



ارائه روشی ترکیبی از شبکه‌های عصبی نظارت‌شده و نظارت‌نشده در طبقه‌بندی تصاویر سنجش از دور

عطاءالله حدادی^{۱*}، محمودرضا صاحبی^۲، مهدی مختارزاده^۳، هیرش فتاحی^۴

۱. دانشجوی کارشناسی ارشد مهندسی سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی
۲. استادیار گروه مهندسی ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
۳. استادیار گروه مهندسی ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
۴. کارشناس ارشد مهندسی سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ پذیرش مقاله: ۱۳۸۹/۳/۱۸

تاریخ دریافت مقاله: ۱۳۸۸/۷/۶

چکیده

در پژوهش حاضر، روشی ترکیبی از شبکه‌های عصبی نظارت‌شده و نظارت‌نشده برای طبقه‌بندی تصاویر سنجش از دور ارائه شده است. مبنای الگوریتم پیشنهادی، شبکه‌های خودسازمانده (SOM) و الگوریتم شبکه عصبی پس‌انتشار خطاست. الگوریتم طبقه‌بندی نظارت‌نشده SOM به تنهایی قادر به طبقه‌بندی و برچسب‌گذاری دقیق نتیجه نهایی نیست، لذا در نوشتار حاضر از الگوریتم پس‌انتشار خطا برای تعیین برچسب نهایی کلاس‌ها استفاده شده است. در ابتدا تصویر با استفاده از الگوریتم شبکه‌های خودسازمانده بخش‌بندی می‌شود. سپس برچسب نرون‌های شبکه‌های خودسازمانده با استفاده از الگوریتم پس‌انتشار خطا و داده‌های آموزشی تعیین می‌شود و در ادامه نقشه پوششی تهیه می‌گردد. به‌منظور کاهش حجم سنگین محاسبات شبکه‌های خودسازمانده، در پژوهش حاضر از الگوریتم PCA برای تعیین مقدار اولیه بردار وزن نرون‌ها استفاده شده است. ارزیابی الگوریتم پیشنهادی با تصاویر چندطیفی لندست (ETM+) و IKONOS انجام گرفت. هر قسمت از الگوریتم با الگوریتم‌های دیگر جایگزین شد و نتایج به‌دست آمده با الگوریتم پیشنهادی مقایسه گردید. در ابتدا به‌جای الگوریتم SOM از الگوریتم‌های نظارت‌نشده K-Means و FCM و به‌جای الگوریتم MLP برای تعیین برچسب نرون‌های الگوریتم SOM از الگوریتم KNN استفاده گردید. همچنین نتایج نهایی الگوریتم پیشنهادی با دیگر الگوریتم‌های طبقه‌بندی مقایسه شد. نتایج حاصل از دقت طبقه‌بندی الگوریتم پیشنهادی و دیگر الگوریتم‌ها، نشان می‌دهد که الگوریتم پیشنهادی توانایی بهبود نتایج طبقه‌بندی را - به‌ویژه برای تعداد نمونه‌های آموزشی اندک - داراست.

کلیدواژه‌ها: سنجش از دور، طبقه‌بندی، شبکه‌های عصبی مصنوعی، الگوریتم SOM، الگوریتم MLP.

* نویسنده مکاتبه‌کننده: تهران، خیابان ولیعصر، تقاطع میرداماد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری. تلفن: ۸۸۸۸۸۴۴۵

۱- مقدمه

مزایای مختلف داده‌های سنجش از دور، همچون امکان تهیه اطلاعات در مقیاس‌های مختلف جهانی، ملی و ناحیه‌ای، پوشش وسیع، مقرون به صرفه بودن، تولید اطلاعات چندزمانه و مواردی از این دست، کاربردهای گوناگونی را برای داده‌های سنجش از دور امکان‌پذیر ساخته است. از جمله این کاربردها تهیه نقشه‌های کاربری و پوششی با استفاده از داده‌های سنجش از دور است (Richards and Jia, 2006).

