

مقایسه روش ماشین بردار پشتیبان با روش‌های حداکثر احتمال و شبکه عصبی برای تفکیک واحدهای سنگ‌شناسی

سعید گودرزی مهر^۱، رحیم علی‌عباسپور^۲، وحید احدنژاد^{۳*} و باهره خاکباز^۴

۱- کارشناس ارشد، دانشکده کارتوگرافی، دانشگاه تهران

۲- استادیار، گروه مهندسی نقشه‌برداری، پردیس دانشکده‌های فنی، دانشگاه تهران

۳- استادیار، گروه زمین‌شناسی، دانشگاه پیام نور، تهران

تاریخ دریافت: ۹۰/۱۰/۷

تاریخ پذیرش: ۹۱/۳/۱۷

چکیده

تهیه نقشه‌های زمین‌شناسی توسط تصاویر چندطیفی، با توجه به نزدیکی رفتار طیفی بسیاری از سنگ‌ها می‌تواند امری دشوار باشد. لذا در این پژوهش روش ماشین بردار پشتیبان (SVM)، بعنوان یکی از روش‌های طبقه‌بندی تصویر که قابلیت انعطاف مناسبی برای حالات مختلف دارد مورد استفاده قرار گرفت و کرنل‌های مختلف آن با دو روش طبقه‌بندی حداکثر احتمال (MLC)^۲ و شبکه‌های عصبی (NNC)^۳، بمنظور تولید نقشه زمین‌شناسی و با مقادیر مختلف نمونه‌های تعلیمی و با توجه به برداشت‌های زمینی و مطالعات آزمایشگاهی، مورد تحلیل و ارزیابی قرار گرفت. نتایج به دست آمده نشان داد روش SVM در هر سه کرنل خود توانسته است بیشترین دقت (۸۳/۴۲٪) را نسبت به دو روش دیگر ارائه کند. همچنین روش SVM با ۵۰٪ از داده‌های تعلیمی نیز می‌تواند به دقتی معادل استفاده از ۱۰۰٪ درصد نمونه‌های تعلیمی برسد در حالیکه دو روش دیگر چنین قابلیت را از خود نشان ندادند. از طرفی ارزیابی نتایج حاصل از شاخص تفکیک‌پذیری جفریس-ماتوسیتا^۴ با نتایج دقت طبقه‌بندی به روش SVM، گویای این حقیقت است که این روش در داده‌های با تفکیک‌پذیری پایین‌تر بسیار کارآمدتر از دو روش دیگر مورد بحث بوده و بنابراین به نظر می‌رسد این روش برای تهیه نقشه زمین‌شناسی مناسب‌تر از دو روش فوق خواهد بود.

واژه‌های کلیدی: سنجش از دور، TMS، حداکثر احتمال، شبکه عصبی، طبقه‌بندی SVM.

مقدمه

تامین کننده داده‌های کارآمدی است که برای استخراج اطلاعات مورد نظر از آنها نیاز به پردازش‌هایی بر روی تصویر است. طبقه‌بندی تصویر، یکی از مولفه‌های اصلی فرآیند استخراج اطلاعات موضوعی است که از طریق بررسی رابطه بین اثر طیفی و کلاس‌ها یا طبقات مختلف حاصل می‌شود (Oommen, 2008).

داده‌های حاصل از سنجش از دور با توجه به فراهم کردن پوشش وسیع از منطقه و ارائه پارامترهای کمی، می‌توانند منبعی مناسب برای به‌روز کردن نقشه‌های سنگ‌شناسی باشند (Rajen-dran et al., 2007). تصاویر حاصل از فناوری سنجش از دور

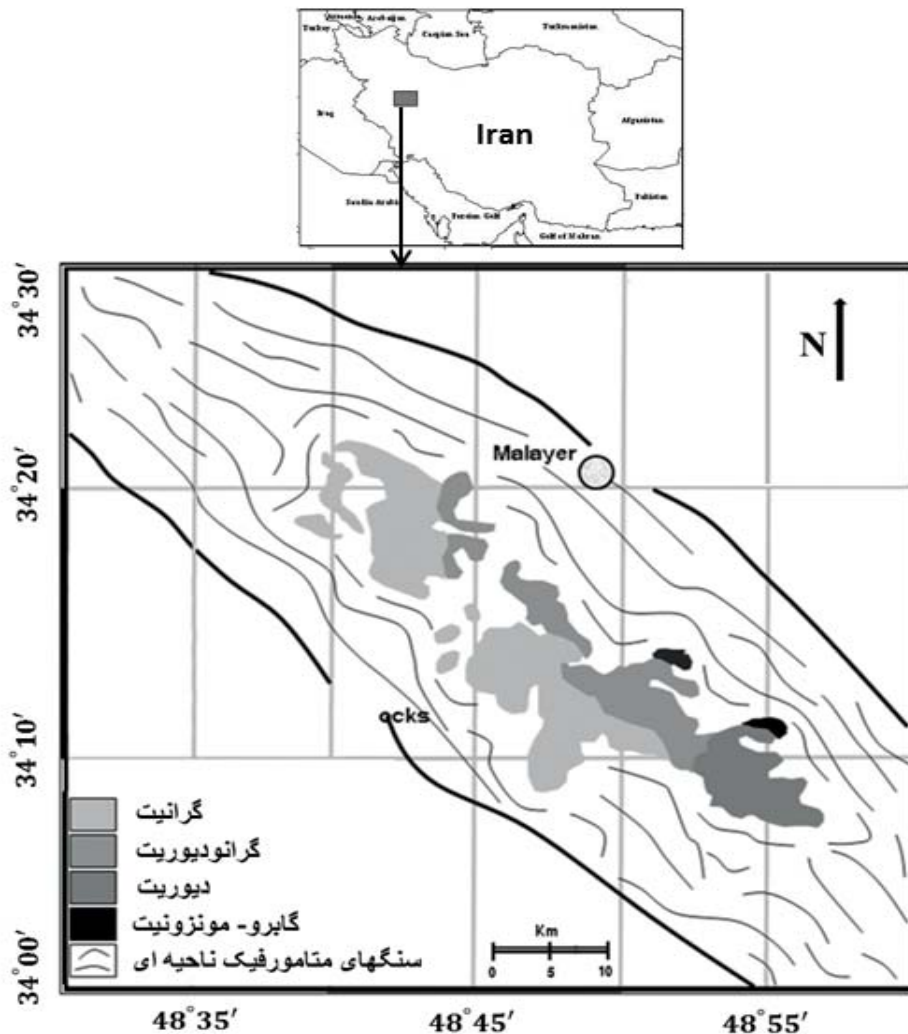
* نویسنده مرتبط v.ahadnejad@pnu.ac.ir

1- Support Vector Machine
2- Maximum Likelihood Classification
3- Neural Network Classification
4- Jefferis-Matusita

بطور اتوماتیک بسیار دشوار می‌گردد (Hord, 1982). برای غلبه بر این مشکل، روش‌های طبقه‌بندی نظارت شده ارائه گردیدند که در آن‌ها از نمونه‌های تعلیمی به‌عنوان کلیدی که اثر طیفی مربوط به یک عارضه خاص و مورد نظر کاربر را نشان می‌دهد، برای طبقه‌بندی استفاده می‌شود (Lillesand et al., 2004). اما به هر حال خطاهایی در طبقه‌بندی وجود دارند که می‌تواند به علت ضعف تجربه و دانش کاربر باشد.

از طرفی به علت تأثیرات متفاوت حاصل از ویژگی‌های عوارض سطحی بر پاسخ طیفی رسیده به سنجنده، انتخاب مکان مناسب برای بررسی‌های زمین‌شناسی از طریق در نظر گرفتن برخی عوامل نظیر شرایط جوی، پوشش گیاهی، توپوگرافی و لیتولوژی سنگ بستر، میزان تمرکز کانی‌ها نسبت به اطراف و نهایتاً ویژگی‌های کانی‌های اجتماع یافته در محل می‌تواند در بسیاری از الگوریتم‌های کامپیوتری موثر باشد (Frei and Jutz, 1989; Blodget et al., 1978). از این‌رو، بخشی از شهرستان ملایر که به لحاظ توپوگرافی و شرایط جوی در زمان عکس‌برداری و پوشش گیاهی مناسب‌تر بود، برای این مطالعه انتخاب گردید (شکل ۱).

در حقیقت فرآیند طبقه‌بندی تصویر، تبدیل داده‌ها به اطلاعات قابل درک است (Mountrakis et al., 2011). در گذشته، تکنیک‌های طبقه‌بندی تصاویر بر مبنای تفسیر بصری کاربر بود که اغلب باعث به وجود آمدن خطاهای سیستماتیک می‌گردید که این امر ناشی از تجربه و توانایی مفسر در تفسیر تصاویر بود (Lillesand et al., 2004). طبقه‌بندی رقومی تصاویر کمک می‌کند تا فرآیند طبقه‌بندی تصویر به واقعیت نزدیک‌تر باشد (Oommen, 2008). طبقه‌بندی رقومی تصاویر با استفاده از هر دو روش طبقه‌بندی نظارت شده و نظارت نشده صورت می‌گیرد که هر دو روش از مکانیسم تصمیم‌گیری کمی و اتوماتیک بهره می‌گیرند. اساس طبقه‌بندی رقومی تصاویر سنجنش از دور بر این مبنا است که اثر طیفی مربوط به هر عارضه پوشش دهنده تصویر، منحصر به فرد است (Oommen, 2008). در طبقه‌بندی نظارت نشده، بطور اتوماتیک و بر اساس اختلاف اثر طیفی و محاسبات آماری، هر پیکسل به کلاس خاصی تعلق می‌گیرد. ضعف این روش در این است که در صورتی که عارضه مورد نظر دارای اختلاف اثر طیفی کمی نسبت به سایر عوارض باشد، تفکیک آن با این روش و



شکل ۱. نقشه موقعیت منطقه مورد مطالعه و طبقه‌بندی کلی سنگ‌شناسی.

Camps-Valls et al. (2010) روشی را برای بهبود تشخیص کرنل مستقل در SVM برای انواع تصاویر، بر اساس معیار استقلال هیلبرت-اشمیت^۲ پیشنهاد کردند. (Knudby et al. (2010) در پژوهشی پیرامون تنوع و بیوماس، از تصاویر آیکنوس برای مدل‌سازی و پیش‌بینی این پدیده استفاده کردند آن‌ها برای این کار روش SVM را با ۵ روش دیگر مقایسه کردند و به این نتیجه رسیدند که این روش بالاترین رتبه را میان سایر الگوریتم‌های به کار رفته دارا است. (Huang et al. (2002) دقت حاصل از بکارگیری روش SVM همراه با کرنل‌های مختلف آن را با سه روش طبقه‌بندی MLC، NNC و روش طبقه‌بندی ساختار درختی (DTC)^۳ مورد مقایسه قرار دادند. نتایج تحقیقات آنها نشان داد که روش SVM دقت بالاتری نسبت به روش‌های MLC و NNC داراست. آنها علت دقت بالای این روش را قابلیت بهینه‌سازی تفکیک‌پذیری کلاس‌ها توسط ابرصفحه جداکننده عنوان کردند. (Oommen et al. (2008) از روش SVM برای طبقه‌بندی واحدهای لیتولوژیک استفاده کردند و نتایج آن را با روش MLC مورد مقایسه قرار دادند که حاکی از بالاتر بودن دقت آن نسبت به روش MLC بود. (Wang et al. (2011) برای تهیه نقشه واحدهای لیتولوژیک و کاهش مشکل حضور پوشش گیاهی در تصویر، از ترکیب روش SVM با ACA^۴ بر روی تصاویر سنجنده‌های TM و ETM+ استفاده کردند و روش SVM-ACA را به عنوان روشی کارآمد در نواحی دارای پوشش گیاهی معرفی نمودند. (An-nan and Lu (2009) از ترکیب روش SVM و DE برای تهیه نقشه واحدهای لیتولوژیک بهره گرفتند و روش DE-SVM را به عنوان روشی مناسب برای تفکیک این واحدها ارائه کردند. (Al-Anazi و Gates (2010) به منظور مدل‌سازی فاصله نقاط مناسب، برای طبقه‌بندی واحدهای لیتولوژیک، از مدلی جدید بر مبنای روش SVM بهره گرفتند و نتایج آن را با روش شبکه عصبی مقایسه نمودند که در این تحقیق نیز روش SVM دقت بالاتری را ارائه نمود.

