخانی<sup>۳</sup>

<sup>۱</sup> دانشجوی دکتری تخصصی، مهندسی معدن گرایش اکتشاف مواد معدنی، دانشگاه صنعتی شاهرود، Adel.Shirazy@shahroodut.ac.ir

<sup>۲</sup> دانشیار دانشگاه صنعتی شاهرود، دانشکده مهندسی معدن، نفت و ژئوفیزیک، Mziaii@shahroodut.ac.ir

<sup>۳</sup> استاد، دانشگاه صنعتی امیرکبیر، دانشکده مهندسی معدن، Ardehez@aut.ac.ir

چکیده: برگه یک صد هزارم ژئوشیمیایی کیوی، واقع در استان اردبیل، توسط سازمان زمین‌شناسی و اکتشافات کشور ایران با استفاده از آنالیز رسوبات آبراهه‌ای تهیه شده است. این ناحیه شامل سه واحد رسوبی، آذرین و دگرگونی است. قدیمی ترین واحد رسوبی موجود سنگهای قبل از کرتاسه میباشد و جدیدترین آن مربوط به کواترنر و عهد حاضر است. با توجه به استعداد کانی‌سازی فلزی بالاخص در این منطقه، بررسی دقیق آن با اهمیت است. بنا به همین امر، یافتن اطلاعاتی در مورد ارتباط و رفتارسنجی عناصر تیتانیوم و روی در این منطقه، برای پیدایش و تعیین وسعت هاله‌های ژئوشیمیایی، تعیین امیدبخش بودن ناحیه و تخمین عیار، ضرورت می‌یابد و می‌بایست مورد مطالعه قرار گیرند. بنا بر این در پژوهش حاضر برای رفتارسنجی عناصر نام برده، از روش مشهور و مفید کا-میانگین استفاده شد که روشی خوشه‌بندی بوده 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 و با در نظر گرفتن مراکز خوشه‌ها و نتایج حاصل، معادلاتی برای پیش‌بینی مقدار عنصر تیتانیوم بر حسب سه پارامتر روی، طول و عرض نقاط نمونه‌برداری با نگاه ویژه بر روش مذکور ارائه شد. پس از بررسی های رفتاری عناصر، آزمایش شبکه عصبی مصنوعی برای تخمین میزان تیتانیوم با روش رگرسیون عمومی مورد بررسی و تفسیر قرار گرفت که منتج به نتایج مطلوبی گردید.

**واژه‌های کلیدی:** ژئوشیمی، زمین آمار، رسوبات آبراهه‌ای، داده کاوی، شبکه عصبی مصنوعی، کا-میانگین

### ۱- مقدمه

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

هر یک از روشها دارای محدودیت‌ها و معایبی هستند که بر روی دقت تخمین تأثیر می‌گذارند [۱] یکی از روشهای نوین تخمین عیار به کمک روش خوشه‌بندی است. روشهای تحلیل خوشه ای کاربرد وسیعی در علوم زمین دارند. گروه بندی خوشه ای، روشی است که برای دسته‌بندی داده های ژئوشیمیایی به کار میرود .

تحلیل خوشهای، مشاهداتی که با هم شباهت زیاد دارند را به یکدیگر مرتبط می کند، سپس به طور متوالی مشاهداتی را که بیشترین شباهت نسبت به مشاهدات قبلی را دارند به آنها متصل می کند [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 خوشه بندی یک روش غیر مستقیم است، بدین معنی که این روش را می توان حتی هنگامی که هیچ نوع اطلاعات قبلی از ساختار داخلی پایگاه دادهها وجود ندارد، استفاده نمود. از این روش می توان برای کشف الگوهای پنهان و بهبود عملکرد روشهای مستقیم نیز استفاده نمود [۵].

روش k-means یکی از روشهای خوشه بندی دادهها در دادهکاوی است. این روش روشی انحصاری و مسطح محسوب می شود که به طور وسیعی توسط پژوهشگران مختلف مورد بررسی قرار گرفته است و در تلاش است که به خوشه بندی تعدادی نمونه با تعداد دسته مشخص (k) پردازد، به نحوی که مجموع فواصل اقلیدسی هر یک از نمونهها از مرکز دسته ای که به آن تخصیص یافته است، کمینه شود [۶] مواردی چند از کاربرد روش k-means که به منظور تحلیلی مناسب از رفتار دادهها و آنالیزهای موجود نسبت به یکدیگر داشته است که می توان به تقسیم بندی عوارض زمین شناسی [۷]، تقسیم بندی تأثیر پوشش گیاه و بازایی سلامتی آب در جنگلهای ساحل مدیترانه [۸] ارائه برنامه شناسایی الگوهای ژئوشیمیایی در مناطق معدنی [۹] پیش گویی در مورد ارگانیک های کربن در سیستمهای هوشمند [۱۰] و تعیین اثر پخش شونده گی گاز در محیط شهری اشاره نمود [۱۱].