یکی از مهمترین روش‌های استخراج اطلاعات از تصاویر سنجش از دور، طبقه‌بندی است که به کاربران امکان تولید انواع اطلاعات مختلفی از قبیل نقشه‌های پوششی، نقشه‌های کاربری، و نقشه تغییرات را می‌دهد. الگوریتم‌های طبقه‌بندی در حالت کلی به دو روش نظارت‌شده^۱ و نظارت‌نشده^۲ تقسیم‌بندی می‌شوند. در الگوریتم‌های طبقه‌بندی نظارت‌شده از داده‌های آموزشی که غالباً براساس نقشه‌های حقیقی زمین و عملیات میدانی تهیه شده‌اند، استفاده می‌شود. در روش نظارت‌نشده، مرحله آموزش وجود ندارد و الگوریتم براساس مشخصات آماری داده‌های سنجش از دور مورد نظر، عمل دسته‌بندی را انجام می‌دهد. روش‌های طبقه‌بندی نظارت‌نشده معمولاً به نام روش‌های خوشه‌بندی^۳ مطرح می‌گردند. در این حالت، تصویر به تعدادی کلاس با برچسب نامشخص طبقه‌بندی می‌شود؛ لذا کاربر پس از عمل طبقه‌بندی باید برچسب کلاس‌ها را براساس سایر منابع اطلاعاتی مشخص کند (Ibid). دقت الگوریتم‌های طبقه‌بندی نظارت‌شده به مراتب بالاتر از الگوریتم‌های نظارت‌نشده است، اما این الگوریتم‌ها نیازمند تعداد داده‌های آموزشی زیادی هستند. این مشکل در داده‌های با ابعاد بالاتر بیشتر به چشم می‌خورد. در نوشتار حاضر، الگوریتمی برای طبقه‌بندی داده‌های با ابعاد بالا، بدون نیاز به تعداد داده‌های آموزشی زیاد پیشنهاد شده است که حاصل تلفیق الگوریتم پس‌انتشار خطا^۴ (MLP) است که از نوع شبکه عصبی نظارت‌شده و الگوریتم شبکه‌های

خودسازمانده^۵ (SOM) است که در زمره شبکه‌های عصبی نظارت‌نشده قرار دارد.

شبکه‌های عصبی شبیه‌سازی‌شده از مغز انسان، شامل نرون‌هایی هستند که از طریق وزن‌هایی به هم مرتبط شده‌اند، و به‌طور کلی به دو دسته نظارت‌شده و نظارت‌نشده تقسیم می‌شوند. هر یک از این دو دسته به عنوان یکی از روش‌های رایج در بسیاری از کاربردها شناخته شده‌اند. الگوریتم MLP و SOM به ترتیب یکی از انواع رایج الگوریتم‌های شبکه عصبی نظارت‌شده و نظارت‌نشده هستند (Atkinson and Tatnall, 1997).

الگوریتم MLP برای طبقه‌بندی بسیاری از تصاویر ماهواره‌ای به کار گرفته شده است که از جمله می‌توان به اینها اشاره کرد: تصاویر با حد تفکیک بالا (Mokhtarzade and Valadan Zoej, 2007; Del Frate et al., 2007)، طبقه‌بندی تصاویر راداری (Hara et al., 1994)، طبقه‌بندی و شناسایی تغییرات در تصاویر مرئی با رزولوشن بالا (Pacifci et al., 2007; Chini et al., 2008)، طبقه‌بندی و شناسایی تغییرات در تصاویر SAR (Del Frate et al., 2008)، شناسایی اهداف در تصاویر POLSAR به صورت خودکار (Martorella et al., 2009) و بسیاری از تصاویر دیگر. یکی از مشکلات الگوریتم MLP همانا نیاز آن به داده‌های آموزشی زیاد است (Bogdanov, 2008). این امر باعث می‌شود تا الگوریتم مذکور در مواقعی که داده‌های آموزشی و کنترلی کافی در اختیار نباشد، نتایج ضعیفی به دست دهد.

از جمله تحقیقات صورت گرفته در خصوص استفاده از الگوریتم SOM - به‌عنوان یکی از روش‌های طبقه‌بندی نظارت‌نشده- می‌توان به طبقه‌بندی ابرها در تصاویر ماهواره‌ای NOAA (Wilkinson et al. 1992)،

1. Supervise
2. Unsupervise
3. Clustering
4. Multi Layer Perceptron
5. Self Organizing Map

به‌منظور کاهش حجم سنگین محاسبات شبکه‌های خودسازمانده، در اینجا از الگوریتم PCA برای تعیین مقدار اولیه بردار وزن نرون‌ها استفاده شده است.

ارزیابی الگوریتم پیشنهادی با یک تصویر لندست (ETM+) که دارای شش باند است و یک تصویر IKONOS که دارای چهار باند است، انجام گرفت. هر قسمت از الگوریتم با الگوریتم‌های دیگر جایگزین شد و نتایج به‌دست آمده با الگوریتم پیشنهادی مقایسه گردید. در ابتدا به‌جای الگوریتم SOM از الگوریتم‌های نظارت‌نشده K-Means و FCM و به‌جای الگوریتم MLP برای تعیین برجسب نرون‌های الگوریتم SOM از الگوریتم KNN استفاده گردید. همچنین نتایج نهایی الگوریتم پیشنهادی با دیگر الگوریتم‌های طبقه‌بندی مقایسه شد. نتایج حاصل از دقت طبقه‌بندی الگوریتم پیشنهادی و دیگر الگوریتم‌ها، مؤید این مطلب است که الگوریتم پیشنهادی می‌تواند نتایج طبقه‌بندی را - به‌ویژه برای تعداد نمونه‌های آموزشی اندک - بهبود بخشد.

