مجله‌ی علمی و پژوهشی شریف
تیر ۱۳۸۷، شماره‌ی چهل و دوم، ص. ۲۲-۲۷

دسته‌بندی ناپیوستگی‌های موجود در توده‌سنگ با استفاده از شبکه عصبی رقابتی در چهارچوب احتمالات

اسماعیل افلاکی (استادیار)
دانشکده‌ی مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر
سیامک هاشمی (دکتری)
شرکت مشاور

دسته‌بندی دقیق ناپیوستگی‌ها در توده‌های سنگ در تحلیل و طراحی سازه‌های سطحی روی سنگ نقش مهمی ایفا می‌کند. روش سنتی دسته‌بندی ناپیوستگی‌ها مبتنی بر تعیین چگالی سطحی توزیع قطب ناپیوستگی‌ها بر روی صفحه‌ی استریونت است. استفاده از روش‌های مختلف تعیین چگالی سطحی، به نتایج متفاوتی منجر خواهد شد.
در این نوشتار به‌منظور دسته‌بندی ناپیوستگی‌ها از ترکیب روش‌های هوش مصنوعی با روش‌های احتمالاتی استفاده شده است. از مزایای این روش، تعیین دقیق تعداد دسته‌های ناپیوستگی و تعیین تعلق هر ناپیوستگی به دسته‌ی خاص و مستقل بودن آن از توزیع داده‌ها است.

eaflaki@aut.ac.ir
siamak_hashemi@yahoo.com

واژگان کلیدی: ناپیوستگی، شبکه‌ی عصبی، ترازبندی، استریوگرافیک.

۱. مقدمه

رفتار توده‌های سنگ تا حد زیادی تحت تأثیر ناپیوستگی‌های موجود در آن است. شکست‌های متعدد شیروانی‌های سنگی و نیز لغزش‌های گوه‌یی را می‌توان به وجود درزه و ترک در توده‌سنگ نسبت داد. ناپیوستگی‌ها، در طبقه‌بندی مهندسی توده‌های سنگ نیز نقش اساسی دارند. بنابراین چه در مهندسی عمران و چه در مهندسی معدن، جمع‌آوری و تحلیل دقیق داده‌های مربوط به ناپیوستگی‌های موجود در محیط‌های سنگی اهمیت به‌سزایی دارد.

روش‌های تعیین و اندازه‌گیری ناپیوستگی‌ها را می‌توان به دو گروه کلی تقسیم کرد: نمونه‌گیری به‌وسیله‌ی حفر گمانه و نمونه‌برداری از رخنمون‌های توده‌سنگ. در روش اول می‌توان از مغزه‌های بازیافت شده به همراه سایر داده‌ها برای تعیین جهت درزه‌ها، هندسه‌ی سطحی و غیره استفاده کرد. به‌علاوه می‌توان دیواره‌های گمانه‌ها را به‌وسیله‌ی دوربین‌های مدار بسته بررسی‌کرد. همچنین گمانه‌ها دسترسی برای ابزارهای ژئوفیزیکی، برای به دست آوردن اطلاعات دیگر در مورد ساختار توده‌سنگ را ممکن می‌سازند. در روش دوم، امتداد ناپیوستگی‌ها ـ به ویژه هنگامی که به سطح زمین می‌رسند ـ مشخص است و درنتیجه با نقشه‌برداری از رخنمون‌ها، اندازه‌گیری مستقیم پارامترهای ناپیوستگی میسر می‌شود.

ناپیوستگی‌ها در توده‌سنگ به گروه‌های متعدد، نظیر لایه‌بندی، گسل، درزه و غیره، تقسیم می‌شوند. اطلاعات دقیق‌تر درمورد انواع ناپیوستگی در منابع متعدد تشریح شده‌اند.[۱] ناپیوستگی‌ها عموماً به‌صورت دسته‌یی و متمایل به یک الگو رخ می‌دهند. هنگامی که از رخنمون‌ها نقشه‌برداری می‌شود، رابطه‌ی زمین‌شناسی بین گروه‌های ناپیوستگی و اطلاعات مربوط به نوع ناپیوستگی‌ها را نیز ثبت می‌کنند. بنابراین، اطلاعات جمع‌آوری شده درمورد «ناپیوستگی‌ها در حین نقشه‌برداری» در تحلیل درزه‌ها اهمیت زیادی دارد.