(Demira and Erturk (2009) پیشنهاد کردند که برای بهبود دقت طبقه‌بندی به روش SVM در تصاویر ابر طیفی، نمونه‌های تعلیمی قرار گرفته در مرز، در طی دو مرحله طبقه‌بندی، یکپارچه شوند. (Su et al. (2009) در مطالعه‌ای با استفاده از داده‌های ماهواره‌ای MISR نشان دادند که با استفاده از روش‌های SVM و MLC می‌توان حتی با داشتن ۲/۳ مجموعه داده‌ها به دقتی رسید که با کل داده‌ها قابل دستیابی است. (Knorn et al. (2009) برای طبقه‌بندی جنگل از روش SVM استفاده کردند. هدف آن‌ها از این تحقیق، ارزیابی دقت طبقه‌بندی در مجموعه‌ای از تصاویر متوالی (به عنوان مثال شکل ۶) بود. این تحقیق نشان داد که این روش زمانی که سطح زمین از چندین عارضه پوشیده شده باشد، نیز کارآمد خواهد بود.

منطقه مورد مطالعه در این پژوهش در استان همدان و در بخش شمالی زون سندج - سیرجان قرار داشته و بین طول جغرافیایی E ۳۷' ۱۵" تا E ۴۸' ۴۲" ۰۲' ۴۹" و عرض جغرافیایی N ۳۳' ۵۵" ۳۲" تا N ۳۴' ۲۱" ۳۹" واقع شده و مساحتی در حدود ۱۵۹۷/۳ کیلومترمربع را در بر گرفته است (شکل ۱). این ناحیه یکی از مهمترین زون‌های تکتونیکی محلی ایران است که در طی رورانش نئوتیس و متعاقب آن، برخورد پوسته عربی با پوسته ایران در اواخر دوره کرتاسه تکامل یافته است (Ahadne- jad et al., 2011). سنگ‌های این ناحیه بیشترین تغییر شکل را در کوهزایی زاگرس داشته‌اند و در امتداد شمال غربی جنوب شرقی گسترده شده‌اند. واحدهای سنگ‌شناختی ملایر عبارتند از: مقادیر زیادی از سنگ‌های گرانودیوریت، مقادیر کمتری از دایک‌های فلسیک و بازیک و همچنین سنگ‌های دگرگونی و پگماتیت. گرانودیوریت‌های ملایر به وسیله کمر بند گسل شمال غربی - جنوب شرقی زاگرس و شمال غربی - جنوب شرقی ارومیه - دختر احاطه شده است (شکل ۱).

روش‌های متعددی برای طبقه‌بندی نظارت شده وجود دارد (Murai, 1996) که مقبول‌ترین آن‌ها، روش طبقه‌بندی حداکثر احتمال (MLC) است. برخلاف این محبوبیت، این روش دارای محدودیت‌هایی نیز هست (Murai, 1996). یکی از جدیدترین روش‌های ارائه شده برای طبقه‌بندی، استفاده از روش SVM، به عنوان روشی نظارت شده می‌باشد (Huang et al., 2002). این روش به علت توانایی در بکارگیری بهینه از داده‌های تعلیمی، در اغلب موارد توانسته است طبقه‌بندی را از بسیاری از روش‌های رایج با دقت مطلوب‌تری انجام دهد (Mountrakis et al., 2011). در این مقاله با استفاده از مطالعات میدانی و آنالیزهای آزمایشگاهی بر روی نمونه‌های تعلیمی، قابلیت روش SVM و انواع حالات آن با سایر روش‌های طبقه‌بندی نظارت شده از قبیل طبقه‌بندی به روش حداکثر احتمال (MLC) و شبکه‌های عصبی (NNC) برای تفکیک واحدهای سنگ‌شناسی مورد ارزیابی قرار گرفته است.

پیشینه تحقیق

تاکنون روش‌های طبقه‌بندی زیادی، اعم از روش‌های پارامتریک و غیرپارامتریک، در مطالعات سنجش از دور به کار گرفته شده‌اند (Mountrakis et al., 2011). در این میان، روش SVM به عنوان یک الگوریتم طبقه‌بندی چندمتغیره قدرتمند، به طور گسترده‌ای در پژوهش‌ها و مطالعات سنجش از دور مورد استفاده قرار گرفته است (Melgani and Bruzzone, 2004; Huang et al., 2002). اما این روش هنوز مانند سایر روش‌های طبقه‌بندی (نظیر شبکه‌های عصبی) شناخته شده نیست (Mountrakis et al., 2011). با این وجود، استفاده از آن در سال‌های اخیر به شدت در حال افزایش است که در ادامه این بخش به برخی از این موارد اشاره می‌شود.

- 1- Training data
- 2- Hilbert-Shmidt
- 3- Decision Tree Classification
- 4- Adaptive Cellular Automata

می‌کند که با داشتن داده‌های تعلیمی کمتر نیز می‌توان به حداکثر دقت ممکن رسید.


Mountrakis et al. (2011) در پژوهشی به بررسی روش SVM پرداختند و تحقیقات انجام گرفته در این حوزه را در قالب هدف استفاده، آشکارسازی اهداف ایستا و پویا، قدرت تفکیک مکانی و طیفی تصاویر، نوع تصاویر و حیطه‌های کاربرد این روش، طبقه‌بندی کردند (شکل ۲).

روش تحقیق

در این پژوهش، کارایی روش SVM برای تولید نقشه سنگ‌شناسی با روش‌های NNC و MLC مورد مقایسه قرار گرفت. برای بررسی دقیق‌تر این روش، از مقادیر مختلفی از نمونه‌های تعلیمی استفاده گردیده و سه تابع مورد استفاده در این روش، یعنی RBF^۱، چندجمله‌ای^۲ و خطی^۳ به لحاظ قدرت طبقه‌بندی مورد ارزیابی قرار گرفتند. هدف این مقاله بررسی کارایی روش SVM در طبقه‌بندی ۶ واحد سنگ‌شناسی موجود (جدول ۱) در منطقه می‌باشد.

روند کلی مراحل انجام شده در این پژوهش در قالب شکل ۳ نشان داده شده است.

(Huang et al. 2008) از روش SVM برای طبقه‌بندی جنگل استفاده کردند و دقت این طبقه‌بندی را بر اساس تاثیر دادن شیب و جهت زمین، ارتفاع و آزمون خورشید و موقعیت نسبی درختان در طبقه‌بندی، بررسی کردند. آن‌ها متوجه شدند که بعد از تصحیحات توپوگرافیک، در همه طبقات دقت طبقه‌بندی به میزان ۳/۶ درصد بهبود یافته است. (Lardeux et al. 2009) برای طبقه‌بندی تراکم پوشش گیاهان گرمسیری، از روش SVM بهره گرفتند. نتایج این تحقیق نشان داد که طبقه‌بندی به روش SVM به میزان ۲۰ درصد باعث افزایش دقت نسبت به روش طبقه‌بندی ویشارت^۱ گشته است. آن‌ها خاطر نشان کردند زمانی که داده‌های رادار از توزیع ویشارت پیروی نمی‌کنند، روش SVM می‌تواند بسیار مناسب‌تر باشد. (Mathur and Foody 2008) روشی را برای کاهش داده‌های زمینی پیشنهاد کردند و به این نتیجه رسیدند که با استفاده از روش SVM تنها با داشتن ۱۳ داده‌های تعلیمی نیز می‌توان طبقه‌بندی را به نحو مطلوب انجام داد. (Song et al. 2005) از روش SVM و تصاویر لندست برای پایش جنگل بهره گرفتند و این روش را برای این نوع تصویر کالیبره کردند. در حقیقت این روش به علت داشتن انعطاف‌پذیری بیشتر نسبت به سایر روش‌ها، و ارائه سه کرنل مختلف، این امکان را فراهم