روش نوین بعدی در تخمین که پژوهش های زیادی در باب آن منتشر گردیده روش شبکه عصبی مصنوعی است. کاربردهای متفاوت شبکه های عصبی مصنوعی در دهه های اخیر در زمینه های گوناگون، حاکی از قابلیت زیاد آنها در مهندسی معدن برای تخمین های گوناگون است. [۱۲، ۱۳، ۱۴، ۱۵] شبکه عصبی مصنوعی از نظر عملکرد دارای روش های متفاوتی است که می توان به شبکه پر کاربرد پرسپترون چند لایه با الگوریتم پس انتشار خطا اشاره کرد. از آنجا که شبکه های عصبی به خوبی قادرند تا روابط غیر خطی مجهول بین داده های گوناگون را با دقت زیاد برآورد کنند. [۱۶] به همین دلیل در سالهای اخیر در دنیا سعی شده است تا از شبکه های عصبی پرسپترون با الگوریتم پس انتشار خطا و دیگر روشهای شبکه عصبی مصنوعی برای پیش بینی مقادیر عناصر با استفاده از مختصات و سایر عناصر استفاده شود. [۱۷، ۱۸، ۱۹]

یکی از دیگر روش های 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 می توان به مدلسازی و تشخیص الگوی زمین شناسی با شبکه عصبی رگرسیون عمومی، برآورد پارامتر های تأثیر گذار در کانی سازی و پیش بینی عناصر بر حسب سایر عناصر و پدیده های ساختاری اشاره داشت. [۲۰، ۲۱، ۲۲] در نتیجه در این پژوهش در نظر است با اجرای یک رشته کدنویسی در محیط نرم افزاری مت لب و همچنین استفاده از نرم افزار SPSS توانمندی های روش های مذکور بررسی شده و با توجه به نتایج بدست آمده روندی را جهت بهبود اکتشاف این منطقه نمایان سازد.

## ۲- زمین شناسی منطقه مورد مطالعه

منطقه کیوی شامل سه واحد رسوبی، آذرین و دگرگونی میباشد. [۱۳] قدیمی ترین واحد رسوبی موجود سنگهای قبل از کرتاسه میباشد و جدیدترین آن مربوط به کواترنر و عهد حاضر است. (شکل ۱)

### ۲-۱- زمین شناسی عمومی منطقه

در مسیر جاده سنگ آباد به میانه رخنمونهایی از سنگهای دگرگونی با ترکیب فلدسپات، کلدیریت، میکاشیست، فیلیت دیده می شود. رخنمونهای آهکهای کرتاسه فقط در نواحی جنوب خاوری منطقه مورد مطالعه دیده میشود که گسترش آنها به سوی خاور بیشتر است. این واحد بصورت آهک سیلیسی توده ای تا ضخیم لایه است و گاهی میان لایه های آهک شیلی، شیللهای آهکی و شیللهای پیریت دار داخل آن دیده می شود. رنگ آن خاکستری و گاهی گلی پرنگ است. [۱۳]

در منطقه بصورت واحدهای رسوبی و آذرین است که قسمت اعظم منطقه را پوشانده است. پس از ولکانیسم گسترده ائوسن و احتمالاً با یک وقفه زمانی که میتواند معادل فاز پیرنئن باشد، فعالیت الیگوسن با پدیده های آتشفشانی بصورت خروج گدازه های ریولیتی و آندزیتی شروع شده و با رسوبگذاری کنگلومرا، ماسه سنگ و مارن ادامه می یابد.

سنگهای آذرین رخنمون شده در این منطقه شامل سنگهایی با ترکیب داسیتی، میانه و بازیک است. سنگهای اسیدی و میانه فقط در جنوب باختری منطقه دیده می شود. در حالیکه سنگهای گابرویی در بخشهای خاوری و شمال این منطقه رخنمون دارد. با توجه به آنیکه تمام توده های نفوذی منطقه، سنگهای آتشفشانی ائوسن را قطع کرده اند، احتمالاً خروج آنها می تواند در ارتباط با فاز کوهزایی پیرنئن (ائوسن - اولیگوسن) باشد.

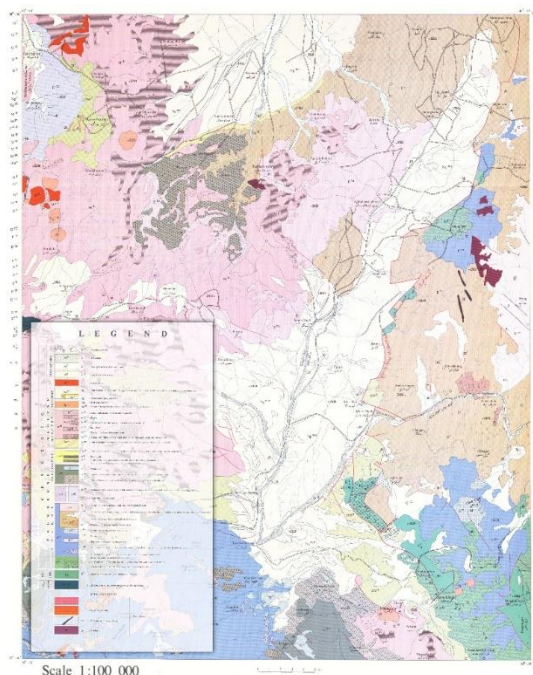
سنگهای گرانیتی در جنوب باختری روستای کمینان و در حاشیه رودخانه قزل اوزن دیده می شود. رنگ اصلی سنگ گلی روشن و دارای فلدسپات و کوارتز، در متن میباشد. بافت سنگ میکروگرانولار و گرافیک بوده، کانیهای تشکیل دهنده آن، فلدسپات آلکان، پلاژیوکلاز، کوارتز و مسکویت است. این توده نفوذی کوچک در داخل سنگهای آتشفشانی ائوسن تزیق شده و اثرات دگرسانی روی این سنگها بجا گذاشته است. بنابراین می توان گفت که این سنگها جوانتر از سنگهای ائوسن می باشد. [۱۳]

در کنار رخنمون گرانیته دو بیرونزدگی کوچک نیز از یک توده نفوذی با ترکیب کوارتز موزونیت دیده می‌شود. بافت سنگ گرانولار است، کانیهای آن پلاژیوکلاز، فلدسپات آلکالن، کوارتز، آمفیبول، کلریت، اپیدوت و سریسیت میباشد. در جنوب روستای النگش در داخل آندزیت‌های پورفیری و مگاپورفیری ائوسن، دایکهای متعدد و ضخیمی دیده می‌شود که دارای راستای شمال خاوری - جنوب باختری هستند.