ساختار مقاله حاضر بدین شرح است: در بخش دوم، نظریه شبکه‌های عصبی شامل الگوریتم SOM و الگوریتم MLP توضیح داده شده است. در بخش سوم، الگوریتم پیشنهادی تشریح شده است. در بخش چهارم ابتدا منطقه مورد مطالعه و داده‌های استفاده شده توصیف می‌شوند، سپس نتایج حاصل از الگوریتم پیشنهادی و دیگر الگوریتم‌های طبقه‌بندی استفاده‌شده در تحقیق ارائه می‌شود. در نهایت در بخش پنجم، نتایج حاصل مورد بحث قرار می‌گیرد و پیشنهادهایی برای کارهای آینده ارائه شده است.

۲- طبقه‌بندی تصاویر سنجش از دور به کمک شبکه‌های عصبی

شبکه عصبی مصنوعی از اجزای ساده محاسباتی به‌نام نرون‌ها تشکیل شده که در واقع ساختار آنها از ساختار

طبقه‌بندی پوشش زمین با استفاده از تصاویر SPOT (Hosokawa et al., 1999)، طبقه‌بندی تصاویر پلاریمتری (Putignano et al., 2006; Hosokawa and Hoshi., 2002; Hara et al., 1994) و شناسایی تغییرات در تصاویر لندست ETM+ و TM (Ghosh et al., 2009) اشاره کرد. با توجه به اینکه روش SOM از نوع الگوریتم‌های نظارت‌نشده است، تنها خوشه‌بندی تصویر صورت گرفته و لازم است تا برجسب‌گذاری خوشه‌ها در مرحله‌ای جداگانه دنبال شود. همچنین، زمان طولانی برای محاسبات از دیگر مشکلات استفاده از روش SOM به شمار می‌آید.

ترکیب الگوریتم‌های MLP و SOM برای طبقه‌بندی تصاویر سنجش از دور ارائه شده است (Goncalves et al., 1998). در این روش از الگوریتم SOM برای تصویر فضای چندبعدی به یک فضای دوبعدی استفاده شده است که از آن برای تعیین داده‌های آموزشی برای هر کلاس استفاده می‌شود. سپس بر اساس داده‌های آموزشی، الگوریتم MLP آموزش می‌بیند و تصویر ورودی مورد طبقه‌بندی قرار می‌گیرد. همچنین Lee و Lathrop در سال ۲۰۰۶ با ترکیب الگوریتم‌های SOM، LVQ^۱ و GMM الگوریتمی برای طبقه‌بندی تصاویر سنجش از دور در مناطق شهری ارائه کرده‌اند.

در پژوهش حاضر، ضمن معرفی ساختاری مناسب برای تلفیق روش‌های نظارت‌شده و نظارت‌نشده شبکه‌های عصبی، به ارزیابی دقت و مقایسه نتایج با سایر روش‌های طبقه‌بندی پرداخته شده است. هدف اصلی از ترکیب این دو روش، دستیابی به مزایای هر دو الگوریتم شامل دقت بالا، و نیاز به تعداد داده‌های آموزشی کم و مناسب برای داده‌های با ابعاد بالاست. در روش پیشنهادی ابتدا تصویر با استفاده از الگوریتم شبکه‌های خودسازمانده بخش‌بندی می‌شود. سپس برجسب نرون‌های شبکه‌های خودسازمانده با استفاده از الگوریتم پس‌انتشار خطا و داده‌های آموزشی تعیین می‌شود و در ادامه نقشه پوششی تهیه می‌گردد.

1. Gaussian Mixture Model

نرون i مختصات (x_i, y_i) در فضای توپولوژی و بردار وزنی $\underline{w}_i = (w_i^1, w_i^2, \dots, w_i^n)^T \in R^n$ اختصاص داده می‌شود، که ارتباط بین نرون‌های لایه ورودی و نرون‌های لایه خروجی را برقرار می‌سازد و در آن، n معرف ابعاد داده‌های ورودی است.