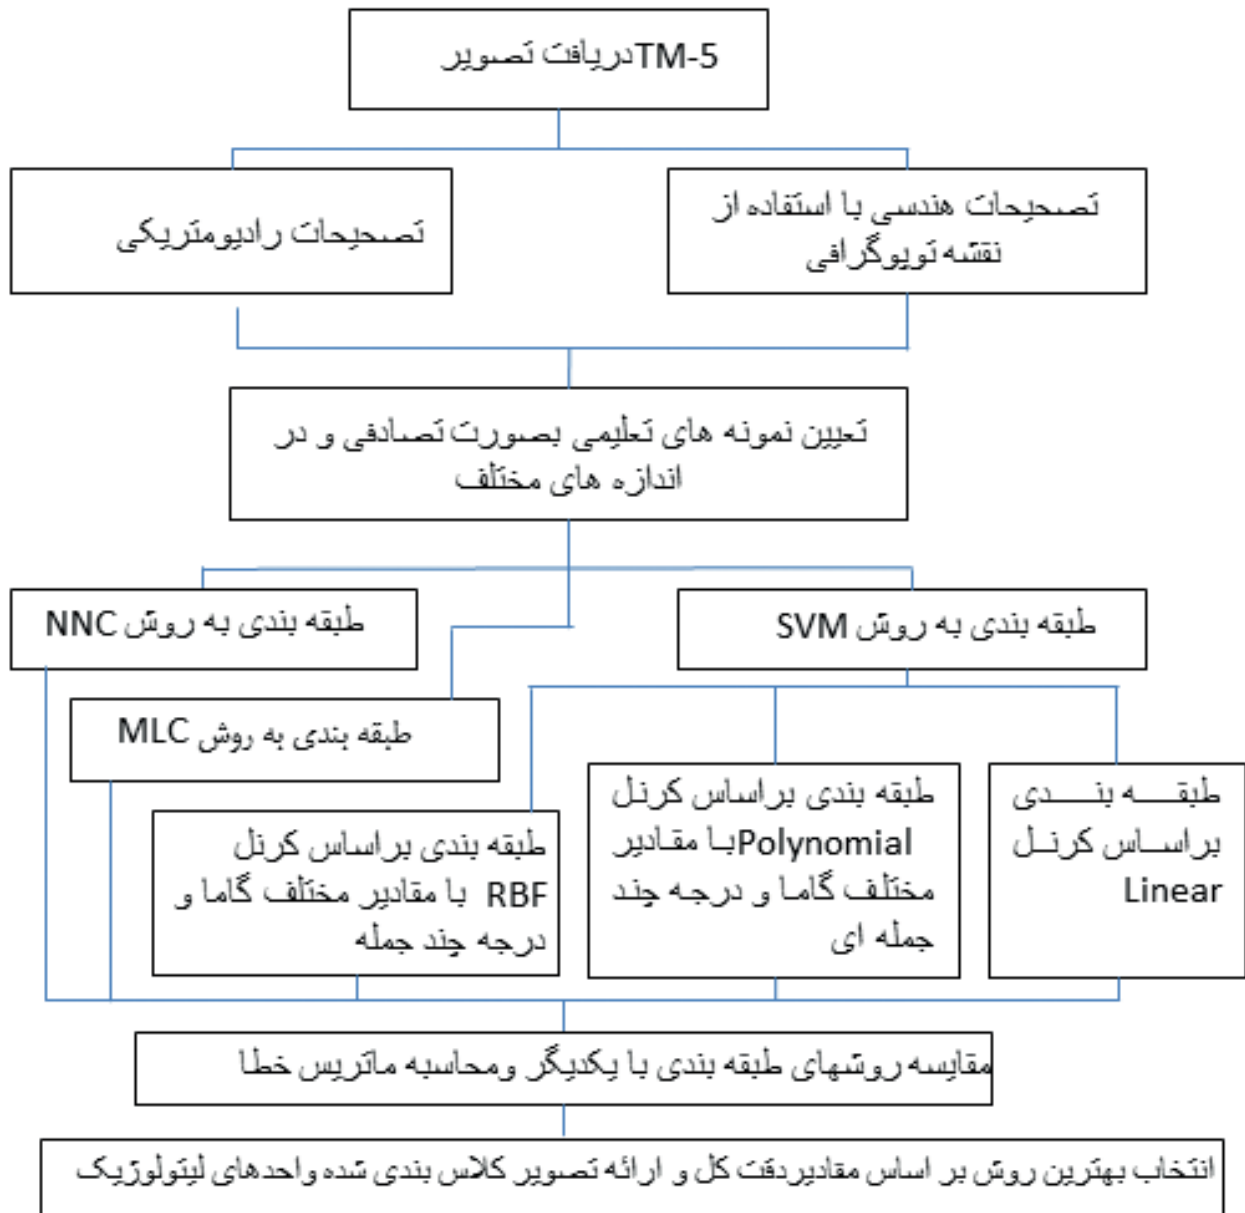


شکل ۲. خلاصه‌ای از مطالعات انجام گرفته با استفاده از روش SVM در فاصله زمانی سال‌های ۲۰۰۹-۲۰۱۱ (Mountrakis et al., 2011).

- 1- Wishart
- 2- Radial Basis Function
- 3- Polynomial
- 4- Linear

جدول ۱. واحدهای مورد بررسی

ردیف	واحدهای لیتولوژیکی
۱	رسوبات آبرفتی پست
۲	نهبته‌های کوهپایه‌ای سطح بلند و بادبزنهاى آبرفتی
۳	فیلیت، اسلیت و شیست خاکستری تیره و ماسه‌سنگ دگرگونه
۴	گرانیت، گرانودیوریت و دیوریت
۵	گابرو
۶	هورن فلس فلدسپات و میکادار
۷	پوشش گیاهی و مناطق شهری



شکل ۳. روند کلی مراحل تولید تصویر طبقه بندی شده واحدهای سنگ شناسی.

پیش پردازش تصاویر ماهواره‌ای

مرحله پیش پردازش داده‌ها یکی از مهم‌ترین مراحل در پردازش تصاویر است؛ چرا که تمامی محاسبات بعدی بر اساس تصویر تولیدی در این مرحله انجام می‌گیرد. نوع و نحوه انجام این عملیات بسته به عوامل مختلفی چون نوع داده‌های مورد استفاده و هدف تحقیق، متغیر خواهد بود. به طور کلی پیش پردازش داده‌ها شامل دو مرحله کلی تصحیحات رادیومتریکی و تصحیحات هندسی است. برای تصحیحات هندسی، بر اساس نقشه توپوگرافی موجود، از تعدادی نقطه با پراکندگی مناسب در سطح تصویر و نقشه مختصات دار استفاده گردید. در ادامه، تصحیحات رادیومتریکی نیز تا مرحله تبدیل DN¹ به رادیانس، بر روی تصویر پیاده‌سازی شد (Markham and Helder, 2009).

تهیه نمونه‌های تعلیمی

اساساً طبقه‌بندی تصاویر سنجش از دور فرآیند مشکلی است، چرا که بیشتر روش‌های طبقه‌بندی نظارت شده نیازمند داده‌های تعلیمی به اندازه کافی بزرگ هستند (Chi et al., 2008). از طرف دیگر، نحوه انتخاب نمونه‌های تعلیمی نیز یکی از مهمترین عوامل در طبقه‌بندی پیکسل‌ها است (Paola and Schoweng-erd, 1995). برای رسیدن به دقت بهتر، این عامل می‌تواند حتی از انتخاب الگوریتم طبقه‌بندی نیز مهم‌تر باشد (Hixon et al., 1980). در حقیقت پارامترهای زیادی بر نحوه کلاس‌بندی تصویر تاثیر می‌گذارند که از آن جمله، داده‌های ورودی و ارائه پیکسل‌هایی به عنوان نمونه تعلیمی را می‌توان برشمرد (Gong and Howarth, 1990; Foody et al., 1995). تاثیر داده‌های ورودی به عنوان نمونه‌های تعلیمی برای طبقه‌بندی در مطالعات زیادی مورد ارزیابی قرار گرفته است (Genderen and Lock, 1978).

یک روش رایج این است که مجموعه‌های کوچکی از پیکسل‌های هموزن در تصویر بعنوان نمونه‌های تعلیمی انتخاب شود (Campbell, 1996)، اما انتخاب داده‌های تعلیمی با این روش می‌تواند به علت زیر حد قابل قبول بودن تنوع طیفی هر کلاس منجر به تضعیف دقت طبقه‌بندی گردد (Gong and Howarth, 1990). از این رو برای کاهش این مشکل و حداقل کردن اثر همبستگی مکانی، می‌توان از نمونه‌گیری تصادفی استفاده کرد (Campbell, 1996). لذا در این تحقیق نیز برای اینکه تمامی مشکلات مذکور به حداقل برسند، ابتدا بر اساس نقشه زمین‌شناسی در مقیاس ۱:۱۰۰۰۰۰ مناطق از تصویر که شرایط همگن بودن پیکسل‌ها در آن لحاظ شده بود، انتخاب گردید. با توجه به اینکه نمونه‌های تعلیمی ورودی می‌بایست تا حد زیادی به واقعیت رفتار طیفی کلاس مورد نظر نزدیک باشند تا الگوریتم طبقه‌بندی کننده از نمونه‌های مناسب برای انجام فرآیند طبقه‌بندی استفاده کند؛ لذا

باید تا حد ممکن از نمونه‌های مطمئن‌تر استفاده شود. از طرفی نقشه‌های زمین‌شناسی به روز نیستند و بسیاری از نواحی می‌تواند توسط پوشش گیاهی و سایر پدیده‌ها تحت تاثیر قرار گرفته باشد و در واقع پیکسل مخلوط ایجاد کرده باشد که برای حل آن از تصاویر 421FCC²، 431FCC³، مطالعه نمودار طیفی پیکسل‌های هر کلاس و نمایش پیکسل‌ها در فضای چندبعدی استفاده شد تا پیکسل‌های مشکوکی که در ابر داده‌های کلاس مورد نظر با دیگر کلاس‌ها تداخل داشتند، از نمونه‌های تعلیمی کلاس مورد نظر حذف گردد و پیکسل‌هایی همگن‌تر انتخاب شوند. در ادامه، برای کاهش همبستگی مکانی، قابلیت اعتماد بیشتر به خروجی طبقه‌بندی‌ها و بررسی و کنترل بهتر تاثیر اندازه داده‌های تعلیمی بر نتایج طبقه‌بندی، از روش ESR (Paola and Schowengerdt, 1995) که در آن از درصد ثابتی از پیکسل‌ها در اندازه‌های ۱۰٪، ۲۰٪، ...، ۱۰۰٪ از کل پیکسل‌های هر کلاس، به صورت تصادفی انتخاب می‌شود، استفاده گردید (جدول ۱).

پس از بررسی نمودار طیفی کلاسها بر روی هر یک از باندهای TM5، مشخص گردید که نمودار طیفی واحدهای مورد نظر در سه باند ۳، ۴ و ۵ بیشترین اختلاف طیفی را نسبت به هم دارند. لذا برای بررسی و نمایش چگونگی همپوشانی طیفی ابر داده‌ها در بهترین حالت تفکیک‌پذیری از این باندها استفاده گردید. مطابق با آنچه که در شکل ۴ دیده می‌شود، واحد لیتولوژیک شماره ۳ و ۶ بیشترین شباهت را به منحنی گوسی توزیع نرمال دارند و واحدهای ۲ و ۵ کمترین نزدیکی را دارند.


طبقه‌بندی به روش حداکثر احتمال (MLC)

روش طبقه‌بندی حداکثر احتمال هنوز هم یکی از رایج‌ترین روش‌های طبقه‌بندی تصویر است. در این روش، احتمال اینکه یک پیکسل بتواند به هر یک از m کلاس موجود تعلق یابد بررسی می‌شود و سپس پیکسل به کلاسی که بیشترین احتمال را دارد اختصاص می‌یابد (Jensen, 2005). در این روش از قاعده تصمیم بیز (BDR)⁴ برای محاسبه احتمال استفاده می‌شود (Oommen, 2008):

$$D = \text{Ln}(ac) - [0.5 \text{Ln}(\text{Covc})] - [0.5(X - Mt)^T (\text{Covc}^{-1})(X - Mt)] \quad (1)$$

که در رابطه فوق، D معرف فاصله وزنی (احتمال)، C نشان دهنده کلاس مورد نظر، X معرف بردار اثر طیفی برای پیکسل تحت بررسی، Mt بردار میانگین برای داده‌های تعلیمی در کلاس ac، c بیانگر درصد احتمال اینکه پیکسل مورد نظر عضو C باشد (فرض بر این است که در اینجا تمامی احتمالات اولیه کلاس‌ها یکسان باشد) و Covc نشان دهنده ماتریس کوواریانس

1- Digital Number
2- False Color Composite
1- Equal Sample Rate
2- Bayesian Decision Rule



شکل ۴. نمودار فراوانی ارزش پیکسل‌ها در باند ۳، برای شش واحد لیتولوژیک با استفاده از ۵۰ درصد از نمونه‌های تعلیمی (شماره هر نمودار مطابق با شماره ردیف نمونه تعلیمی در جدول ۱ می باشد)

می‌گردد (Richards, 1999). در حقیقت، این روش‌ها دارای ماهیت طبقه‌بندی لایه‌ای هستند که هر لایه از تعدادی گره (نرون) تشکیل شده و به وسیله چند ورودی، فرآیند آغاز شده و به یک خروجی منتهی می‌شود (Richards, 1999). به طور کلی عملکرد این روش بر اساس رابطه زیر است (شکل ۵):

$$O = f(W'x + \theta) \quad (2)$$

در رابطه فوق θ معرف حد آستانه، W' بردار وزنی ضرایب و x بردار ورودی است. تعداد نرون‌ها نیز به وسیله توپولوژی شبکه و ابعاد داده مشخص می‌گردد (Richards, 1999) که در اینجا تعداد نرون‌های ورودی معادل شش باند غیرحرارتی سنجنده TM-5 در نظر گرفته شد و طبقه‌بندی بر اساس آن انجام گرفت. فرآیند طبقه‌بندی به روش شبکه عصبی در سه مرحله به شرح زیر انجام شد:

- ۱- انجام فرآیند آموزشی با استفاده از داده‌های ورودی
- ۲- مرحله اعتبارسنجی که در آن چگونگی موفقیت مرحله اول و صحت شبکه بررسی می‌شود (تولید نمودار RMS^۱ برای مقادیر W به دست آمده در n تکرار، شکل ۶). در این مرحله با ۱۰ درصد داده‌های تعلیمی و با ۳۵۰ تکرار RMS کمتر از ۰/۵ حاصل گردید، ولی با ۵۰ و ۱۰۰ درصد داده‌های تعلیمی به ترتیب با ۱۰۰ و ۵۰ بار تکرار و خیلی سریع‌تر، مقادیر RMS به حداقل خود نزدیک گردید.