این دایکها اغلب در ستیخ کوهها مشاهده میگردند. بافت این سنگها میکروگرانولار بوده و دارای کانیهای پلاژیوکلاز در حد لابرادوریت، کلینوپیروکسن از نوع اوژیت، الیوین تجزیه شده و کانیهای کدر میباشد. حداکثر پهنای این دایکها ۳۰ متر بوده و طول آنها گاهی بیش از ۲۰۰۰ متر می‌رسد. رخنمونهایی از سنگهای گابرویی و الیوین گابرو در باختر روستای النگش و جنوب روستای سیاه پوش دیده میشود. این گابروها نیز سنگهای آتشفشانی ائوسن را قطع کرده اند. بافت این سنگها میکروگرانولار است. کانیهای تشکیل دهنده سنگ شامل پلاژیوکلاز، اوژیت، الیوین تجزیه شده به کلریت، سرپانتین و ایدنگسیت، آپاتیت و کانیهای فلزی است. این سنگها نیز جوانتر از سنگهای آتشفشانی ائوسن هستند. [۱۳]

### ۲-۲- زمین شناسی اقتصادی منطقه

اندیسهای فراوانی از کانیهای فلزی و غیرفلزی در منطقه به چشم می‌خورد. برخی از مواد معدنی مثل مس، زغال سنگ، تراورتن، سنگ ساختمانی و آهک، شن و ماسه یا قبلاً استخراج شده اند و یا در حال حاضر نیز مورد بهره برداری قرار دارند. آهک اسپارایتی کرتاسه بالا دارای رنگ مناسب برای استفاده در سنگ نما هستند ولی اغلب بعلت عملکرد گسلهها خرد شده می‌باشند. در داخل سنگهای آتشفشانی ائوسن آثاری از کانی سازی مس بصورت پراکنده و رگه ای 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 خاوری روستای سنجبدله و در داخل بخش ولکانوسدیمتر ائوسن، آثاری از زغال سنگ نامرغوب وجود دارد که با توجه به ذخیره کم و نامرغوب بودن آن نمی‌تواند به عنوان یک اندیس خوب در نظر گرفته شود. در داخل سنگهای آتشفشانی نئوژن، سنگهایی با بافت پرلیتی و سیاه رنگ دیده می‌شود که از نظر ترکیب شیمیایی مشابه پرلیت است و جهت استفاده صنعتی نیاز به مطالعات بیشتری دارد. مارنهای قرمز نیز بویژه در مناطق شمال خاوری روستای فاراب جهت تهیه آجر ساختمانی مناسب می‌باشد. زیرا مقدار گچ و نمک خیلی پایینی دارد و درصد کانیهای رسی آن بالاست. [۱۳ و ۱۴] در منطقه مورد مطالعه چشمه های آهک ساز نسبتاً زیادی فعال بوده و تراورتن های متنوعی را بوجود آورده‌اند که بعضی از آنها با توجه به رنگ و ضخامت مناسب می‌تواند مورد بهره برداری قرار گیرد. همچنین بستر رودخانه های موجود مثل کیوی، اردبیل می‌تواند محل مناسبی برای استخراج شن و ماسه باشد.



شکل ۱: نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ کیوی، اردبیل [۱۳]

### ۳- روش مورد مطالعه

از منطقه کیوی تعداد ۷۱۴ نمونه رسوبات آبراهه ای جمع آوری و به روش ICP-MS تجزیه شده که در این پژوهش به منظور تخمین عیار تیتانیوم و بررسی رفتار آن نسبت به روی، این عناصر، به دلیل پارائز بودن و همچنین با توجه به مقدار ضریب همبستگی شان، مورد بررسی و پردازش قرار گرفته‌اند.

همانطور که در جدول ۱ مشاهده می شود مقادیر ضریب همبستگی اسپیرمن [۲۷] این سه عنصر خوب بوده و نشان دهنده‌ی ارتباط این دو عناصر با یکدیگر است.

جدول ۱: ضرایب همبستگی اسپیرمن برای تیتانیوم و روی

	تیتانیوم	روی
روی	۰/۶۹	۱
تیتانیوم	۱	۰/۶۹

### ۳-۱- الگوریتم k-means

الگوریتم k-means با مقداری مشخص برای K (تعداد دسته‌ها) شروع کرده و سعی در تخمین موارد زیر دارند:

بدست آوردن نقاطی به عنوان مراکز خوشه‌ها که این نقاط در واقع همان میانگین نقاط متعلق به هر خوشه هستند.

نسبت دادن هر نمونه داده به یک خوشه که آن داده کمترین فاصله تا مرکز آن خوشه را دارا باشد [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 مجدداً داده‌ها را به خوشه‌های جدید نسبت داد [۲۸]. مراحل مهمی که در این الگوریتم طی می‌شود به طور خلاصه به شرح ذیل است [۳۰، ۲۹]:

۱- ابتدا k عضو ( که 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  $C_j$  می‌باشد.