الگوریتم SOM در فرایندی دومارحله‌ای آموزش می‌بیند. در مرحله اول، نرون برنده در الگوریتم SOM بر مبنای معیار شباهت که معمولاً فاصله اقلیدسی یا منتهن است انتخاب می‌گردد. در مرحله دوم، به‌روزرسانی بردار وزن نرون‌ها در مرحله آموزش که عملی تکراری است صورت می‌پذیرد. رابطه (۱) نحوه به‌روزرسانی وزن‌ها را نشان می‌دهد.

رابطه (۱)

$$\underline{w}_i(t+1) = \underline{w}_i(t) + \eta(t)h_{si}(t)[\underline{x} - \underline{w}_i(t)]$$

در این رابطه پارامتر h_{si} تابع همسایگی را در اطراف نرون برنده (s) ، $\eta \in [0, 1]$ نرخ به‌روزرسانی بردار وزن‌ها، \underline{w} بردار وزن، t نشان‌دهنده تکرار و $i \in [1, m]$ شماره نرون مورد بررسی است.

تابع h_{si} می‌تواند مستطیلی^۱ با مقداری ثابت برای همسایه‌های نرون برنده در یک شعاع همسایگی و مقدار صفر برای دیگر نرون‌ها و یا به صورت تابع گوسین در نظر گرفته شود. البته بیان تابع به صورت گوسین نتایج بهتری در این زمینه ارائه می‌دهد، زیرا بردار وزن نرون‌های همسایه بر اساس فاصله از نرون برنده به‌روز خواهد شد که در واقع مقداری ثابت نیست و به صورت رابطه (۲) تعریف می‌شود.

رابطه (۲)

$$h_{si}(t) = \exp(-\text{dist}(N_s, N_i)^2 / 2\sigma^2(t))$$

در این رابطه $\text{dist}(N_s, N_i)$ فاصله اقلیدسی بین نرون برنده N_s ، و نرون مورد بررسی N_i در فضای

نرون‌های عصبی بیولوژیکی انسان شبیه‌سازی شده است. مهمترین وظیفه نرون، دریافت اطلاعات از نرون‌های همسایه به عنوان ورودی، انتساب پارامتر وزن به هر یک از ورودی‌ها، تأثیر بر ورودی‌های موجود به وسیله تابع عملکرد داخلی نرون به‌منظور محاسبه پاسخ نرون به داده‌های ورودی و نهایتاً ارسال پاسخ محاسبه‌شده به سایر نرون‌های شبکه به عنوان ورودی جدید است (Atkinson and Tatnall, 1997; Haykin, 1999). دو مرحله مهم در عملکرد شبکه عصبی عبارتند از آموزش شبکه و بازخوانی شبکه.

در مرحله آموزش، وزن‌های هر یک از نرون‌های موجود در شبکه (که به پارامترهای ورودی نرون مربوط به آن نسبت داده می‌شوند) طی فرایندی تکرار شونده تغییر می‌کنند. تغییرات اعمال شده سبب می‌گردد که در نهایت شبکه مذکور به‌منظور انجام محاسباتی خاص و جایگزینی تابعی ویژه جهت‌دهی می‌شود. به‌منظور آموزش شبکه، معمولاً از داده‌های آموزشی استفاده می‌شود که به آن آموزش نظارت‌شده گفته می‌شود. داده‌های آموزش شامل مجموعه‌ای از داده‌های ورودی هستند که پاسخ مورد انتظار برای آنها از قبل مشخص است.

در نوشتار حاضر روشی ترکیبی از شبکه‌های عصبی نظارت‌شده و نظارت‌نشده برای طبقه‌بندی تصاویر سنچس از دور ارائه شده است. الگوریتم پیشنهادی بر اساس شبکه‌های خودسازمانده (SOM) و الگوریتم شبکه عصبی پس‌انتشار خطاست.

۲-۱- شبکه‌های عصبی خودسازمانده

الگوریتم شبکه‌های خودسازمانده از دو لایه تشکیل شده است، لایه ورودی که معمولاً هر نرون در آن معادل یک باند از تصویر است و لایه خروجی که لایه رقابتی نیز نامیده می‌شود (Kohonen et al., 2000; Kohonen, 1995). لایه خروجی SOM به صورت مجموعه‌ای از m نرون است که این نرون‌ها در نوعی توپولوژی ویژه در کنار یکدیگر قرار می‌گیرند. به هر

1. Bubble

بردار وزن‌ها و مواردی از این دست، از دیگر مشکلات الگوریتم SOM به شمار می‌آید. پارامترهای مذکور معمولاً برحسب ماهیت داده‌های ورودی و به صورت سعی و خطا تعیین می‌شوند (Su & Chang, 2000). همچنین واحد مرده^۱ نیز که به دلیل شرکت نکردن یک نرون در رقابت به وجود می‌آید، نتایج الگوریتم SOM را تحت تأثیر قرار می‌دهد (Menhaj, 2002).