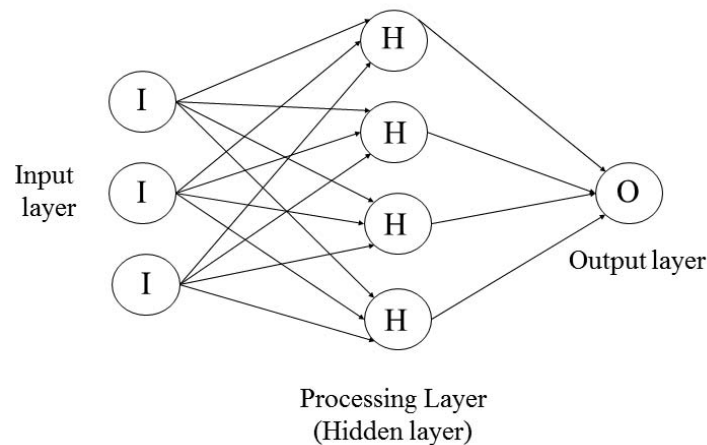
پیکسل‌های تعلیمی در کلاس c است (Schrader and Pouncey, 1997).

مزیت اصلی این روش این است که تغییرات موجود در هر کلاس را با استفاده از ماتریس کوواریانس برای کلاس‌بندی پیکسل مورد نظر، لحاظ می‌کند، گرچه این روش چندین عیب نیز دارد (Murai, 1996). این روش بر این فرض تکیه دارد که داده‌های هر باند مورد استفاده به عنوان ورودی الگوریتم، دارای توزیع نرمال بوده و همچنین کافی است تعدادی از پیکسل‌ها انتخاب شوند تا بتوانند تخمین درست از بردار میانگین و ماتریس واریانس-کوواریانس ارائه کنند (Oommen, 2008). بنابراین، براساس مقادیر مختلف نمونه‌های تعلیمی، این روش در منطقه مورد استفاده قرار گرفت و تصویر طبقه‌بندی شده‌ای از واحدهای سنگ‌شناسی تهیه شد.

طبقه‌بندی به روش شبکه عصبی (NNC)

تاکنون انواع روش‌های طبقه‌بندی برای شبکه عصبی مصنوعی ارائه شده است که یکی از متداول‌ترین آن‌ها روش شبکه عصبی پرسپترون چند لایه‌ای است (احمدی ندوشن و همکاران، ۱۳۸۸). اساس کارایی روش‌های طبقه‌بندی شبکه‌ای زمانی مشخص می‌گردد که با مجموعه داده‌هایی روبرو باشیم که به وسیله یک سطح تصمیم خطی ساده از هم تفکیک نشوند که در این صورت و به وسیله چنین روش‌هایی، در طی یک فرآیند لایه‌ای و با استفاده از سطوح غیرخطی، این تفکیک امکان‌پذیر

1- Root Mean Square Error




شکل ۵. فرم کلی شبکه عصبی با لایه میانی.

ماشین بردار پشتیبان در واقع یک طبقه بندی کننده دودویی است که دو کلاس را با استفاده از یک مرز خطی از هم جدا می کند و وابسته به خانواده طبقه بندی های خطی تعمیم یافته است (Srivastava and Bhambhu, 2009). ماشین بردار پشتیبان، داده ها را با عبور یک صفحه (مرز خطی) و با استفاده از تمامی باندها و به کارگیری یک الگوریتم بهینه سازی طبقه بندی می کند. بدینگونه که ابتدا نمونه هایی که مرز کلاس ها را تشکیل می دهند به دست می آیند. به عبارت دیگر تعدادی از نقاط آموزشی که کمترین فاصله تا مرز تصمیم گیری را دارند می توانند به عنوان بردار پشتیبان در نظر گرفته شوند. در این روش با افزایش بعد

۳- طبقه بندی عارضه های مورد نظر که در مرحله آموزشی ارائه شده بودند (Wijaya, 2005).

طبقه بندی به روش SVM

روش SVM، یک روش آماری غیرپارامتریک نظارت شده است و بر اساس این فرض عمل می کند که هیچ گونه اطلاعی از چگونگی توزیع مجموعه داده ها وجود نداشته باشد. ویژگی اصلی این روش توانایی بالا در استفاده از نمونه های تعلیمی کمتر و رسیدن به دقت بالاتر در مقایسه با سایر روش های طبقه بندی پیشین است (Mantero et al., 2005; Mountrakis et al., 2011).



شکل ۶. نمودار RMS به دست آمده برای صحت شبکه در ۱۰۰۰ بار تکرار برای مقادیر ۱۰% (نمودار قرمز)، ۵۰% (نمودار آبی) و ۱۰۰% (نمودار سبز) نمونه های تعلیمی.

دو طرف مرز تصمیم‌گیری تعریف می‌شوند، به گونه‌ای که صفحه مرز بیشترین فاصله مساوی بین دو صفحه موازی را ایجاد کند. هرچه فاصله بین دو صفحه موازی بیشتر باشد دقت کلاس‌بندی بیشتر خواهد شد (Srivastava and Bhambhu, 2009). در حقیقت این الگوریتم در پی یافتن یک ابرصفحه است که بتواند به نحوی عمل کند تا ضمن سازگاری با داده‌های تعلیمی، توانایی تفکیک و جداسازی مجموعه داده از یکدیگر را نیز داشته باشد (Mountrakis et al., 2011).

یک ابرصفحه مناسب، صفحه یا جداکننده‌ای است که بتوان با آن یک همسایگی در اطراف آن ایجاد کرد که علیرغم بیشینه بودن پهنا، پیکسلی داخل آن قرار نگیرد (کشاورز و قاسمیان‌یزدی، ۱۳۸۴). منظور از اصطلاح ابرصفحه جداکننده بهینه، محدوده‌ای است که بتواند با استفاده از داده‌های تعلیمی، پیکسل‌هایی که به نادرستی طبقه‌بندی می‌شوند را به حداقل برساند (Mountrakis et al., 2011). برای تعریف این سطح جدا کننده چندین کرنل وجود دارد (شکل ۷).

در صورتی که ابر داده‌ها دارای تداخل زیادی باشند، می‌توان از کرنل‌های چندجمله‌ای با درجات چندجمله‌ای و گامای متفاوت و یا از کرنل RBF استفاده کرد. روابط مورد استفاده برای این سه کرنل به شرح زیر است:

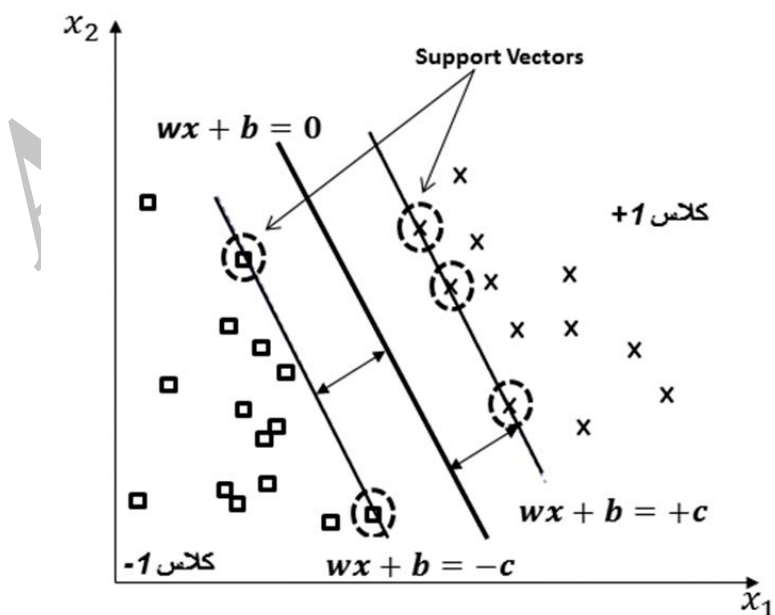
خطی	$K(x_i, x_j) = x_i^T x_j$
چندجمله‌ای	$K(x_i, x_j) = (g x_i^T x_j + r)^d, g > 0$
RBF	$K(x_i, x_j) = \exp(-g \ x_i - x_j\ ^2), g > 0$

داده‌ها نتیجه مطلوب‌تری حاصل می‌گردد. در واقع در صورتی که در فضای طیفی، کلاس‌ها تداخل داشته باشند، داده‌ها به فضایی با ابعاد بیشتر برده می‌شوند، به گونه‌ای که تمایز آن‌ها میسر گردد. هدف اصلی این الگوریتم یافتن بیشترین فاصله بین دو کلاس و در نتیجه افزایش دقت طبقه‌بندی است در حالی که خطای تعمیم نیز تا حد امکان کاهش یابد (Zhang et al., 2008).

مولفه اساسی که SVM را متمایز می‌کند، پیروی روند پردازش این الگوریتم از قاعده‌ای است که به عنوان کاهش ریسک ساختاری (SRM) شناخته می‌شود. در واقع SVM خطاهای کلاس‌بندی را در داده‌های مشاهده نشده بدون فرضیه قبلی از احتمال تخریب داده به حداقل می‌رساند، در حالی که تکنیک‌های آماری مانند MLC تخریب داده‌ها را شناخته شده در نظر می‌گیرند (Mount-rakis, et al. 2011).

برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم، از روش حاشیه بهینه استفاده می‌شود (Vapnik and Chervonenkis, 1991). مرز خطی بین دو کلاس به گونه‌ای محاسبه می‌شود که: الف) تمام نمونه‌های کلاس +1 در یک طرف مرز و تمام نمونه‌های کلاس -1 در طرف دیگر مرز واقع شوند (شکل ۷). ب) مرز تصمیم‌گیری به گونه‌ای باشد که فاصله نزدیک‌ترین نمونه‌های آموزشی هر دو کلاس از یکدیگر، در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است حداکثر شود (کشاورز و قاسمیان‌یزدی، ۱۳۸۴).

به عبارت دیگر، در این روش ابتدا فاصله نزدیک‌ترین نمونه‌های تعلیمی دو کلاس در راستای عمود بر مرزها محاسبه شده و با حل مساله بهینه‌سازی، مرز بهینه مشخص می‌شود. مرز بهینه مرزی است که بیشترین حاشیه را دارا باشد. دو صفحه موازی در



شکل ۷. طبقه‌بندی به روش SVM در دو کلاس و با استفاده از کرنل خطی در دو بعد.