اطلاعاتی درمورد جهت‌یافتگی ناپیوستگی، نوع ناپیوستگی، زبری سطح ناپیوستگی، گسترش، اندازه‌ی دهانه، نوع و میزان پرشدگی، شرایط رطوبتی و سایر خصوصیاتی که مهم تشخیص داده شده‌اند مجموعه داده‌های معمولی در ارتباط ناپیوستگی‌ها را تشکیل می‌دهند. بعضی خصوصیات ثبت شده از ناپیوستگی‌ها در طی نقشه‌برداری (مانند جهت‌گیری و اندازه‌ی دهانه) ذاتاً کمّی‌اند، در حالی که سایر خصوصیات ناپیوستگی‌ها کیفی هستند. خصوصیات ناپیوستگی‌ها براساس شباهت‌هاشان به زیرگروه‌ها یا دسته‌ها تقسیم می‌شوند. ابزار تحلیل داده‌های مربوط به درزه‌ها و تقسیم آنها به دسته‌های مختلف عمدتاً مبتنی بر ترازبندی قطب‌های درزه و درزه‌ها (خطوط عمود بر صفحات ناپیوستگی) بر روی صفحات استریوگراف می‌باشند. امروزه برنامه‌های رایانه‌یی این کار را به‌راحتی انجام می‌دهند یکی از این برنامه‌ها نرم‌افزار DIPS است.[۲] در این روش تحلیل‌گر داده‌ها، دسته‌های مختلف درزه را از روی نمودار ارائه شده توسط برنامه معین می‌کند. یکی از ایرادهای اساسیِ

برنامه‌ی DIPS این است که تعیین چگالی قطب‌ها روی صفحه به‌وسیله‌ی حرکت دادن یک دایره بر روی آن صورت می‌گیرد و به‌همین دلیل با تغییر قطر دایره یا تغییر الگوی حرکت آن، منحنی‌های تراز تغییر می‌کند.[۴] بنابراین جدا کردن دسته درزه‌ها با استفاده از ترازبندی جهت‌گیری قطب‌ها روی صفحات استریوگرافیک یک فرایند ذهنی است که بستگی به طرز تفکر فرد تحلیل‌گر دارد. در این روش تحلیل‌گران مختلف می‌توانند بسته به پیش‌زمینه و تجربه‌ی فردی خود به جواب‌های بسیار متفاوتی برسند. در مواردی که مرز بین دسته درزه‌ها نامشخص باشد، تفاوت در نتایج تشدید می‌شود.

برای حل وابستگی مسئله به قضاوت فردی برای اولین بار در سال ۱۹۷۶ یک الگوریتم خوشه‌یی برای دسته‌بندی داده‌ها ارائه شد[۱] که بعدها توسعه‌ی بیشتری یافت.[۵] در حال حاضر از روش‌های آماری مثل رگرسیون[۱]، تحلیل تصمیم‌گیری[۲] و تحلیل دسته‌یی[۳] و اخیراً روش‌های هوش مصنوعی استفاده می‌شود. پس از دسته‌بندی، مرکز هر دسته درزه محاسبه شده و به‌عنوان نماینده‌ی آن دسته‌درز، در طراحی‌ها استفاده می‌شود. الگوریتم ارائه شده در این نوشتار مبتنی بر نوعی هوش مصنوعی موسوم به «شبکه‌ی عصبی» است که وظیفه دسته‌بندی داده‌ها و تعیین مرکز هر دسته را برعهده دارد.

۲. شبکه‌های عصبی

در سال‌های اخیر، در جوامع علمی تمایل رو به افزایشی نسبت به ابزار رایانه‌یی که سیستم زیست‌شناختی مغز انسان را شبیه‌سازی می‌کند، ایجاد شده است. این ابزار که به‌عنوان شبکه‌های عصبی مصنوعی شناخته می‌شود در شاخه‌های مختلف علوم و مهندسی کاربرد گسترده‌یی دارد. و یکی از خصوصیات جالب این نرم‌افزار این است که توانایی یادگیری و عمومی‌سازی دارند. البته باید توجه داشت که یادگیری در شبکه‌های عصبی مصنوعی محدود است و آنچه عملاً مورد توجه قرار می‌گیرد توانایی محاسباتی این شبکه‌ها است. این عمل در نورون، (سلول عصبی) که واحد پایه‌ی پردازش اطلاعات یک شبکه‌ی عصبی مصنوعی است انجام می‌گیرد. شبکه‌های عصبی متعددی طراحی شده‌اند که از ساختارها و عملگرهای متعدد استفاده می‌کنند. در این تحقیق از شبکه‌های عصبی رقابتی استفاده می‌شود که در ادامه به تشریح آنها می‌پردازیم.