۲-۲- شبکه‌های عصبی پس از انتشار خطا


الگوریتم پس‌انتشار را در سال ۱۹۸۲ پارکر مطرح کرد و روملهارات، هینتون و ویلیامز در سال ۱۹۸۶ به شرح و بسط آن پرداختند (Zurada, 1992). در این شبکه‌ها، عناصر پردازشگر معمولاً در قالب لایه‌های مختلف شامل سه نوع لایه ورودی، میانی و خروجی ساختاردهی می‌شوند. شکل ۱ ساختار یک شبکه عصبی پس‌انتشار خطا را نشان می‌دهد.

لایه ورودی دارای نرون‌هایی به تعداد ابعاد داده‌های ورودی طبقه‌بندی است، که هر نرون وظیفه ورود یک باند اطلاعاتی به شبکه را بر عهده دارد. لایه خروجی دارای یک نرون است که نوع کلاس خروجی هر پیکسل را مشخص می‌سازد و لایه‌های میانی به‌عنوان واسط لایه ورودی و خروجی، عملکرد شبکه را غیرخطی و منعطف می‌کند.

توپولوژی و $\sigma(t)$ تابعی از تعداد تکرار است که شعاع همسایگی را تعیین می‌کند.

الگوریتم‌های خوشه‌بندی مانند الگوریتم SOM وابسته به مقادیر اولیه هستند. برای تعیین مقادیر اولیه بردار وزن نرون‌ها در الگوریتم SOM چندین روش مانند استفاده از مقادیر تصادفی و یا استفاده از مقادیر ویژه داده‌های اولیه وجود دارد (Haykin, 1999). اتیک و همکاران (Attik et al., 2005) چند روش تعیین مقدار اولیه را برای الگوریتم SOM که شامل روش تصادفی و PCA است، بررسی کردند و روشی بر مبنای PCA و استفاده از گرید منظم برای تعیین مقادیر اولیه SOM را پیشنهاد کردند. روش‌های دیگری چون استفاده از الگوریتم K-Means نیز برای بهبود الگوریتم SOM پیشنهاد شده است (Su and Chang, 2000).

از مهمترین مزایای شبکه‌های خودسازمان‌ده می‌توان به انعطاف‌پذیری، عدم حساسیت به داده اشتباه (Villmann et al., 2003)، تطابق با تراکم داده‌ها (Simard et al., 2000) و عدم محدودیت نسبت به ابعاد فضای ورودی (Kohonen et al., 2000) اشاره کرد. در مقابل این مزایا، محاسبات پیچیده و زمانبر از مشکلات الگوریتم SOM به شمار می‌آید. علاوه بر تعداد دفعات تکرار زیاد در مرحله آموزش، وابستگی نتایج اجرای الگوریتم به معرفی تعداد زیادی از پارامترهای ورودی مانند نرخ آموزش، تابع همسایگی، مقدار اولیه برای



شکل ۱. ساختار شبکه عصبی پس‌انتشار خطا

1. Dead unit

پارامترهای نرخ به روزرسانی و گشتاور باید به درستی به شبکه معرفی شود. مقدار η باید بین صفر و یک باشد. استفاده از مقادیر بزرگ مانند $0/8$ سبب همگرایی سریع می شود اما در تکرارهای بعدی، جواب الگوریتم حول نقطه مینیمم نوسان می کند و مقدار کوچک باعث زمان بر شدن الگوریتم می شود؛ اما الگوریتم به پایداری بالاتری دست می یابد.

۳- معرفی الگوریتم پیشنهادی

الگوریتم پیشنهادی در پژوهش حاضر مشتمل بر دو مرحله اصلی شامل طبقه بندی نظارت نشده به وسیله شبکه خودسازمانده SOM و سپس برچسب گذاری نرون های خروجی این شبکه به وسیله یک شبکه عصبی پس انتشار خطاست. شکل ۲ الگوریتم پیشنهادی را نشان می دهد.

ابتدا SOM براساس بخشی از تصویر مورد آموزش نظارت نشده قرار می گیرد. در این مرحله برای کاهش محاسبات و همگرایی سریع الگوریتم SOM از الگوریتم PCA برای تعیین مقادیر اولیه بردار وزن ها استفاده شده است.