گردید این نقشه حاصل برداشت‌های زمینی و آنالیزهای XRF¹ و XRD² برای واحدهای مختلف سنگ‌شناسی بوده است و برای هر عارضه به صورت تصادفی تعداد ۳۰ پیکسل، به عنوان واقعیت زمینی انتخاب شد و بر اساس آن ماتریس خطا برای هر روش محاسبه گردید که در ادامه نتایج هر الگوریتم به صورت جداگانه نمایش داده می‌شود.

نتایج حاصل از طبقه‌بندی به روش SVM برای سه کرنل چندجمله‌ای، RBF و خطی

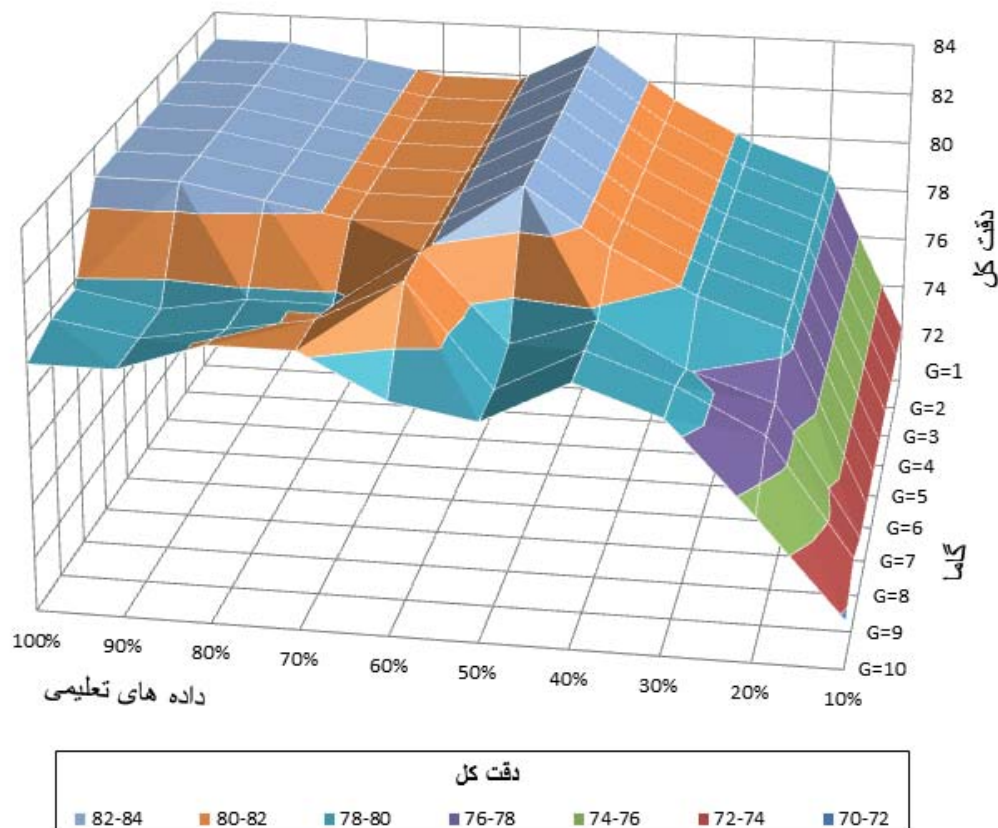
از آنجا که درجه کرنل چندجمله‌ای و مقدار گاما می‌تواند بر نتایج تاثیرگذار باشد لذا تاثیر هر کدام از این پارامترها بر دقت طبقه‌بندی جداگانه بررسی گردید.

به منظور بررسی تاثیر همزمان سه پارامتر اندازه داده‌های تعلیمی، تغییرات گاما از صفر تا ۱۰ و دقت طبقه‌بندی، از نمودار سه بعدی برای نمایش نتایج استفاده شد. همانطور که شکل ۸ نشان می‌دهد با افزایش تعداد داده‌های تعلیمی به تدریج دقت طبقه‌بندی نیز افزایش می‌یابد اما در این میان تغییرات گاما نیز تقریباً تا $G=7$ ثابت است و از آن به بعد روندی کاهشی دارد. نکته

در روابط فوق T ماتریس ترانهاده، g بیانگر گاما، d درجه چندجمله‌ای و X_i و X_j نشان‌دهنده بردار مولفه λ_m و λ_n است. در این تحقیق با سه کرنل فوق و با درجات مختلف چندجمله‌ای و مقادیر گامای متفاوت، طبقه‌بندی واحدهای سنگ‌شناسی صورت گرفت و نتایج آن تحلیل گردید. در حقیقت در کرنل‌های غیرخطی SVM، پارامتر گاما کنترل کننده شکل مرز تصمیم است؛ مقادیر کم آن باعث نزدیک شدن مرز تصمیم به حالت خطی می‌شود و با افزایش مقدار آن، انعطاف‌پذیری مرز تصمیم بالاتر می‌رود و مرز تصمیم به شکل ابر داده‌های هر کلاس نزدیکتر می‌گردد تغییر پارامتر d نیز باعث انعطاف‌پذیری ابرصفحه جداکننده می‌شود.

نتایج و تحلیل‌ها

پس از طبقه‌بندی تصویر برای تفکیک ۶ واحد سنگ‌شناسی، به وسیله هر کدام از روش‌های طبقه‌بندی ذکر شده در مقاله، مرحله ارزیابی دقت انجام شد تا مشخص گردد کدام روش بیشترین دقت را در طبقه‌بندی دارا بوده است. به همین منظور، برای تهیه ماتریس خطای حاصل از تفکیک واحدهای سنگ‌شناسی در منطقه مورد مطالعه، از نقشه زمین‌شناسی اصلاح شده استفاده



شکل ۸. نتایج دقت طبقه‌بندی بر اساس مقادیر مختلف داده‌های تعلیمی و مقادیر گامای متفاوت برای کرنل چندجمله‌ای (مقادیر ستون دقت براساس درصد هستند).

1- X - Ray Fluorescence
2- X - Ray Diffraction

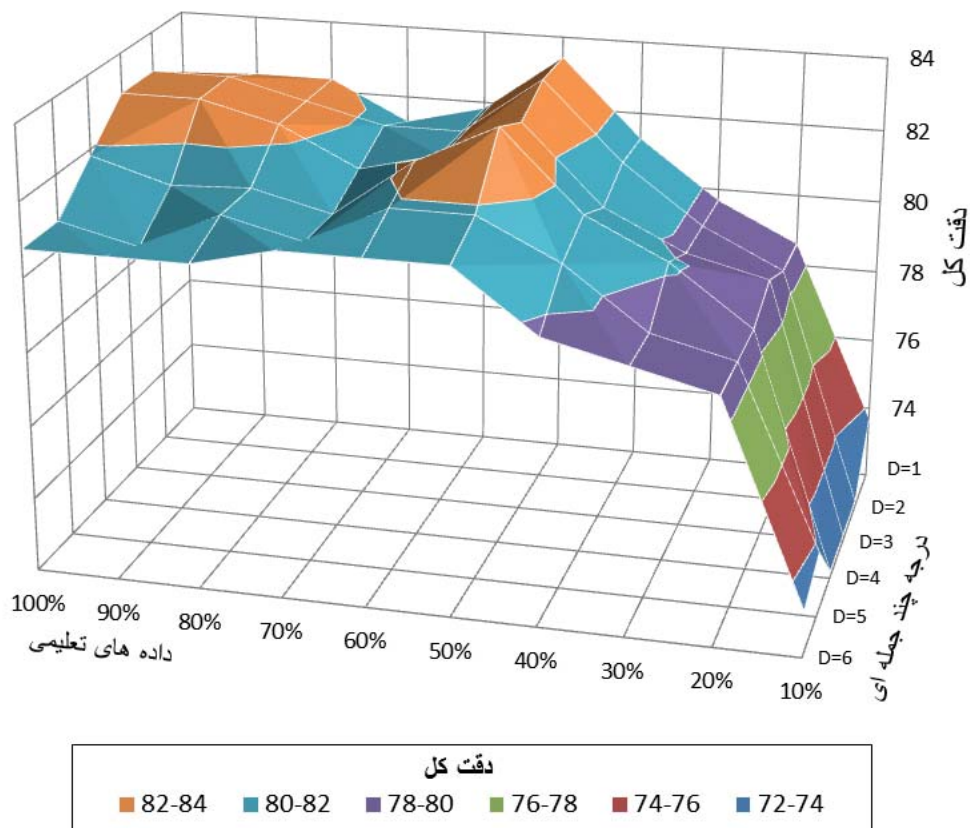
رویه بدست آمده (شکل ۱۰) نشان می‌دهد که در این کرنل RBF نیز با افزایش اندازه نمونه‌های تعلیمی، دقت طبقه‌بندی افزایش می‌یابد که این افزایش تا حجم نمونه تعلیمی ۵۰ تا ۶۰ درصد ادامه دارد و به اوج خود می‌رسد (ناحیه آبی رنگ در قله رویه) که این مقدار با اندکی کاهش در نمونه‌های تعلیمی ۱۰۰ درصد نیز مشاهده می‌شود.

هر سه مورد ذکر شده در بالا نشان دادند که تاثیر عامل چگونگی توزیع ابر داده‌ها، نسبت به عواملی چون: نوع کرنل، درجه چندجمله‌ای و مقادیر گامای متفاوت، تاثیر بیشتری بر افزایش دقت طبقه‌بندی خواهد گذاشت لذا بیشترین دقت به دست آمده در روش SVM برای ۵۰ درصد داده‌ها و معادل ۸۳/۴۲٪ با روش‌های RBF، خطی (شکل ۱۱) و چندجمله‌ای است.

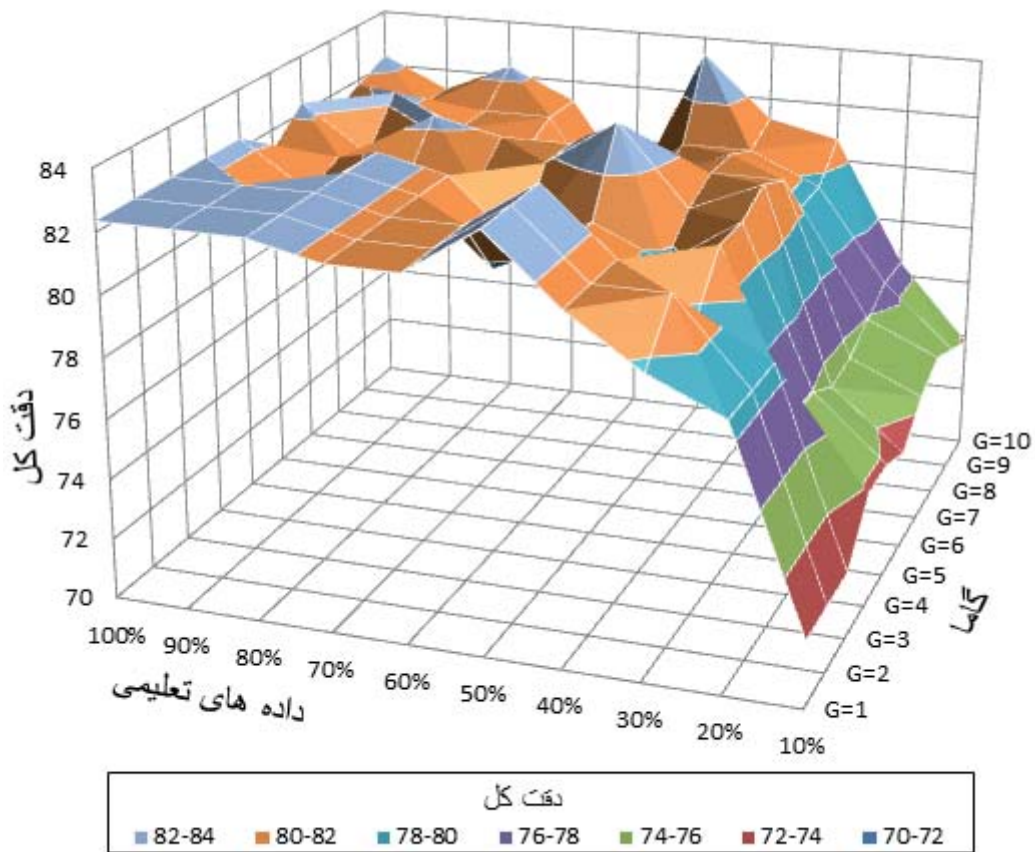
در ادامه به منظور بررسی تاثیر میزان تفکیک‌پذیری داده‌های تعلیمی مورد استفاده بر نتایج حاصل از طبقه‌بندی، از روش جفریس-ماتوسیتا استفاده گردید. در این روش مقدار بدست آمده برای تفکیک‌پذیری بین صفر تا ۲ خواهد بود که هرچه قدر عدد بدست آمده به ۲ نزدیکتر باشد، نشان دهنده بیشتر بودن تفکیک‌پذیری میان کلاس‌ها است و هر چه به صفر نزدیکتر باشد، نشان دهنده کاهش تفکیک‌پذیری است (Richards, 1999). پس از محاسبه میزان تفکیک‌پذیری به روش جفریس - ماتوسیتا برای