۱.۲. شبکه‌های عصبی رقابتی

شبکه‌های عصبی رقابتی نوعی از شبکه‌های عصبی‌اند که در دسته‌بندی اطلاعات یا شناسایی تعلق داده‌ها به دسته‌ها کاربرد دارند. شمای کلی یک شبکه‌ی عصبی رقابتی در شکل ۱ نشان داده شده است.

در این شبکه، $\underline{p}$ بردار ورودی است که R عضو دارد. W ماتریس وزن است که هر سطر آن، بردار وزن مربوط به یک نورون است. $\underline{n}$ حاصل‌ضرب داخلی $\underline{p}$ در W است و هر عضو آن، فاصله‌ی بردار وزن هر نورون از نقطه‌ی $\underline{p}$ است. اگر بردارها را به‌هنجار کنیم $\underline{n}$ برابر کسینوس زاویه بین دو بردار است. تعداد اعضای $\underline{n}$ برابر تعداد نورون‌هاست. $comp$ یک تابع است که با استفاده از $\underline{n}$ و خروجی شبکه $\underline{a}$ را تولید می‌کند. $\underline{a}$ برای نورون با کم‌ترین فاصله (بزرگ‌ترین $\underline{n}$) برابر یک، و برای بقیه‌ی نورون‌ها برابر صفر است و تعلق ورودی به نورون و دسته داده‌ی برنده را نشان می‌دهد. b «بردار اریبی» نام دارد و وظیفه‌ی آن حل مشکل نورون مرده است. «نورون مرده» نورونی است که شانسی برای برنده‌شدن ندارد. در یک تفسیر فیزیکی،

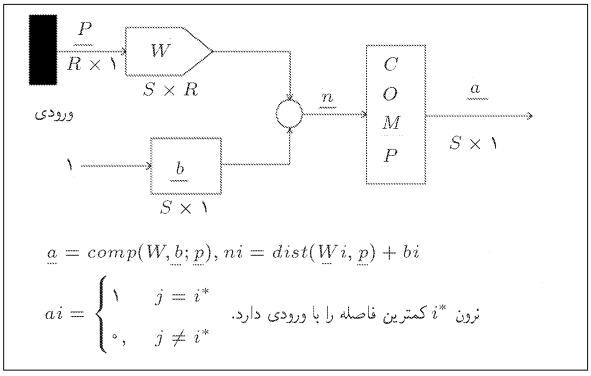

شکل ۱. نمای یک شبکه‌ی عصبی رقابتی.

نورون مرده نورونی است که از تمام مراکز داده دور افتاده است. با ثبت تعداد دفعاتی که نورون‌ها در رقابت برنده شده‌اند می‌توان نورون‌های مرده را پیدا کرد. پس از این کار مقدار بایاس نورون مرده در هر مرحله افزایش می‌یابد تا با بزرگ شدن مقدار $\underline{n}$ و در واقع بزرگ‌تر شدن منطقه‌ی تحریک نورون، احتمال برنده شدن نورون و در نتیجه حرکت کردن آن به سمت یکی از محل‌های تمرکز داده افزایش پیدا کند.

۱.۱.۲. قانون یادگیری

در شبکه‌های عصبی دو روش کلی برای آموزش و یادگیری وجود دارد: یادگیری نظارت شده و یادگیری غیرنظارت شده[۶]، که قانون یادگیری شبکه‌های عصبی رقابتی در گروه دوم (یادگیری بدون ناظر) قرار می‌گیرد. در این روش دسته آموزشی فقط شامل بردارهای ورودی است و الگوریتم آموزش وزن‌های شبکه را برای تولید بردارهای خروجی هماهنگ تعدیل می‌کند. هدف از این کار تولید الگویی یکسان از خروجی‌ها، با استفاده از بردارهای دسته آموزشی یا برداری است که به بردار مورد نظر در دسته آموزشی بسیار شبیه است. در این شبکه‌ها چنان‌که از نام آن‌ها برمی‌آید، خروجی سلول‌های عصبی با یکدیگر به رقابت می‌پردازند تا یکی از آن‌ها که امتیاز بیشتری دارد در رقابت برنده شده و از سایر سلول‌ها متمایز شود. برای این کار به یک قانون یادگیری مناسب که برای آموزش ماتریس وزن در شبکه رقابتی قابل استفاده باشد مورد نیاز است. باید توجه داشت که هنگامی استفاده از قانون یادگیری مطرح خواهد بود که دسترسی به الگوهای مرجع ممکن نباشد، زیرا در غیر این‌صورت می‌توان با استفاده از الگوهای مرجع، ماتریس W را ساخت. قانون یادگیری مورد استفاده در اینجا قانون یادگیری کوهونن است[۶و۷] قانون کوهونن به وزن‌های یک نورون اجازه می‌دهد که بردار ورودی را یاد بگیرد. به این دلیل نورونی که بردار وزن آن به بردار ورودی نزدیک‌تر باشد طوری تنظیم می‌شود که به این بردار نزدیک‌تر باشد. در نتیجه احتمال برنده شدن نورون که در رقابت بعدی که بردار مشابهی ارائه می‌شود بیشتر است و در زمانی که بردار ورودی ارائه شده بسیار متفاوت باشد کم‌تر است. شکل کلی قانون یادگیری کوهونن چنین است:

$$W_i(k) = W_i(k-1) + \alpha a_i(k)[\underline{p}(k) - W_i(k-1)]$$

در این رابطه W بردار وزن مربوط به نورون iام در تکرار kام، و $\underline{p}$ بردار هدف است. α نرخ یادگیری است که نشان‌دهنده‌ی میزان تغییرات وزن نورون‌ها در طول آموزش بوده و دامنه‌ی تغییرات آن بین صفر و یک است. مقدار مناسب نرخ یادگیری برای هر مسئله با سعی و خطا قابل تعیین است و معمولاً در ابتدا از میانگین ۰٫۵ استفاده می‌شود. در ادامه، پیرامون تعیین نرخ یادگیری مناسب بحث خواهد شد. a ضریبی است که مقدار آن برای نورون برنده یک و برای بقیه نورون‌ها صفر است.

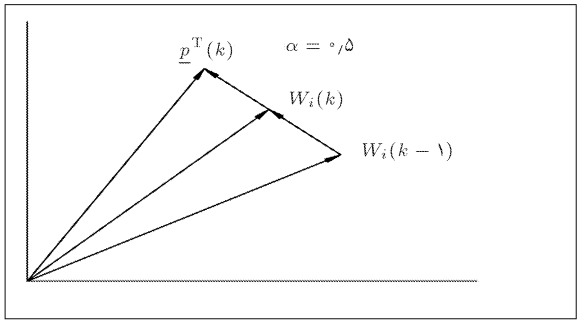

شکل ۲. حرکت بردار وزن به سمت بردار هدف.

بنابراین تنها وزن نورون برنده تغییر می‌کند و به بردار هدف نزدیک‌تر می‌شود (بردار هدف هر بار به‌صورت اتفاقی از بین داده‌ها انتخاب می‌شود). نورون برنده نورونی است که بردار وزن آن بیش از بردارهای وزن بقیه نورون‌ها به بردار هدف نزدیک باشد. بنابراین بردار وزن نورون برنده به‌سمت بردار هدف حرکت می‌کند. این حرکت در مسیری قرار دارد که بردار وزن قدیمی را به بردار ورودی وصل می‌کند (شکل ۲).

۳. الگوریتم استفاده شده

شبکه‌ی استفاده شده در این نوشتار از نوع رقابتی با قانون یادگیری کوهونن است. الگوریتم ارائه شده از دو بخش تشکیل می‌شود که در بخش اول تعداد دسته درزه‌ها مشخص می‌شود و در بخش دوم مرکز هر دسته درزه به دست می‌آید. روش دسته‌بندی در بخش اول مبتنی بر ایده‌ی تصویرکردن مشخصه‌های هر صفحه‌ی شکستگی مانند جهت و شیب روی شبکه استریوگرافیک است. به‌جای تصویر هر صفحه از نقطه‌ی قطب آن صفحه استفاده می‌شود. تمرکز قطب‌ها در واحد سطح شبکه‌ی استریوگرافیک متناسب با تمرکز واقعی صفحات شکستگی در یک جهت مشخص است.[۸] یک شبکه می‌تواند امتداد ترجیحی یک دسته قطب را در سه بعد نشان دهد. مسئله‌ی مهم در این تصویر کردن، انتخاب صفحات شکستگی مناسب است. داده‌های مورد استفاده که همان نقاط قطب صفحات هستند، ابتدا باید طوری انتخاب شوند که بیشترین واریانس و دامنه‌ی وسیع‌تری داشته باشند. باید توجه داشت که در حین آموزش فاصله بین ورودی جدید تا بردار وزن همه نورون‌ها محاسبه می‌شود و چنان که ذکر شد نورونی که بردار وزنش کم‌ترین فاصله را تا ورودی داشته باشد نورون برنده است. با توجه به تغییر وزن نورون برنده و همسایگانش در طول آموزش، با بالا رفتن دقت شبکه‌ی میزان واریانس و در واقع شعاع همسایگی کاهش می‌یابد. مراحل یافتن این خطوط عبارت‌اند از:[۱۰و۱۱]