دوم، SOM آموزش داده شده بر روی کل تصویر اعمال می شود و پیکسل ها را خوشه بندی می کند. خروجی این مرحله تصویری است که به تعداد نرون های الگوریتم SOM طبقه بندی شده است. اما برچسب واقعی پیکسل ها مشخص نیست.

سوم، داده های آموزشی که به وسیله کاربر تهیه شده است به منظور آموزش شبکه عصبی MLP در برچسب گذاری خوشه های SOM مورد استفاده قرار می گیرد و شبکه MLP آموزش دیده به منظور طبقه بندی نهایی تصویر به کار گرفته می شود. با استفاده از داده های آموزشی تعیین شده، برای هر کلاس نرون هایی از الگوریتم SOM فعال می شوند. با توجه به

آموزش شبکه های عصبی MLP شامل دو مرحله است. در مرحله اول که از سمت ورودی به سمت خروجی است، مقدار خطا برحسب رابطه (۳) محاسبه می شود.

$$E = \frac{1}{2} \sum_{j=1}^L (d_j - o_j^m)^2 \quad \text{رابطه (۳)}$$

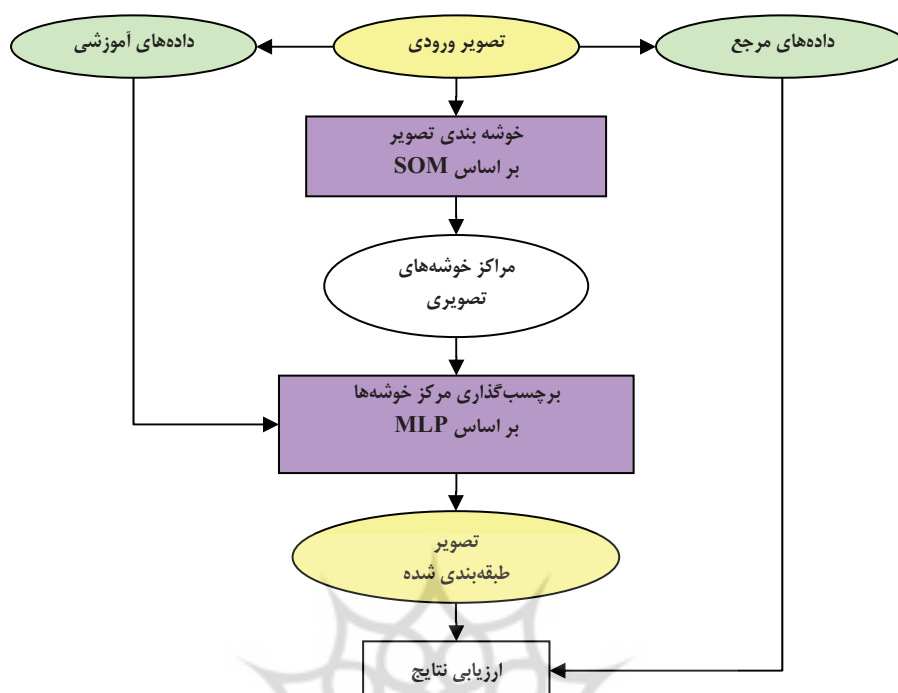
که در آن d_j و o_j به ترتیب خروجی مورد انتظار و جواب حاصل از شبکه عصبی در نرون j ام موجود در لایه خروجی را نشان می دهند و L تعداد نرون های طراحی شده در لایه پایانی است. در مرحله دوم که از سمت خروجی شبکه به سمت ورودی شبکه است، بردار وزن ها تعدیل می شود. رابطه (۴) چگونگی این محاسبات را نشان می دهد.

$$\begin{cases} \Delta w_{i,j}^{k-1,k} = -\eta(t) \frac{\partial E}{\partial w_{i,j}^{k-1,k}} \\ \Delta w_{i,j}(t+1) = -\Delta w_{i,j} + \alpha \Delta w_{i,j}(t) \end{cases} \quad \text{رابطه (۴)}$$

به طوری که $w_{i,j}$ وزن منتسب به پاسخ نرون j ام است که به عنوان ورودی به نرون i ام در لایه بعد ارسال می گردد. η ثابت عددی است که روند و مقدار تصحیحات اعمال شده به وزن ها را کنترل می کند و نرخ آموزش^۱ نامیده می شود. α که پارامتر اینرسی^۲ نام دارد، مقادیر بین صفر و یک به خود می گیرد و در نقش پایدارسازی روند آموزش عمل می کند، بدین ترتیب که میزان تصحیحات در هر مرحله تحت تأثیر مرحله قبل است. t بیانگر تعداد تکرار انجام شده در مرحله آموزش است.