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

۳- در این رابطه، x نشان دهنده بردار یک نمونه‌ای است که در  $C_j$  عضو می‌باشد و  $\#C_j$  نشان‌دهنده تعداد نمونه‌هایی می‌باشد که در کلاس  $C_j$  عضو می‌باشند. لازم به ذکر است که رابطه (۱) برای محاسبه مرکز هر دسته در خلال حل استفاده می‌گردد و در شروع الگوریتم معمولاً

به صورت تصادفی k نمونه انتخاب می‌گردند و به عنوان مرکز هر دسته در نظر گرفته می‌شوند. [۲۰]

۴- محاسبه تابع هدف ناشی از دسته‌بندی  $\{C_1, C_2, \dots, C_k\}$  بر اساس رابطه (۵) که به محاسبه مجموع فواصل نمونه‌ها از مرکز دسته‌ها می‌پردازد.

$$f(C_1, C_2, \dots, C_k) = \sum_{j=1}^k \sum_{x \in C_j} |x - z_j|^2 \quad (2)$$


۵- کمینه نمودن تابع هدف رابطه (۲) و یافتن دسته‌بندی مناسب روی مجموعه M با تعداد دسته K [۳۰].

### ۳-۲- روش خوشه بندی درختی

در 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 پیچیده هستند. ایده‌ی اصلی این گونه شبکه‌ها تا حدودی

الهام گرفته از شیوه‌ی کارکرد سیستم عصبی زیستی برای پردازش داده‌ها و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. عنصر کلیدی این ایده، ایجاد ساختارهایی جدید برای سامانه‌ی پردازش اطلاعات است. [۳۱]

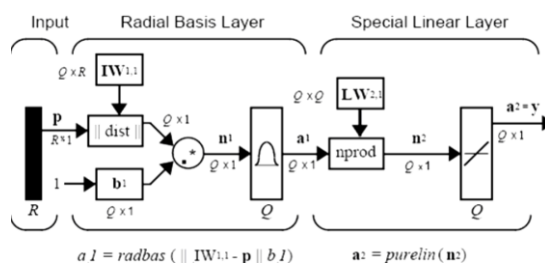
این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده بهم پیوسته با نام نورون تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب ببیند بقیه سلول‌ها می‌توانند نبود آنرا جبران کرده، و نیز در بازسازی آن سهیم باشند. این شبکه‌ها قادر به یادگیری‌اند. مثلاً با اعمال سوزش به سلول‌های عصبی لامسه، سلول‌ها یادمی‌گیرند که به طرف جسم داغ نروند و با این الگوریتم سیستم می‌آموزد که خطای خود را اصلاح کند. [۳۲] یادگیری در این سیستم‌ها به صورت تطبیقی صورت 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 لایه ای را میتوان در شکل ۳ مشاهده نمود.



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

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

الگوریتم این شبکه را می‌توان درحکم یک شبکه شعاعی [۳۵] نرمال شده در نظر گرفت که برای هر واحد آموزشی یک نرون پنهان دارد. [۳۶] این شبکه الگوریتم یادگیری تک گذر با ساختار موازی که اسپچت در ۱۹۹۰ آن را اختراع کرد [۳۷,۳۸] قادر به تولید خروجی‌های پیوسته است. این شبکه‌ها براساس تابع چگالی احتمال پایه گذاری شده و از ویژگی‌های بارز آن زمان آموزش سریع و مدل سازی توابع غیرخطی است. این شبکه حتی با داده‌های پراکنده در یک فضای اندازه گیری چند بعدی، تغییرات همواری از داده مشاهده ای را برای دیگر داده‌ها فراهم می‌کند. صورت الگوریتمی این شبکه برای هر مسئله رگرسیونی در جایی که هیچ گونه فرضیاتی برای قضاوت خطی بودن وجود نداشته باشد، می‌تواند مورد استفاده قرار گیرد. این شبکه پارامترهای شبکه پس انتشار خطا را ندارد ولی در عوض فاکتور هموار ساز خطا را ندارد ولی در عوض فاکتور هموار ساز توجه به میانگین مربعات خطا به دست می‌آید [۳۸] همان طور که در شکل ۴ نشان داده شده است، ساختار این شبکه شبیه به ساختار کلی شبکه شعاعی است؛ فقط تفاوت جزئی در لایه دوم دارد.



شکل ۴: ساختار کلی شبکه عصبی رگرسیون عمومی [۳۹]

### ۴- بحث و بررسی

در مطالعات مختلفی نظیر رابطه‌ی دیوریت دگرسان شده با کانی مگنتیت در کمر بند آهنی شیلی [۴۰]، رابطه بین مس و مولیبدن کانسار مس پورفیری [۴۱] و رابطه بین عناصر گروه پلاتین کانسار مس پورفیری [۴۲] رفتار عناصر به روشهای گوناگونی نسبت به یکدیگر سنجیده شده است. در مطالعه پیش رو با به کارگیری روش k-means برای خوشه‌بندی داده‌های رسوبات آبراههای منطقه کیوی، با مقدار عیار عناصر تیتانیوم و روی (با در نظر گرفتن مختصات نقاط نمونه‌برداری)، مقدار بهینه k در هر مورد محاسبه شده است.

در این پژوهش به منظور مشخص نمودن 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 الی ۱۰ تغییر داده می‌شوند و سپس به کمک معیار مذکور، نتایج حاصل شده مورد تحلیل قرار می‌گیرند تا  $k$  بهینه انتخاب شود [۴۳].

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

$$S(i) = \frac{\text{Min}(\text{Aveg\_Between}(i, k)) - \text{Aveg\_Within}(i)}{\text{Max}[\text{Aveg\_Within}(i), \text{Min}(\text{Aveg\_Between}(i, k))]} \quad (۳)$$

در رابطه فوق  $S(i)$  بیان کننده میزان مطلوبیت نمونه  $i$  ام در کلاس مورد نظر خودش، پارامتر  $\text{Aveg\_within}(i)$  نشان دهنده میانگین فاصله نمونه  $i$  ام از سایر نمونه‌های دیگر در آن کلاسی است که خود نمونه  $i$  ام وجود دارد و پارامتر  $\text{Aveg\_Between}(i, k)$  بیان کننده میانگین فاصله نمونه  $i$  ام از سایر نمونه‌هایی می‌باشد که در دسته دیگری مانند  $k$  قرار دارد [۳۰، ۴۳].