قابل توجه مقادیر به دست آمده برای دقت طبقه‌بندی است چرا که برای گاما از صفر تا ۷، با استفاده از ۵۰ تا ۶۰ درصد داده‌های تعلیمی می‌توان به دقتی رسید که با ۱۰۰ درصد داده‌های تعلیمی امکان رسیدن به آن وجود دارد. دو قسمت آبی رنگ در بالاترین ناحیه رویه نشان‌دهنده حداکثر دقت طبقه‌بندی است که بین ۸۲ تا ۸۴ درصد می‌باشد. ناحیه نارنجی رنگ موجود در اطراف آن رتبه دوم دقت با عدد ۸۰ تا ۸۲ درصد را داراست. نکته مهم دیگر این است که شکل فوق نشان می‌دهد که تعداد داده‌های تعلیمی و نحوه پراکندگی آنها بر نتیجه طبقه‌بندی بسیار تاثیرگذارتر از تغییرات مقدار گاما است.


با توجه به رویه به دست آمده برای شکل ۹ می‌توان به این نتیجه رسید که در اینجا نیز همانند شکل ۸، با ۵۰ درصد از داده‌های تعلیمی می‌توان به دقتی کمی بیش از زمانی که از ۱۰۰ درصد داده‌ها برای طبقه‌بندی استفاده می‌شود، رسید. دو ناحیه نارنجی رنگ در بالای رویه گواه این موضوع است. اما نکته مهم این است که برای درجات ۶ و ۵ در چندجمله‌ای با کاهش دقت روبرو هستیم که این امر ناشی از چگونگی توزیع مقادیر DN داده‌های تعلیمی نسبت به هم در فضای طیفی است که باعث گردیده درجات یک تا چهار، تفکیک بهتری برای ابر داده‌های هریک از نمونه‌های تعلیمی داشته باشد.



شکل ۹. نتایج دقت طبقه‌بندی بر اساس مقادیر مختلف داده‌های تعلیمی و مقادیر مختلف درجه چندجمله‌ای برای کرنل چندجمله‌ای (مقادیر ستون دقت براساس درصد هستند).



شکل ۱۰. نتایج دقت طبقه‌بندی بر اساس مقادیر مختلف داده‌های تعلیمی و مقادیر مختلف گاما برای کرنل RBF (مقادیر ستون دقت براساس درصد هستند).




شکل ۱۱. نتایج دقت طبقه‌بندی بر اساس مقادیر مختلف داده‌های تعلیمی برای کرنل خطی (مقادیر ستون دقت براساس درصد هستند).

در میان این روش‌ها، روش SVM بیشترین همبستگی را با کاهش تفکیک‌پذیری داده‌ها از خود نشان می‌دهد. مقادیر به دست آمده به عنوان ضریب همبستگی (۰/۹۳) برای کرنل چندجمله‌ای، ۰/۸۶ برای کرنل خطی و ۰/۹۶ برای کرنل RBF) میان دقت طبقه‌بندی به این روش و میزان تفکیک‌پذیری، گویای این حقیقت خواهد بود که زمانی که داده‌های تعلیمی به لحاظ طیفی شباهت بیشتری با هم داشته باشند و از نظر تفکیک‌پذیری طیفی، تفکیک کمتری را از خود نشان دهند این روش بیشتر از روش‌های MLC و NNC توانایی تفکیک خواهد داشت (شکل ۱۴). در حقیقت زمانی که تعداد داده‌های تعلیمی کمتر و ابر داده‌های تعلیمی تفکیک‌پذیری بیشتری از هم داشته باشند، محدوده مرز بهینه تا رسیدن به بردارهای پشتیبان بزرگتر خواهد شد. در نتیجه زمانی که طبقه‌بندی بر روی پیکسل‌های تصویر آغاز می‌گردد، پیکسل‌های بیشتری به علت قرار گرفتن در این ناحیه به کلاس دیگر اختصاص می‌یابند که همین امر دقت را کاهش می‌دهد. این امر زمانی که با داده‌های با تفکیک‌پذیری کم ولی تعداد کافی، مانند واحدهای سنگ‌شناسی، روبه‌رو هستیم پارامتری مثبت برای تفکیک‌پذیری محسوب می‌شود، ولی زمانی که این کاهش تفکیک‌پذیری با کاهش داده‌های تعلیمی حاصل شده باشد باعث کاهش دقت طبقه‌بندی می‌شود که از این نظر نکته‌ای منفی برای این روش خواهد بود.

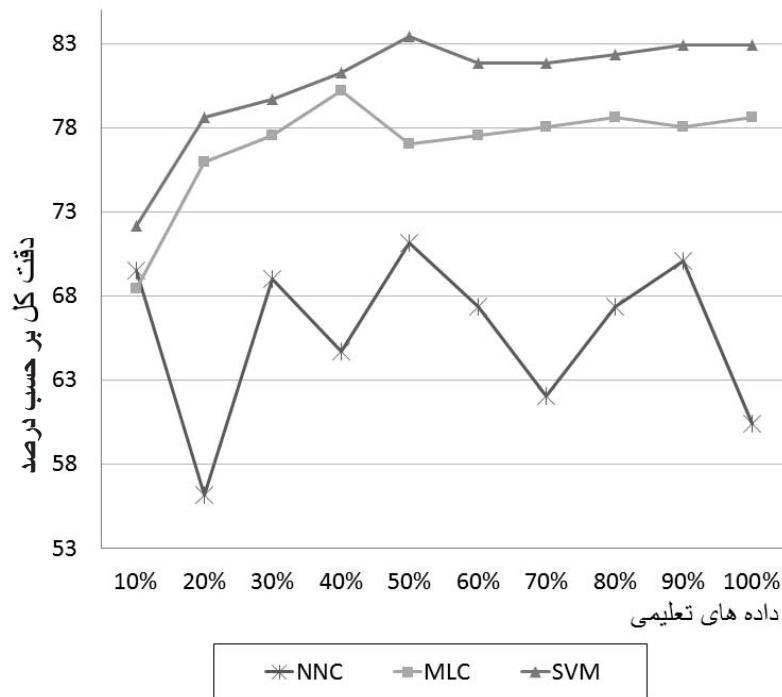
مقایسه سه روش SVM، NNC و MLC

همانگونه که در شکل ۱۴ دیده می‌شود، در تمامی نمونه‌های تعلیمی و در تمام کرنل‌ها، دقت طبقه‌بندی به روش SVM بالاتر از سایر روش‌ها است و تقریباً، در بقیه موارد روش MLC رتبه

هر یک از کلاس‌ها نسبت به کلاس دیگر، از مقادیر به دست آمده برای کلاس‌های مختلف در هر یک از حجم‌های داده‌های تعلیمی، میانگین‌گیری شد تا مشخص شود به طور نسبی در هر یک از حجم داده‌های تعلیمی چه میزان تفکیک‌پذیری خواهیم داشت. مطابق با آنچه شکل ۱۲ نشان می‌دهد با افزایش میزان داده‌های تعلیمی، میزان تفکیک‌پذیری کاهش می‌یابد. بنابراین، باید انتظار داشت تا دقت طبقه‌بندی نیز به این ترتیب کاهش یابد. روش NNC نوسانات زیادی به لحاظ دقت طبقه‌بندی، در داده‌های تعلیمی مختلف دارد و هیچ رابطه منطقی‌ای با مقادیر تفکیک‌پذیری نشان نمی‌دهد، ولی روش MLC از ۴۰ درصد داده‌های تعلیمی به بعد تقریباً مقدار ثابتی را در دقت طبقه‌بندی از خود نشان می‌دهد، ولی روند افزایشی دقت خود را با مقادیر بیشتر از ۴۰ درصد نمونه‌های تعلیمی از دست می‌دهد. زمانی که مقدار داده‌های تعلیمی بیشتر می‌شود، با توجه به اینکه داده‌ها بطور تصادفی از مجموعه نمونه‌های تعلیمی انتخاب می‌شوند، بنابر این ابر داده‌ها شکل‌های متفاوتی خواهند داشت. از آنجا که روش NNC قابلیت انعطاف با این تغییرات را ندارد، بنابراین با تغییر شکل ابر داده‌ها، دقت‌های متفاوتی را از خود نشان می‌دهد. روش MLC نیز تا حد زیادی تحت تاثیر نوع توزیع داده‌های تعلیمی و نزدیکی آنها به توزیع نرمال است، چراکه هر بار بطور تصادفی داده‌های تعلیمی از مجموعه نمونه‌های تعلیمی موجود انتخاب می‌شوند. اما زمانی که تعداد داده‌های تعلیمی به نیمی از حجم خود نزدیک می‌شوند، حضور داده‌های جدید تأثیر کمتری در حالت کلی توزیع داده‌ها می‌گذارد و این امر باعث می‌شود تا دقت این روش در ادامه روندی ثابت پیدا کند (شکل ۱۳).



شکل ۱۲. نمودار میزان تفکیک‌پذیری بدست آمده به روش جفریس-ماتوسیتا برای مقادیر مختلف داده‌های تعلیمی.

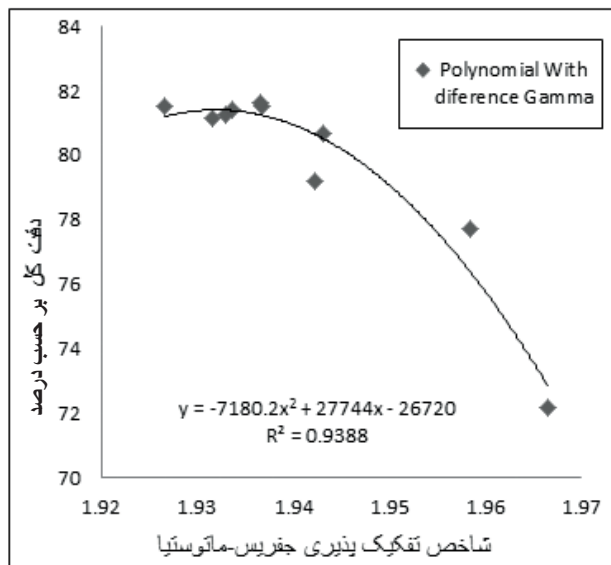


شکل ۱۳. مقایسه نتایج دقت بدست آمده برای طبقه بندی به سه روش SVM، MLC و NNC.