در ساختار MLP معمولاً یک لایه میانی برای مقاصد طبقه بندی کفایت می کند، اما رابطه ای که تعداد نرون در لایه میانی را مشخص کند به صورت صریح وجود ندارد. استفاده از تعداد نرون زیاد در لایه میانی، شبکه را قادر به یادگیری بیشتر می کند و از طرف دیگر زمان آموزش و فراخوانی را نیز بالا می برد. علاوه بر این،

1. Learning Rate
2. Momentum Parameter



شکل ۲. الگوریتم پیشنهادی: در ابتدا تصویر با استفاده از SOM خوشه‌بندی می‌شود، سپس برچسب نرون‌ها با استفاده از MLP تعیین می‌گردد و نهایتاً نقشه پوششی حاصل می‌شود.

ماتریس خطا پارامترهای متعددی برای بیان دقت استخراج می‌گردد که از آن جمله می‌تواند دقت کلی^۱، ضریب کاپا^۲، دقت کاربر^۳ و دقت تولیدکننده^۴ را نام برد (Richards and Jia, 2006).

۴- پیاده‌سازی و ارزیابی نتایج

برای پیاده‌سازی الگوریتم پیشنهادی در این مقاله از نرم‌افزار Matlab استفاده شده است. به این منظور توابع نرم‌افزار مطابق با نیازهای تحقیقاتی مورد ویژه‌سازی قرار گرفت. همچنین آماده‌سازی تصویر و استخراج داده‌های آموزشی و داده‌های چک با استفاده از نرم‌افزار

اینکه نرون‌های الگوریتم SOM در فرایند آموزش به طور کامل در فضای ویژگی تصویر پخش می‌شوند، لذا نرون‌هایی از الگوریتم SOM دو کلاس و یا بیشتر را مشخص می‌کنند. ورودی الگوریتم پس‌انتشار خطا، همان بردار وزن نرون‌های الگوریتم SOM و برچسبی است که به‌وسیله الگوریتم SOM تعیین شده است. خروجی این بخش جدول^۱ LUT است که شماره نرون و برچسب نرون را در خود جای می‌دهد. با اعمال این جدول، برچسب واقعی خوشه‌های حاصل از الگوریتم SOM تعیین می‌شود و نقشه پوششی از تصویر تهیه می‌گردد.

چهارم، ارزیابی دقت براساس داده‌های چک. گام نهایی در هر فرایند طبقه‌بندی برآورد دقت است. با برآورد دقت، میزان اطمینان بر روی نتایج مشخص می‌شود. متداول‌ترین راه برای بیان کردن دقت طبقه‌بندی، استفاده از ماتریس خطا^۲ است. بر مبنای


1. Look Up Table
2. Error matrix or Confusion matrix
3. Overall accuracy
4. Kappa coefficient
5. User's accuracy
6. Producer's accuracy

هفت، ماهواره لندست -۷، سنجنده ETM+ است. این تصویر مربوط به قسمتی از شهر تیمینس^۱ کشور کاناداست. در شکل ۳-الف تصویر ماهواره‌ای منطقه مورد نظر در باندهای ۳، ۴ و ۵ نشان داده شده است. رزولوشن تصویر ۳۰ متر و اندازه تصویر ۴۹۳ پیکسل در ۹۱۰ پیکسل است این تصویر در تاریخ ۲۰۰۱/۸/۲۱ گرفته شده است. داده‌های آموزشی و کنترل برای ارزیابی الگوریتم در این تصویر، از نقشه پوششی (شکل ۳-ب) که تحت نظارت سازمان منابع طبیعی کانادا در سال ۲۰۰۴ تهیه شده است، استخراج گردید.

ENVI انجام گرفت. در ادامه پس از تشریح داده‌های مورد استفاده، روند اجرایی و نتایج حاصل از هر بخش، شامل پیاده‌سازی الگوریتم SOM و برچسب‌گذاری خوشه‌ها براساس الگوریتم MLP تشریح شده است. در پایان، ضمن مقایسه نتایج، بررسی تأثیر پارامترهای مختلف در الگوریتم‌های فوق تشریح شده است.

۴-۱- داده‌های مورد استفاده

برای ارزیابی الگوریتم پیشنهادی از دو تصویر استفاده شده است. تصویر اول شامل باندهای یک تا پنج و باند



شکل ۳. الف) تصویر لندست مورد مطالعه در باندهای ۳، ۴ و ۵. ب) نقشه پوششی. دایره‌های زرد رنگ، کلاس‌های در نظر گرفته شده برای طبقه‌بندی را نشان می‌دهند.