با محاسبه میزان مطلوبیت تحت عنوان میانگین مطلوبیت به تحلیل نتایج پرداخته می‌شود. مقدار مطلوبیت بین ۱- تا ۱+ تغییر می‌کند، که هرچه این مقدار به ۱+ نزدیکتر باشد نمونه مورد نظر در دسته بندی مناسب تر و هرچه به ۱- نزدیکتر باشد دارای دسته بندی نامناسبی است و عدد صفر به این معنی است که حضور نمونه مورد نظر در دسته فعلی و یا دسته دیگری دارای اهمیت چندانی نیست. بنابراین برای هر نمونه مقدار رابطه (۶) محاسبه میگردد و سپس با محاسبه میانگین اعداد حاصل شده تحت عنوان میانگین مطلوبیت دسته بندی انجام شده، به تحلیل نتایج پرداخته می‌شود. دومین معیار استفاده شده، تابع کیفیت است. بر اساس دانسته‌ها، بهترین خوشه بندی به صورتی است که مجموع تشابه بین مراکز خوشه و همه اعضای خوشه را حداکثر و مجموع تشابه بین مراکز خوشه‌ها را حداقل بشود. برای انتخاب بهترین خوشه، ابتدا یک محدوده پیشنهادی برای تعداد خوشه‌ها مشخص می‌شود. که در این پژوهش محدوده بین ۳ تا ۱۰ 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 نمود که به ازای آن فاصله بین مراکز خوشه‌ها و شباهت مراکز خوشه با اعضای درون هر خوشه حداکثر است. کیفیت نتایج خوشه بندی با  $k$  خوشه به صورت زیر تعریف می‌شود [۴۵، ۴۴]:

$$O = \{c^n | n = 1, \dots, k\} \quad (۴)$$

$$O^n = \{c_i | i = 1, \dots, \|T^c - O\|\} \quad (۵)$$

$$\rho(k) = \frac{1}{k} \sum_{n=1}^k \left( m_i n \left\{ \frac{\eta_n + \eta_m}{\delta_{nm}} \right\} \right) \quad (۶)$$

$$\eta_n = \frac{1}{\|\sigma^n\|} \sum_{c_j \in O^n} \text{Sim}(c_j, c^n) \quad (۷)$$

$$\eta_m = \frac{1}{\|\sigma^m\|} \sum_{c_j \in O^m} \text{Sim}(c_j, c^m) \quad (۸)$$

$$\delta_{nm} = \text{Sim}(C^n, C^m) \quad (۹)$$

در این معادلات  $O$  مجموعه مراکز خوشه‌ها،  $C^n$  مراکز خوشه‌ها،  $O^n$  مجموعه عناصری که به عنوان مراکز خوشه انتخاب نشده‌اند،  $T^c$  مجموعه کلیه عناصری که خوشه بندی روی آنها صورت گرفته است،  $\eta_n$  میانگین شباهت بین مرکز خوشه  $C^n$  و همه عناصر خوشه  $O^n$  است،  $\eta_m$  میانگین شباهت بین مرکز خوشه  $C^m$  و همه عناصر خوشه  $O^m$  است و در نهایت  $\delta_{nm}$  به عنوان شباهت  $C^n$  و  $O^n$  تعریف می‌شود [۴۴].