۱. محاسبه‌ی بزرگ‌ترین مقدار ویژه، ماتریس کواریانس مجموعه داده‌ها، و مشخص کردن بردار ویژه‌ی مربوط به آن مقدار ویژه؛
۲. تصویرکردن داده‌ها برروی این بردار ویژه (از طریق ضرب داخلی) و به‌دست آوردن بردار توزیع چگالی؛
۳. تقسیم مجموعه داده‌ها در هر نقطه‌یی که بردار توزیع چگالی مقداری برابر صفر یا نزدیک به صفر دارد؛
۴. اگر چنین نقطه‌یی یافت نشد این فرایند با استفاده از بردار ویژه‌ی مربوط به دومین مقدار ویژه‌ی بزرگ تکرار می‌شود؛ و اگر برای هیچ‌کدام از بردارهای ویژه تقسیم‌بندی یافت نشد عملیات متوقف می‌شود و نتیجه گرفته می‌شود که تنها یک گروه (کلاس) داده موجود است؛
۵. برای تقسیم‌بندی بیش‌تر مجموعه داده‌ها، برای داده‌های هر بخش تقسیم شده عملیات بالا تکرار می‌شود.

در بخش دوم الگوریتم تعداد دسته درزه‌ها از بخش اول گرفته شده و یک شبکه‌ی رقابتی کوهونن براساس آن‌ها (تعداد نورون‌های شبکه برابر تعداد دسته درزه‌ها) ساخته می‌شود. بخش دوم الگوریتم نیز خود به دو مرحله تقسیم می‌شود. مرحله‌ی اول مشابه قانون یادگیری کوهونن است و با چند تکرار، هر نورون به یکی از دسته‌درزه‌ها تخصیص داده می‌شود. مرحله‌ی دوم کار مربوط به دقیق‌کردن این اختصاص و یافتن مراکز دسته درزه‌ها است.

در الگوریتم یادگیری کوهونن، میزان اصلاح بردار وزن نورون برنده، برای همه‌ی داده‌های مربوط به آن دسته، با فاصله بردار وزن با نقطه‌ی هدف رابطه‌ی مستقیم دارد. از آن‌جا که بردار وزن برای هر ورودی اصلاح می‌شود لذا وجود حتی یک نقطه با فاصله‌ی زیاد از مرکز دسته درزه، نورون را از مرکز دورکرده و به‌شدت به سمت خود می‌کشاند. بنابراین نتایج حاصله در هر تکرار متفاوت است و هیچ‌گاه دقیق نیستند. در این نوشتار برای حل این مشکل در مرحله‌ی دوم دو طریقه‌ی اصلاح در الگوریتم یادگیری کوهونن ارائه شده است. مراکز تقریبی از شبکه‌ی کوهونن عادی گرفته شده و با این الگوریتم اصلاح شده‌اند.

تغییر اول در این الگوریتم عبارت است از ایجاد رابطه‌ی معکوس بین اصلاح وزن نورون برنده و فاصله‌ی آن با بردار هدف. این مفهوم همان مفهوم میانگین وزنی است به این معنی که نورون در نهایت بر روی مرکز وزنی هر دسته درزه قرار خواهد داشت. باید توجه داشت که این کار در مرحله‌ی دوم انجام می‌شود. در ابتدا که محل تقریبی دسته درزه‌ها مشخص نشده، انجام این کار مانع از تقسیم دسته درزه‌ها بین نورون‌ها می‌شود ولی پس از این مرحله باعث بالا رفتن دقت جواب و نیز ثابت شدن آن نسبت به تعداد تکرارها به میزان زیادی خواهد شد.