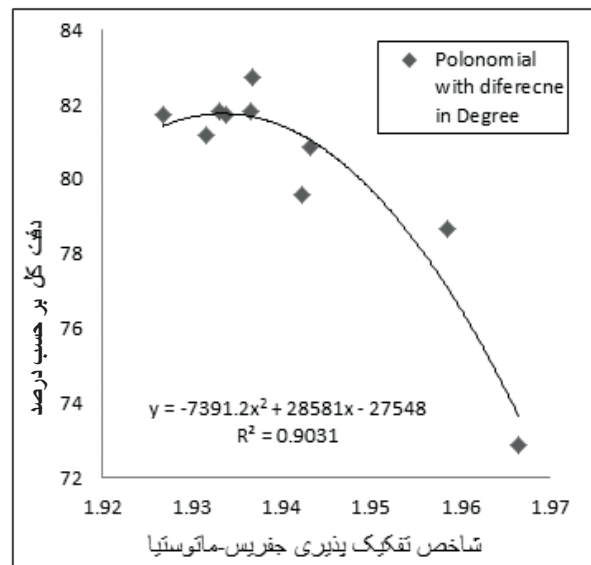
دوم را دارد. از طرفی، روش MLC فقط در یک مورد توانسته به دقت بالای ۸۰ درصد (۸۰/۲۱) برسد، این درحالی است که روش SVM در هفت مورد دقت بالای ۸۰ درصد را ثبت کرده است. جدول ۲ مقادیر ماکزیمم و مینیمم و میانگین را برای هر کدام از روش های مورد استفاده براساس نوع کرنل، درجه چندجمله ای و اندازه نمونه آموزشی به کار رفته، نشان می دهد.

جدول ۲. مقایسه مقادیر دقت حاصل برای سه روش SVM، MLC و NNC بر حسب درصد

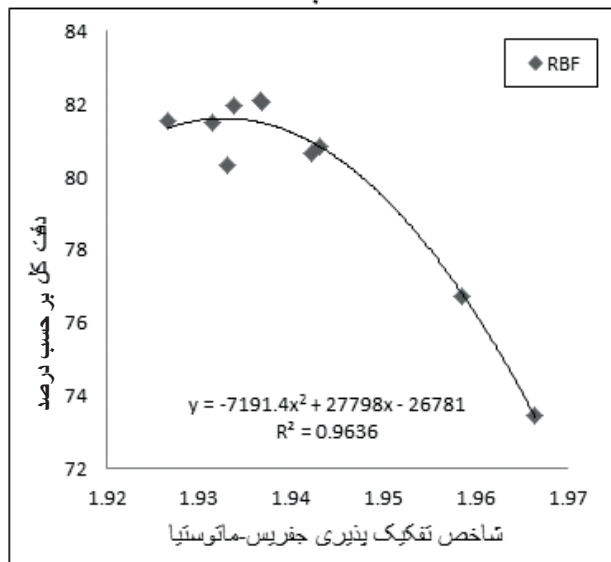
اندازه داده های آموزشی	دقت طبقه بندی (درصد)						
	MLC	NNC	SVM				خطی
			چندجمله ای		RBF		
			میانگین	ماکزیمم مقدار با توجه به d و g	میانگین	ماکزیمم مقدار با توجه به g	
۱۰%	۶۸/۴۴	۶۹/۵۲	۷۲/۸۸	۷۳/۷۷	۷۳/۴۷	۷۴/۸۷	۷۳/۲۶
۲۰%	۷۵/۹۴	۵۶/۱۵	۷۸/۷۰	۷۹/۱۴	۷۶/۷۲	۷۸/۶۱	۷۸/۶۱
۳۰%	۷۷/۵۴	۶۸/۹۸	۷۹/۵۹	۸۰/۲۱	۸۰/۶۳	۸۱/۸۲	۷۹/۶۸
۴۰%	۸۰/۲۱	۶۴/۷۱	۸۰/۸۴	۸۱/۲۸	۸۰/۸۵	۸۱/۲۸	۸۰/۷۵
۵۰%	۷۷/۰۱	۷۱/۱۲	۸۲/۷۱	۸۳/۴۳	۹۲/۹۳	۸۳/۴۲	۸۳/۴۲
۶۰%	۷۷/۵۴	۶۷/۳۸	۸۱/۸۲	۸۲/۳۵	۸۰/۳۲	۸۱/۸۲	۸۱/۲۸
۷۰%	۷۸/۰۷	۶۲/۰۳	۸۱/۱۹	۸۱/۸۲	۸۱/۴۹	۸۱/۸۲	۸۱/۲۸
۸۰%	۷۸/۶۱	۶۷/۳۸	۸۱/۷۳	۸۲/۸۲	۸۱/۹۷	۸۲/۳۵	۸۰/۷۵
۹۰%	۷۸/۰۷	۷۰/۰۵	۸۱/۷۱	۸۲/۸۹	۸۱/۵۴	۸۲/۳۵	۸۱/۲۵
۱۰۰%	۷۸/۶۱	۶۰/۴۳	۸۱/۸۲	۸۲/۸۹	۸۱/۰۸	۸۲/۳۵	۸۱/۲۸




ب



الف



د



ج

شکل ۱۴. تصاویر (الف) و (ب) نشان‌دهنده همبستگی میان دقت کل با شاخص تفکیک‌پذیری برای کرنل چندجمله‌ای با مقادیر گاما و درجه چندجمله‌ای متفاوت و تصاویر (ج) و (د) نیز بیانگر تغییرات همین پارامترها برای کرنل RBF و خطی (مقادیر ستون دقت، براساس درصد هستند).

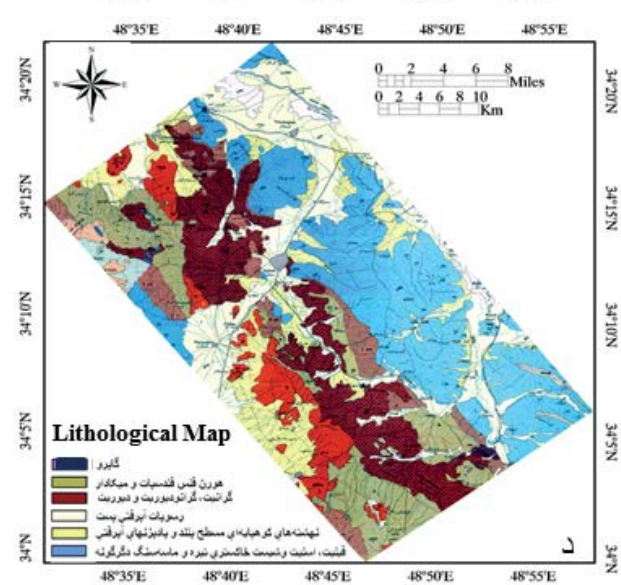
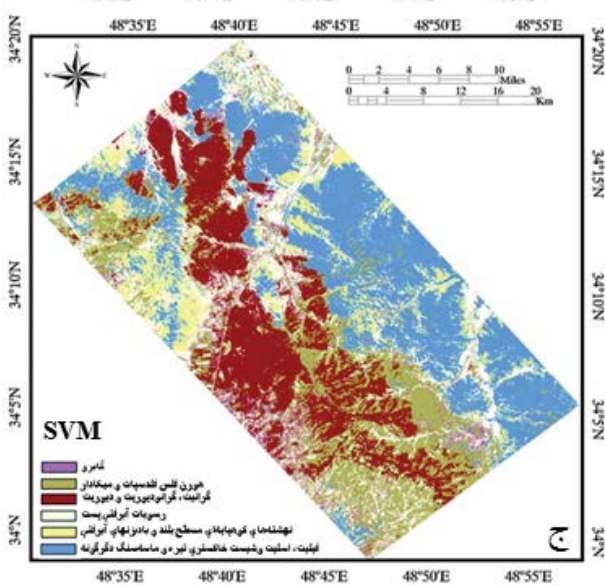
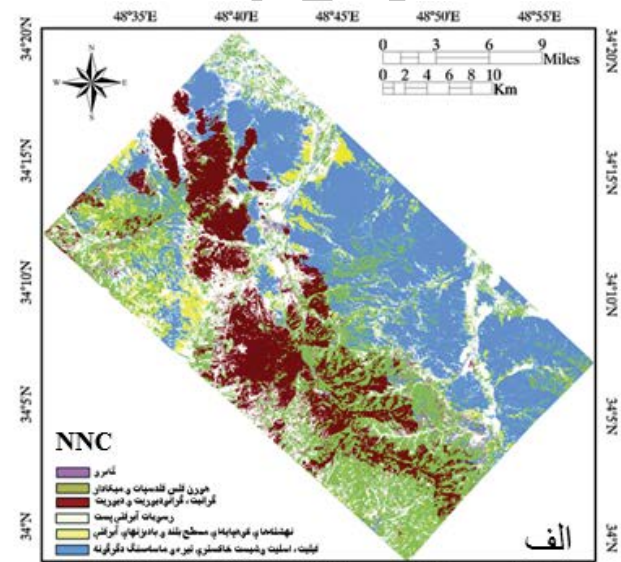
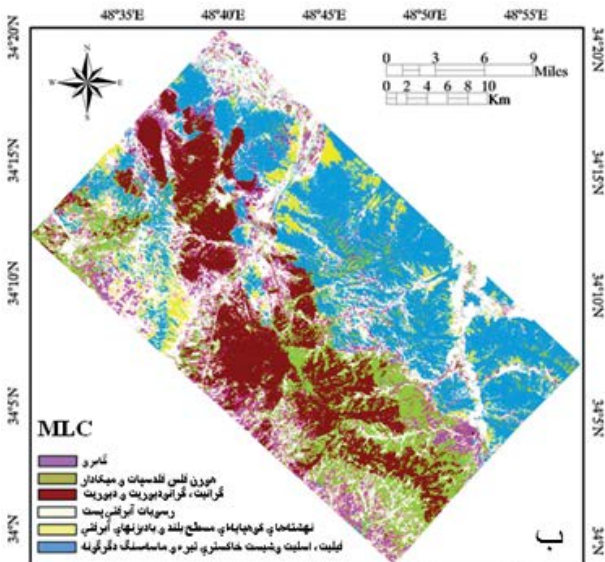
نتیجه‌گیری

با استفاده از روش ماشین بردار پشتیبان و با هر سه کرنل چندجمله‌ای، خطی و RBF با استفاده از نیمی از داده‌های تعلیمی نیز می‌توان به دقتی معادل استفاده از کل نمونه‌های تعلیمی رسید. در صورتی که تعداد داده‌های تعلیمی تفکیک‌پذیر کم باشند و این کاهش تفکیک‌پذیری، به علت کم بودن نمونه‌های تعلیمی نباشد، این روش دقت بهتری را نسبت به زمانی که تفکیک‌پذیری نمونه‌های تعلیمی بالا است از خود نشان می‌دهد. در کرنل چندجمله‌ای ماشین بردار پشتیبان، تغییرات تعداد داده‌های تعلیمی نسبت به تغییرات درجه چند جمله‌ای و گاما، تاثیر بیشتری بر تغییر نتایج طبقه‌بندی دارد.