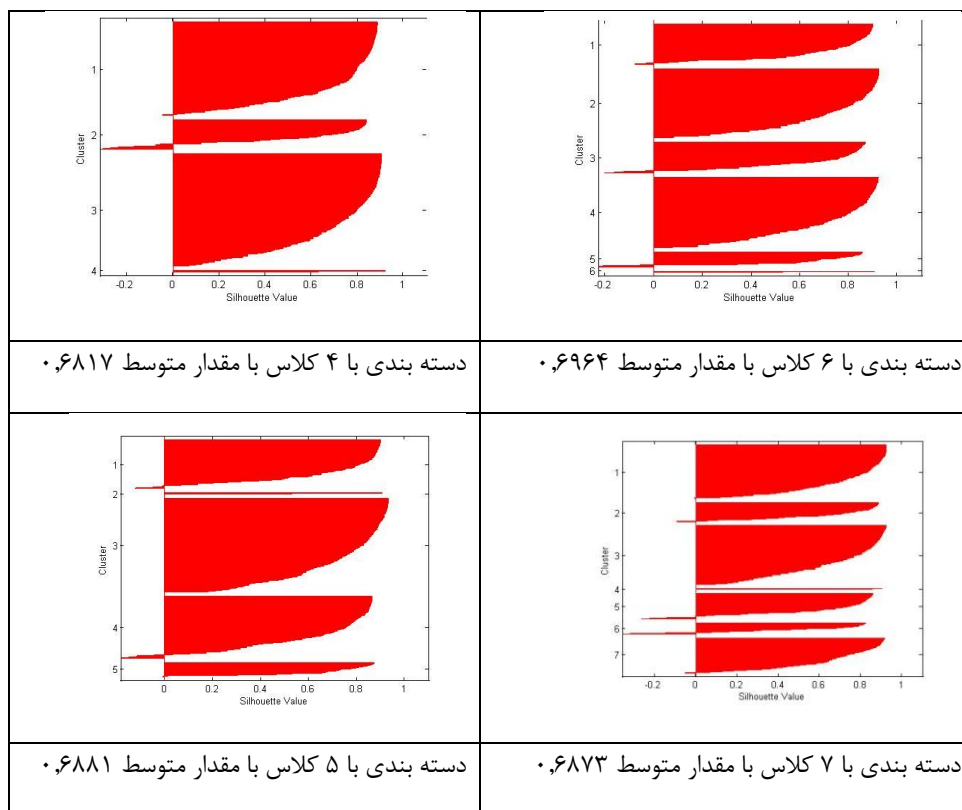
#### ۴-۱- رفتار سنجی تیتانیوم و روی

به منظور بررسی رفتار عناصر مربوطه نسبت به یکدیگر در ابتدا نیمرخ خوشه‌ها و میزان مطلوبیت هر نمونه برای دسته بندی‌های  $k=3$  و  $k=20$  برای عناصر تیتانیوم و روی نسبت به هم 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 ۵ مشاهده می شود ، مطابق با نمودارهای منتخب نیمرخ کلاس و با توجه به مقادیر مطلوبیت بهترین کلاس ، کلاس ۶ به عنوان بهترین دسته انتخاب می شود، زیرا هر چقدر میزان مطلوبیت به مقدار ۱ نزدیک باشد، نمونه‌ها به درستی در کلاس قرار گرفته اند. با توجه به نمودار ، مقادیر منفی تقریباً کمی در این دسته‌بندی نیز دیده می شود .


مقدار متوسط مطلوبیت در این دسته‌بندی برابر با ۰/۶۹۶۴ است که نسبت به مقدار متوسط مطلوبیت در دسته های دیگر این مقدار بیش تر بوده 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 مقدار مطلوبیت بهترین دسته بندی هر گروه فراتر نرفته و به ازای به بعد، روند کاهشی است.



شکل ۵ : نیمرخ خوشه‌ها و مقادیر مطلوبیت با ۴ تا ۷ کلاس مربوط به دو عنصر تیتانیوم و روی

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 ۶ مقدار  $S(i)$  برای دو عنصر تیتانیوم و روی را نشان داده دارای بیشترین مقدار مربوط به کلاس ۶ است. همچنین با توجه به تابع کیفیت و با استفاده از مقدار  $p(k)$  تعداد خوشه مناسب تعیین می‌شود. برای تعیین تعداد خوشه‌ها، مقدار  $p(k)$  با استفاده از رابطه ۶ برای مقادیر مختلف  $k$  محاسبه شده است. همانطور که بیان شد، مقدار حداکثر  $p(k)$  نشان‌دهنده تعداد مناسب خوشه ها است.

شکل ۶: مقدار ملاک اعتبارسنجی  $S(i)$  بر اساس تعداد خوشه‌ها، تیتانیوم-روی

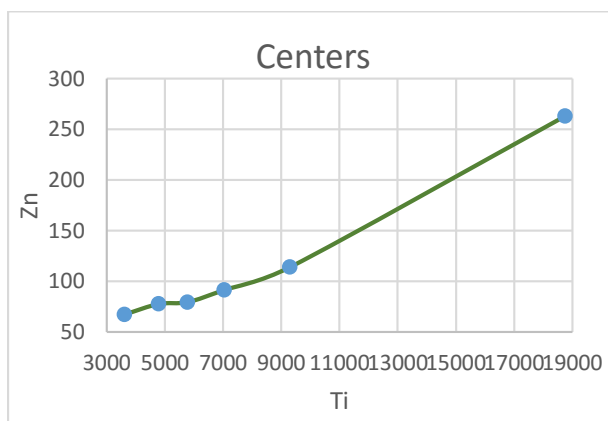


جدول ۲ مقادیر  $p(k)$  به دست آمده متناظر با تعداد خوشه‌ها را نشان می‌دهد. در رفتارسنجی دو عنصر تیتانیوم و مس،  $0.6845$  بیشترین مقدار است، بنابراین مناسبترین تعداد خوشه برابر با شش است همانطور که مشهود است، تعداد خوشه مناسب به دست آمده از تابع کیفیت با نتایج معیار  $S(i)$  مطابقت دارد.

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

$p(k)$	تعداد خوشه	عناصر	$p(k)$	تعداد خوشه	عناصر
0.4337	3	دو عنصر تیتانیوم و روی	0.6053	3	تیتانیوم، روی و موقعیت جغرافیایی
0.5298	4		0.7423	4	
0.5898	5		0.6709	5	
0.6845	6		0.6625	6	
0.5146	7		0.6584	7	
0.5674	8		0.6314	8	
0.5390	9		0.6125	9	
0.5252	10		0.6033	10	

مراکز دسته‌های تعیین شده به ازای بهترین دسته‌بندی که برای دو عنصر تیتانیوم و روی در شکل ۷ و به ازای ۶ کلاس به صورت نمودار نشان داده می‌شود. بر اساس این دسته‌بندی که در شکل ۷ مشخص است، به ازای افزایش عیار عنصر تیتانیوم، عیار عنصر روی افزایش می‌یابد. خط برازشی به صورت  $Y = 0.0132X + 6.717$  و ضریب همبستگی آن نیز برابر با  $R^2 = 0.9774$  به دست آمده است.