اصلاح دوم مربوط به ضریب α در رابطه‌ی اصلاح وزن الگوریتم کوهونن است. این ضریب همان نرخ یادگیری است که در روش استاندارد همواره ثابت است. در هنگام به دست آوردن مراکز دسته درزه‌ها تعداد کمی داده‌ی پراکنده در اطراف دسته درزه وجود دارند، که عملاً اهمیتی ندارند. α به‌عنوان نرخ یادگیری مشخص‌کننده‌ی میزان پاسخ نورون نسبت به داده‌ها است. بنابراین کوچک کردن α به معنی کوچک‌تر شدن منطقه‌ی پاسخ نورون است، همان‌طور که با بزرگ کردن α این منطقه بزرگ‌تر می‌شود. برای از دور خارج‌کردن این داده‌های پراکنده، بعد از هر بار تکرار α کوچک‌تر می‌شود و در نهایت نورون تنها به بخش متمرکز دسته درزه، که اهمیت بیشتری دارد، در نظر گرفته می‌شود.

مزیت این روش نسبت به روش ترازبندی این است که در روش ترازبندی قسمتی که دارای بیش‌ترین چگالی است (و بسته به روش ترازبندی متغیر است) به‌عنوان مرکز و نماینده‌ی دسته درزه، در نظرگرفته می‌شود. این در حالی است که در این روش از ترازبندی استفاده نمی‌شود، بلکه از داده‌ها به‌طور مستقیم استفاده می‌شود و در ضمن با گرفتن میانگین وزنی، همه‌ی داده‌های دسته درزه در پیدا کردن نماینده‌ی دسته تأثیر داده شده‌اند که مطمئناً نتیجه‌ی کار دقیق‌تر خواهد بود. مزیت دیگر این روش مستقل بودن آن از توزیع داده‌هاست. در روش ترازبندی در صورت کم‌بودن داده‌ها برای هر داده‌ی توزیع فیشر[۱۲و۱۳] فرض شده و به‌وسیله‌ی آن داده‌های اضافی تولید می‌شود. در حالی که الگوریتم ارائه شده نیازی به توزیع داده‌ها ندارد و با تعداد داده‌ی کم هم جواب مناسب دریافت خواهیم کرد. ضمناً این الگوریتم این توانایی را دارد که هر داده‌ی قبلی یا جدید را گرفته و مشخص کند که به کدام دسته درزه تعلق دارد.

۴. آزمایش الگوریتم

برای آزمایش الگوریتم یکی از فایل‌های نمونه ارائه شده توسط نرم‌افزار DIPS انتخاب شده است. مجموعه داده‌ها متشکل از ۱۹۵ دسته داده مربوط به درزه‌ها است. تحلیل نتایج چگالی سطحی بسته به تجربه‌ی فرد خبره می‌تواند منجر به تشخیص ۳ یا ۴ دسته درزه شود (شکل ۳). در این‌گونه تحلیل‌ها، تعلق هر داده به یک دسته درزه‌ی خاص، از پیش مشخص نیست. این موضوع در مورد داده‌های جدید هم صدق می‌کند. با توجه به نتایج بخش دسته بندی الگوریتم ارائه شده، داده‌ها به ۴ دسته تقسیم می‌شوند. نتایج مربوط به مراکز دسته‌ها (توسط الگوریتم استاندارد کوهونن) را می‌توان در شکل ۴ مشاهده کرد.

همان‌طورکه در شکل ۴ مشاهده می‌شود باید به تغییرات زیاد مراکز در تکرارهای مختلف و دقت نامناسب آن‌ها توجه داشت. در شکل ۵ نتایج الگوریتم پیشنهادی نشان داده شده است (مراکز محاسبه شده به‌صورت نقطه‌چین نشان داده شده‌اند). در دو تکرار اول از الگوریتم عادی استفاده شده و از آن به بعد، الگوریتم اصلاحی

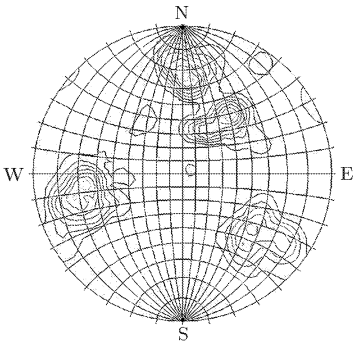

شکل ۳. نتایج حاصل از تحلیل داده‌ها با نرم‌افزار DIPS.