جدول شماره ۳ نیز ماتریس خطای بدست آمده در بهترین حالت استفاده از داده‌های تعلیمی برای روش MLC، یعنی استفاده از ۴۰ درصد از نمونه‌های تعلیمی را نشان می‌دهد. شکل ۱۵ تصویر طبقه‌بندی شده به روش MLC، NNC و همچنین روش SVM برای تفکیک ۶ واحد سنگ‌شناسی را نشان می‌دهد که تصویر حاصل از روش SVM با دقت ۸۳/۴۲ درصد و توسط کرنل چندجمله‌ای با درجه ۵ و با مقدار گامای ۵ و به وسیله ۵۰ درصد از داده‌های تعلیمی تولید شده است. بنابراین با توجه به نتایج بدست آمده می‌توان به این نتیجه رسید که این روش برای تهیه نقشه واحدهای سنگ‌شناسی می‌تواند بسیار کارآمدتر از دو روش دیگر باشد.

جدول ۳. جدول ماتریس خطا برای روش طبقه‌بندی حداکثر احتمال بر مبنای استفاده از ۴۰ درصد از داده‌های تعلیمی

دقت کاربر (پیکسل)	دقت تولیدی (پیکسل)	دقت کاربر (درصد)	دقت تولیدی (درصد)	کلاس‌ها
۲۲/۳۵	۲۲/۳۰	۶۲/۸۶	۷۳/۳۳	۱
۳۰/۳۳	۳۰/۳۵	۹۰/۹۱	۸۵/۷۱	۲
۲۴/۳۳	۲۴/۳۰	۷۲/۷۳	۸۰	۳
۳۰/۳۰	۳۰/۳۲	۱۰۰	۹۳/۷۵	۴
۲۳/۳۵	۲۳/۳۰	۶۵/۷۱	۷۶/۶۷	۵
۲۱/۲۱	۲۱/۳۰	۱۰۰	۷۰	۶
۰/۷۶۲۵	ضریب کاپا	۸۰/۲۱	دقت کل	



شکل ۱۵ الف) تصویر طبقه‌بندی شده به روش NNC، ب) تصویر طبقه‌بندی شده به روش MLC، ج) تصویر طبقه‌بندی شده به روش SVM، د) تصویر نقشه زمین‌شناسی در مقیاس ۱:۱۰۰۰۰۰ سازمان زمین‌شناسی و اکتشافات معدنی کشور (جعفریان و زمانی پدرام، ۱۳۷۸).

- Chi, M., Feng, R. and Bruzzone, L., 2008. Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem. *Advances in Space Research*, 41, 1793–1799.

- Demir, B. and Erturk, S., 2009. Clustering-based extraction of border training patterns for accurate SVM classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 6, 840–844.

- Frei, M. and Jutz, S.L., 1989. Use of Thematic Mapper data for the detection of gold bearing formations in the Eastern Desert of Egypt. *Proceedings of the 7th Thematic Conference on Remote Sensing for Exploration Geology*, Environmental Research Institute of Michigan, Ann Arbor, Mich, 2, 1157–1172.

- Foody, G.M., McCulloch, M.B. and Yates, W.B., 1995. The effect of training set size and composition on artificial neural network classification. *International Journal of Remote Sensing*, 16, 1707–1723.

- Genderen, V.J.L. and Lock, B.F., 1978. Remote sensing: statistical testing of thematic map accuracy. *Remote Sensing of Environment*, 7, 3–14.

- Gong, P. and Howarth, P.J., 1990. An assessment of some factors influencing multispectral land-cover classification. *Photogrammetric Engineering and Remote Sensing*, 56, 597–603.

- Hixon, R.F., Solis Ramirez, M.J. and Villoch, M., 1981. Aspects of morphometric and reproduction of the squid *Ommastrephes petrous*, Steenstrup 1885 in the western Gulf of Mexico. *American Malacological Bulletin Union*, 54-60.

- Hord, R.M., 1982. *Digital Image Processing of Remotely Sensed Data*, Academic Press, New York, 256.

- Huang, C., Davis, L.S. and Townshend, J.R.G., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23, 725–749.

- Huang, H., Gong, P., Clinton, N. and Hui, F., 2008. Reduction of atmospheric and topographic effect on Landsat TM data for forest classification. *International Journal of Remote Sensing*, 29, 5623–5642.

- Jensen, J. R., 2005. *Introductory Digital Image Processing: A Remote Sensing Perspective*, 3rd Edition, Upper Saddle River: Prentice-Hall, 526.

- Knorn, J., Rabe, A., Radeloff, V.C., Kuemmerle, T., Kozak, J. and Hostert, P., 2009. Landcover mapping of

روش ماشین بردار پشتیبان برای تهیه نقشه‌های زمین‌شناسی حتی با کمترین نمونه‌های تعلیمی نیز دقت بیشتری نسبت به روش حداکثر احتمال و شبکه‌های عصبی ارائه می‌کند، بنابراین این روش، زمانی که هدف تفکیک و طبقه‌بندی پدیده‌هایی است که رفتار طیفی نزدیکی دارند (مانند واحدهای سنگ‌شناسی) می‌تواند بسیار کارآمدتر از روش‌های رایج طبقه‌بندی باشد.

منابع

- احمدی ندوشن، م.، سفایان، ع.، و خواجه‌الدین، س.ج. ۱۳۸۸. تهیه نقشه پوشش اراضی شهر اراک با استفاده از روش‌های طبقه‌بندی شبکه عصبی مصنوعی و حداکثر احتمال، پژوهش‌های جغرافیای طبیعی، شماره ۶۹، ۸۳–۹۸.

- جعفریان، م.ب. و زمانی پدارم، م. ۱۳۷۸. ورقه ۱:۱۰۰۰۰۰ ملایر. سازمان زمین‌شناسی و اکتشافات معدنی کشور.

- کشاورز، ا. و قاسمیان یزدی، م. ۱۳۸۴. یک الگوریتم سریع مبتنی بر ماشین بردار پشتیبان برای طبقه‌بندی تصاویر ابرطیفی با استفاده از همبستگی مکانی. مهندسی برق و مهندسی کامپیوتر ایران، شماره ۳، ۴۴–۳۷.

- Ahadnejad, V., Valizadeh, M.V., Deevsalar, R. and Rezaei-Kahkhaei, M., 2011. Age and geotectonic position of the Malayer granitoids: Implication for plutonism in the Sanandaj-Sirjan Zone, W Iran. *Neues Jahrbuch Für Geologie Und Paläontologie*. 261, 61-75.

- Al-Anazi, A. and Gates, I.D., 2010. On the capability of support vector machines to classify lithology from Well Logs. *Springer Natural Resources Research*, 19, 125-139.

- An-nan, J. and Lu, Jin., 2009. Studying the lithology identification method from well logs based on DE-SVM. *IEEE Control and Decision Conference CCDC '09 Chinese*, 2314-2318.

- Baldridge, A.M., Hook, S.J., Grove, C.I. and Rivera, G., 2009. The ASTER Spectral Library Version 2.0. *Remote Sensing of Environment*, 113, 711-715.

- Blodget, H.W., Gunther, F.J. and Podwyssocki, M.H., 1978. National Aeronautics and Space Administration, Technical Paper 1327, Discrimination of Rock Classes and Alteration Products in Southwestern Saudi Arabia With Computer-Enhanced Landsat Data, 34.

- Campbell, J.B., 1996. *Introduction to Remote Sensing*. 2th edition, New York: The Guilford Press, 622.

- Camps-Valls, G., Mooij, J. and Scholkopf, B., 2010. Remote sensing feature selection by kernel dependence measures. *IEEE Geoscience and Remote Sensing Letters*, 7, 587–591.

large areas using chain classification of neighboring Landsat satellite images. *Remote Sensing of Environment*, 113, 957–964.

- Knudby, A., Le Drew, E. and Brenning, A., 2010. Predictive mapping of reef fish species richness, diversity and biomass in Zanzibar using IKONOS imagery and machine-learning techniques. *Remote Sensing of Environment*, 114, 1230–1241.

- Lardeux, C., Frison, P.L., Tison, C., Souyris, J.C., Stoll, B., Fruneau, B. and Rudant, J.P., 2009. Support vector machine for multifrequency SAR polarimetric data classification. *IEEE Transactions on Geoscience and Remote Sensing*, 47, 4143–4152.

- Lillesand, T.M., Kiefer, R.W. and Chipman, J. W., 2004. *Remote Sensing and Image Interpretation*. John Wiley and Sons. New York, 784.

- Mantero P., Moser, G. and Serpico, S. B., 2005. Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Trans. on Geoscience and Remote Sensing*, 43, 559–570.

- Markham, B.L. and Helder, D.L., 2009. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of Environment*, 113, 893–903.

- Mathur, A. and Foody, G.M., 2008. Crop classification by support vector machine with intelligently selected training data for an operational application. *International Journal of Remote Sensing*, 29 2227–2240.

- Melgani, F. and Bruzzone, L., 2004. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42, 1778–1790.

- Mountrakis, G., Im, J. and Ogole, C., 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 13, 247–259.

- Murai, S., 1996. *Remote Sensing Note*, Japan Association of Remote Sensing.

- Oommen, T., 2008. An objective analysis of Support Vector Machine based classification for remote sensing. *Mathematical Geosciences*, 40, 409–424.

- Paola, J.D. and Schowengerdt, R.A., 1995. A review and analysis of back propagation neural networks for classification of remotely sensed multi-spectral imagery. *International Journal of Remote Sensing*, 1, 3033–3058.

- Rajendran, S., Srinivasamoorthy, K. and Aravindan, S., 2007. *Mineral exploration: recent strategies*. New India Publishing, 528.

- Richards, J.A., 1999. *Remote Sensing Digital Image Analysis*, Springer-Verlag, Berlin, 240.

- Schrader, S., Pouncy, R. (ed.), 1997. *ERDAS Field Guide*. 4th ed. ERDAS, Inc. Atlanta, GA.

- Song, X., Cherian, G. and Fan, G., 2005. A v-insensitive SVM approach for compliance monitoring of the conservation reserve program. *IEEE Geoscience and Remote Sensing Letters*, 2, 99–103.

- Srivastava, D.K. and Bhambhu, L., 2009. Data classification using support vector machine, *Journal of Theoretical and Applied Information Technology*, 1–7.

- Su, L., Huang, Y., Chopping, M.J., Rango, A. and Martonchik, J.V., 2009. An empirical study on the utility of BRDF model parameters and topographic parameters for mapping vegetation in a semi-arid region with MISR imagery. *International Journal of Remote Sensing*, 30, 3463–3483.

- Vapnik, V. and Chervonenkis, A., 1991. The necessary and sufficient conditions for consistency in the empirical risk minimization method. *Pattern Recognition and Image Analysis*, 1, 283–305.

- Wang, X., Niu, R., and Wu, K., 2011. Lithology intelligent identification using support vector machine and adaptive cellular automata in multispectral remote sensing image. *SPIE digital library*.

- Wijaya, A., 2005. *Application of Multi-stage Classification to Detect Illegal Logging with the Use of Multi-source Data*, MSc. Thesis, ITC, Enschede, The Netherlands, 64.

- Zhang, Y., Xu, Q., Li, J. and Wang, T., 2008. A robust biased estimator for exterior orientation of pushbroom satellite imagery. *Geomatica*, 62, 455–466.