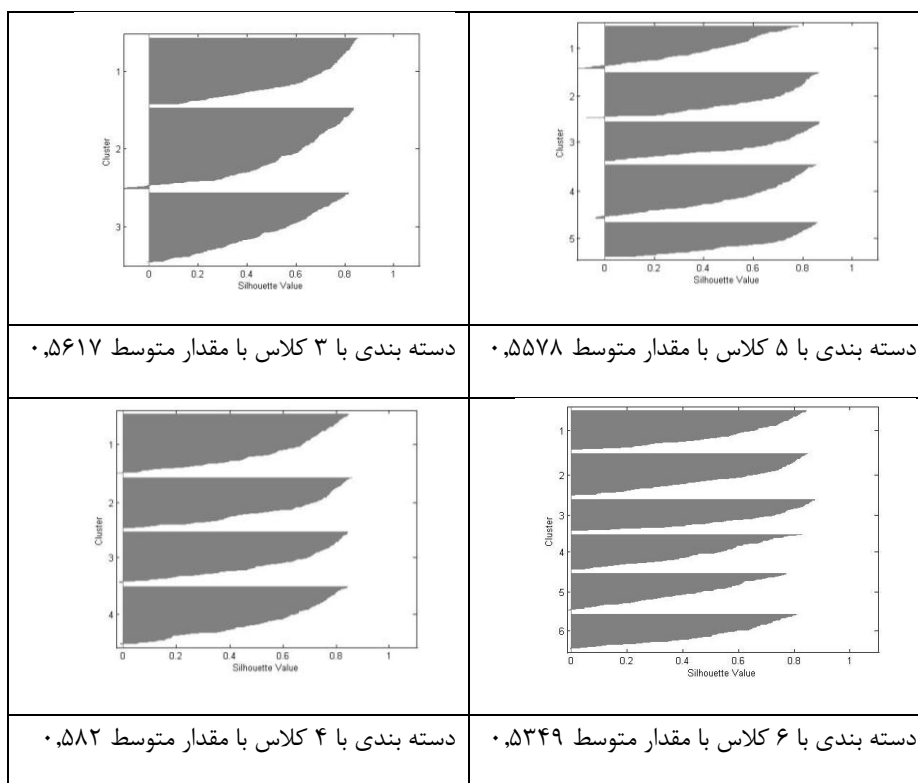
شکل ۷: بهترین خط برازش شده به مراکز دسته‌ها برای تیتانیوم و روی



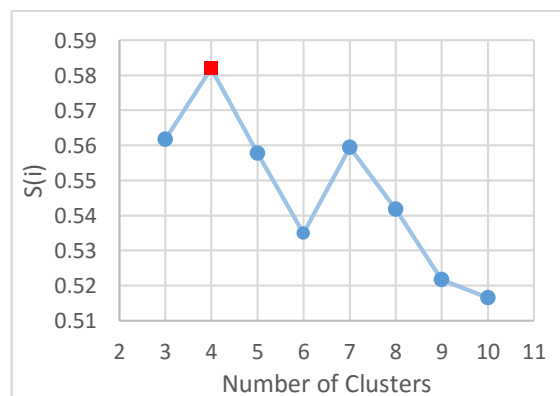
### ۴-۲- بررسی رفتار ساختاری تیتانیوم، روی و مختصات

نیمرخ خوشه‌ها و میزان مطلوبیت دسته بندی های صورت گرفته با توجه به مقدار  $K=3$  الی  $K=6$  در مورد عناصر تیتانیوم و روی (با در نظر گرفتن طول و عرض نقاط) در شکل ۸ آورده شده است.

بر اساس نتایج حاصل شده به ازای مقادیر متفاوت برای  $K$  از ۳ و ۶، همانطور که مشاهده شد، دسته‌بندی روی نمونه‌های تعریف شده با مشخصه های عیار تیتانیوم و روی و همچنین طول و عرض نمونه های برداشت شده، به ازای ۳ کلاس دارای بهترین دسته‌بندی است. همچنین با توجه به شکل ۹، 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 ۱۵ افزایش داده شده است، اما مقدار مطلوبیت از کلاس فوق فراتر نرفت و به ازای بالاتر از ۱۵ کلاس نیز روند کاهشی داشت.



شکل ۸: نیمرخ خوشه‌ها و مقادیر مطلوبیت با کلاس‌های ۳ تا ۶ مربوط به تیتانیوم و روی (همراه مختصات)



شکل ۹: تغییر مقدار ملاک اعتبارسنجی ( $S(i)$ ) براساس تعداد خوشه‌ها (برای عناصر تیتانیوم و روی و مختصات)

مشخصات مراکز خوشه‌ها با پنج کلاس در جدول ۳ آورده شده‌اند.

جدول ۳: مشخصات مراکز خوشه‌ها

Length	Width	Au	As	Class
۱	۰.۱۰۵۰۴۶	۰.۸۷۴۲۹۶	۰.۰۹۵۱۱	First
۰.۰۸۷۷۳۴	۰	۱	۰	Second
۰.۸۹۹۷۶۹	۱	۰.۷۰۹۸۶۷	۱	Third
۰	۰.۸۲۴۳۴۹	۰	۰.۳۳۸۲۶۳	Forth

### ۴-۲-۱- پیش‌بینی عیار تیتانیوم

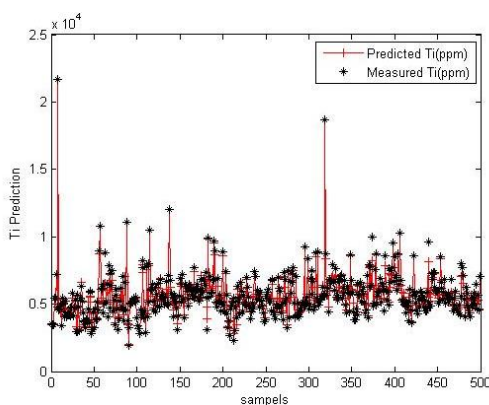
در این قسمت با استفاده از رشته کد های شبکه عصبی مصنوعی رگرسیون عمومی در نرم‌افزار متلب به تعیین توانایی تخمین تیتانیوم توسط روی با توجه به طول و عرض نمونه‌های برداشت شده با استفاده از ۷۰٪ نمونه‌ها که به صورت تصادفی انتخاب گردیده و همچنین تعیین اعتبار تخمین با ۳۰٪ نمونه باقی مانده پرداخته شده است. شایان ذکر است برای تخمین هر چه بهتر، مقادیر در بازه صفر تا یک مطابق فرمول [۵۳] استاندارد سازی گردیده است. مقادیر عنصر تیتانیوم به عنوان متغیر خروجی و مقادیر روی همراه طول و عرض نقاط به عنوان متغیرهای ورودی جهت تعیین الگوریتم تخمین به نرم‌افزار معرفی می‌گردند.