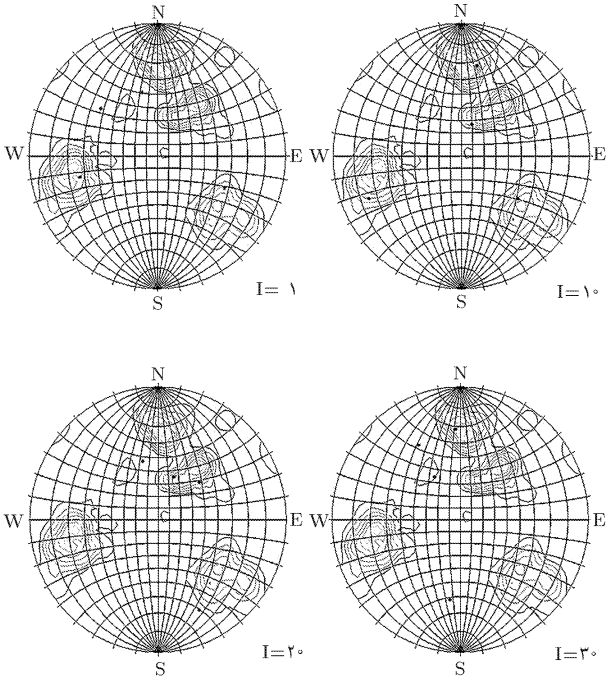

شکل ۴. مراکز دسته‌ها در الگوریتم کوهونن عادی (I دفعات تکرار الگوریتم).

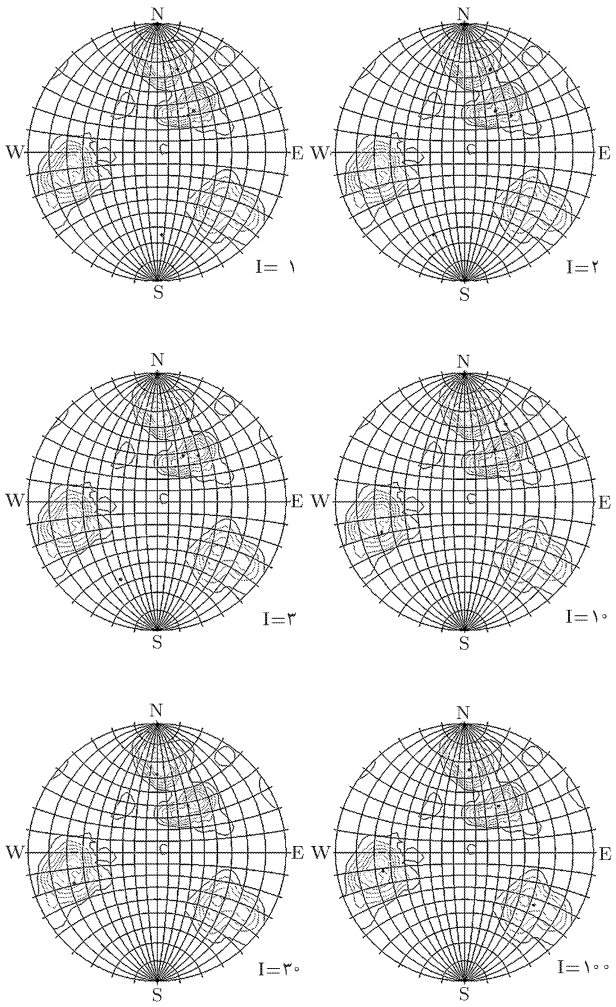

شکل ۵. مراحل تحلیل با الگوریتم پیشنهادی (I نشان‌دهنده دفعات تکرار الگوریتم).

مطرح می‌شود. از آن‌جا که الگوریتم برای این هدف طراحی شده می‌توان دید که نتایج از دقت بالایی برخوردارند. منحنی‌های تراز شکل ۵ توسط نرم‌افزار DIPS رسم شده و برای نرم‌تر و دقیق‌تر شدن آن‌ها در دسته‌هایی که تعداد داده‌ی آن‌ها کم است، مقداری داده‌ی اضافی طبق توزیع فیشر تولید شده است. چنان‌که مشاهده می‌شود، با وجود این که در الگوریتم ارائه شده از هیچ داده‌ی اضافی استفاده نشده است، مراکز به دست آمده برای هر دسته برای داده‌های اضافی نیز صدق می‌کنند. با بالا رفتن دفعات تکرار، نتایج به مراکز دسته درزه‌ها نزدیک می‌شوند و از تکرار ۳۰ام به بعد نتایج تغییر چندانی نمی‌کنند. در این مرحله می‌توان با دقت خوبی تعلق هر درزه را به دسته درزه‌ی مربوط به آن مشخص کرد. این امر نشان‌دهنده‌ی قابلیت یادگیری شبکه و بالا رفتن دقت تخمین‌ها است. به همین دلیل می‌توان از الگوریتم پیشنهادی به‌عنوان وسیله‌یی برای مقایسه و کنترل عملکرد نرم‌افزاری و وسیله‌یی کمکی برای قضاوت مهندسی نام برد.