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


### ۴-۳- تخمین با شبکه عصبی مصنوعی رگرسیون عمومی

با توجه به نیاز تعیین شعاع بهینه [۴۷] جهات تخمین هر چه بهتر در این روش، مقادیر مختلفی از ۰ تا ۱ به صورت تجربی انتخاب شد. مقدار بهینه ۰/۱۵ برای شعاع تاثیر انتخاب گردید.

در شکل ۱۰ می‌توان میزان خط پیوسته تخمینی و عیارهای نقطه ای واقعی را در داده‌های آموزشی و شکل ۱۱ نشان دهنده همین امر بر داده‌های آزمایشی است.




شکل ۱۰: خط تخمین تیتانیوم همراه مقادیر واقعی در داده‌های آموزشی




شکل ۱۱: خط تخمین تیتانیوم همراه مقادیر واقعی داده‌های آزمایشی

نظر به 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 اشکال ۱۲ و ۱۳ آورده شده است.

صحت (R) این برآورد ها در داده های آموزشی برابر ۰/۹۷ و برای داده های آزمایشی ۰/۷۳ تعیین شد.



شکل ۱۳: رگرسیون داده های تخمینی در مقابل واقعی (آزمایشی)



شکل ۱۲: رگرسیون داده های تخمینی در مقابل واقعی (آموزشی)

## ۵- نتیجه گیری

با توجه به وجود شواهد کانی سازی تیتانیوم در منطقه کیوی واقع در استان اردبیل، بررسی وسعت هاله‌های ژئوشیمیایی و رفتار عناصر پارائنز تیتانیوم در منطقه اهمیت می‌یابد بدین منظور با استفاده از روش کا-میانگین به بررسی رفتار تیتانیوم و روی در محدوده کیوی نسبت به هم پرداخته شد و بررسی، رابطه و معادله‌های همراه با ضریب همبستگی ارائه گردید. سپس با استفاده از روش مذکور، 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 عیار عنصر تیتانیوم بر حسب روی، طول و عرض نقاط نمونه‌برداری انجام گرفت و صحت (R) تخمین در داده های آزمایشی در شبکه عصبی مصنوعی رگرسیون عمومی برابر با ۰/۷۳ 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 تیتانیوم در منطقه ارجح دانست.

مراجع

- [1] Majdifar, S., Kamali, GH. (2014). Iron Grade Estimation Using ANFIS Algorithm at Tappeghermez Anomaly of Sangar Mine. Journal of Analytical and Numerical Methods in Mining Engineering (ANM). No 5. (in Persian)
- [2] 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)
- [3] ShayesteFar, M., Rasa, I. (2005). Multivariate Data Analysis of Qanat Marvan Lead-Zinc Deposit., Kerman. Geosciences Scientific Quarterly Journal. No, 57. (in Persian)
- [4] 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.
- [5] Abolhassani, B., Salt, J. E. (2005). A Simplex Kmeans Algorithm for Radio-Port Placement in Cellular Networks. In Canadaian Conference on Electrical and Computer Engineering.
- [6] Chen, T. W., Chien, S. Y. (2009). Bandwidth Adaptive Hardware Architecture of K-Means Clustering for Video Analysis. IEEE Transactions on VLSI Systems.
- [7] Yang, J., Zhuang, Y., Wu, F. (2012). ESVCbased extraction and segmentation of texture features. Computers & Geosciences, Elsevier, 49, 238-247.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] Mohaghegh, S. and Ameri, S., 1995, Artificial Neural Network As A Valuable Tool For Petroleum Engineers, SPE29220, Proceedings, SPE, West Virginia.
- [14] 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 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 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
- [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) Schalkoff, R. J. (1997). Artificial neural networks (Vol. 1). New York: McGraw-Hill.
- [31] Yegnanarayana, B. (2009). Artificial neural networks. PHI Learning Pvt. Ltd..
- [32] Dayhoff, J. E., & DeLeo, J. M. (2001). Artificial neural networks. Cancer, 91(S8), 1615-1635.
- [33] Abraham, A. (2005). Artificial neural networks. handbook of measuring system design.
- [34] Demuth, H., & Beale, M. (1993). Neural Network Toolbox For Use with Matlab--User'S Guide Verion 3.0.
- [35] Rolon, L. F. (2002). Developing intelligent synthetic logs: Application to Upper Devonian units in Pennsylvania.
- [36] Specht, D. F. (1991). A general regression neural network. IEEE transactions on neural networks, 2(6)
- [37] 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.
- [38] Demuth, H., & Beale, M. (2002). Neural Network Toolbox For Use with Matlab--User'S Guide Verion 4.0.
- [39] 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.
- [40] 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.
- [41] Tarkian, M., Stribny, B. (1999). Platinum group elements in porphyry copper deposits: a reconnaissance study. Mineralogy & Petrology, Springer-Verlag, 65, 161-183.
- [42] 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)
- [43] Shina, H.W. and Sohb, S.Y. (2004). Segmentation of Stock Trading Customers According to Potential Value, Expert Systems with Applications, 27, 27-33
- [44] 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).
- [45] 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
- [46] 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.
- [47] Gaborski, R. S. (1991). U.S. Patent No. 5,052,043. Washington, DC: U.S. Patent and Trademark Office