۵. نتیجه‌گیری

در روش سنتی یافتن مراکز دسته درزه‌ها از تراز‌بندی کردن چگالی سطحی توزیع قطب درزه‌ها در روی صفحه استریونت استفاده می‌شود. نتایج حاصل از این روش

در مواردی وابسته به دیدگاه فرد خبره است. روش‌های مختلف ترازبندی چگالی سطحی درزه‌ها می‌تواند به نتایج متفاوت منجر شود.

الگوریتم ارائه شده در این نوشتار یک روش سریع و دقیق برای محاسبه‌ی مراکز دسته درزه‌هاست. در این الگوریتم به جای نقاط دارای چگالی سطحی بیشینه‌ی مراکز وزنی هر دسته درزه با دقت خوبی محاسبه می‌شوند. این عملیات مستقل از توزیع داده‌ها بوده و جواب‌های ارائه شده برای تعداد داده‌ی کم هم مناسب‌اند؛ بنابراین نیازی به تولید داده‌ی اضافی نیست. در ضمن در انتهای الگوریتم می‌توان تعلق هر درزه را به دسته خاص مشخص کرد. استفاده از این روش می‌تواند مکمل مناسبی برای قضاوت مهندسی متخصصین باشد.

برای انجام دسته‌بندی درزه‌ها با دقت بیش‌تر می‌توان پارامترهای دیگری مثل اندازه‌ی دهانه‌ی درزه‌ها، زبری سطح درزه‌ها و غیره را علاوه بر شیب و جهت شیب وارد تحلیل‌ها کرد. یکی از امتیازات الگوریتم ارائه شده در این نوشتار، امکان انجام دسته‌بندی با پارامترهای اضافی است.

پانوشت

1. regression
2. decision analysis
3. cluster analysis

منابع

1. Priest, S. D. Discontinuity Analysis for Rock Engineering, Chapman and Hall, London (1993).
2. DIPS Software. http://www.rocscience.com.
3. Hammah, R.E. and Curran J.H. "Fuzzy cluster Algorithm for the automatic dentification of joint sets", *Int. J. Rock Mech. Min. Sci.* **35**(7), pp. 889-905 (1998).
4. Shanley, R.J. and Mahtab, M.A. "A computer program for clustering points on the sphere", United States Bureau of Mines Information Circulars, Technical Report (8624), (1974).
5. Mahtab, M.A. and Yegulalp, T.M. A Rejection Criterion for Definition of Clusters in Orientation Data, Issues in Rock Mechanics, Proceedings, 23rd. Symposium on Rock Mechanics, pp. 116-123 (1982).
6. Tarassenko, L. *A guide to Neural Computing Applications,* Arnold, London (1998).
7. Kohonen, T. Self-Organization and Associative Memory, Springer-Verlag, New York (1984).
8. Kohonen, T. Self-Organizing Maps: Optimization approaches. In T. Kohonen, K. M akisara, O. Simula, and J. Kangas, editors, "Artificial neural networks", volume II, pages 981-990, Amsterdam, Netherlands, North-Holland (1991).
9. Mahtab, M. A., Bolstad, D. D., Alldredge, J. R., and Shanley, R. J. "Analysis of fracture orientations for input to structural models of discontinuous rock", Washington DC: U.S. Dept. of Interior, Bureau of Mines. Series: Report of Investigations, United States, Bureau of Mines, 7669 (1972).
10. Baecher, G. B., and Christian J. T. Reliability and Statistics in Geotechnical Engineering, John Wiley and Sons Ltd, England (2003).
11. Mahtab, M.A. and Yegulalp, T.M. A Similarity Test for Grouping Orientation Data in Rock Mechanics, 25th. Symposium on Rock Mechanics, Northwestern University, Evanston Ill. (1984).
12. Fisher, R.A. Dispersion on a Sphere, Proc. Roy. Soc. London Ser. A., pp. 295-305 (1953).
13. Kent, J.T. "The fisher-bingham distribution on the sphere", *Journal of the Royal Statistical Society,* Series B, 44, pp. 71-80 (1982).