۱. آب	
۲. جنگل پرتراکم مختلط	
۳. باتلاق - باز	
۴. جنگل پرتراکم میوه مخروطی (coniferous)	
۵. منطقه مسکونی	
۶. باتلاق - درخت	
۷. جنگل - درخت همیشه سبز	
۸. زمین کشاورزی - چراگاه و چمنزار	

شکل ۳. الف) تصویر لندست مورد مطالعه در باندهای ۳، ۴ و ۵. ب) نقشه پوششی. دایره‌های زرد رنگ، کلاس‌های در نظر گرفته شده برای طبقه‌بندی را نشان می‌دهند.

1. Timmins

تصویر لندست تنها ۰/۴۳ درصد از کل داده‌ها را شامل می‌شود.

تصویر دوم شامل باندهای قرمز، سبز، آبی، مادون قرمز و پارامتر NDVI قسمتی از تصویر ماهواره IKONOS از شهر شیراز است. این تصویر قسمتی از شهر شیراز را نشان می‌دهد. در شکل ۴ تصویر منطقه مورد نظر در باندهای ۲، ۳ و ۴ نشان داده شده است. رزولوشن تصویر ۴ متر و اندازه تصویر ۳۰۰ پیکسل در ۲۷۵ پیکسل است. این تصویر در تاریخ ۲۰۰۸/۹/۲۰ گرفته شده است.

برای تصویر لندست، هشت کلاس که به صورت دایره‌های زردرنگ در شکل ۳- ب نشان داده شده است در نظر گرفته شد. جدول ۱ تعداد داده‌های آموزشی و کنترل برای کلاس‌های در نظر گرفته شده در تصویر لندست را نشان می‌دهد. داده‌های آموزشی و کنترل به صورت مستقل و بدون پیکسل مشترک انتخاب شدند و سعی شده است که از نقاط مختلف نقشه پوششی برای انتخاب داده‌های آموزشی و نیز داده‌های کنترل استفاده شود. چنانچه مشاهده می‌شود، داده‌های آموزشی برای

جدول ۱. تعداد داده‌های آموزشی و کنترل در نظر گرفته شده برای آموزش و ارزیابی الگوریتم‌های طبقه‌بندی برای تصویر لندست

اندکس کلاس	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	کلاس ۶	کلاس ۷	کلاس ۸
تعداد داده‌های چک	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
تعداد داده‌های آموزشی	۲۴۵	۲۴۵	۲۴۵	۲۲۴	۲۴۵	۲۴۵	۲۴۵	۲۴۵



شکل ۴. تصویر IKONOS از شهر شیراز در باندهای ۲، ۳ و ۴

جدول ۲. تعداد داده‌های آموزشی و کنترل در نظر گرفته شده برای آموزش و ارزیابی الگوریتم‌های طبقه‌بندی برای تصویر IKONOS

اندکس کلاس	منطقه شهری	خیابان	درخت	گیاه	خاک	غیره
تعداد داده‌های چک	۱۱۷۷	۲۰۳	۱۹۴	۱۷۶	۱۵۹	۱۹۵
تعداد داده‌های آموزشی (۱)	۵۵۰	۵۴۹	۴۹۰	۵۰۳	۵۷۲	۴۲۰
تعداد داده‌های آموزشی (۲)	۲۳۷	۲۸۹	۳۳۳	۲۲۳	۱۴۸	۱۰۸

اقدام به آموزش آن براساس اطلاعات بخشی از تصویر می‌گردد. برای این منظور از معیار شباهت برمبنای فاصله اقلیدسی و مقادیر مختلفی از پارامترهای η و شعاع همسایگی h استفاده شده است، به گونه‌ای که پس از اختیار مقادیر نسبتاً بزرگ برای پارامترهای مذکور، مقادیر آن متناسب با تعداد تکرار، کاهش داده شده است. با این روش، همگرایی سریع بدون کاهش کارایی الگوریتم SOM روی می‌دهد (Kohonen et al., 2000).

برای کاهش مشکل نرون مرده در الگوریتم SOM از روش معرفی شده در Menhaj (2002) استفاده شده است. در این روش، تعداد دفعات برنده شدن هر نرون در هر تکرار مشخص می‌شود. به این ترتیب نرون‌های ناموفق در هر تکرار مشخص و بردار وزن آن برابر با میانگین بردار وزن نرون‌های همسایه مقداره‌دهی می‌شود. شکل ۵ نمودار خطای الگوریتم SOM را نسبت به تعداد تکرار نشان می‌دهد. همان‌طور که مشاهده می‌شود الگوریتم SOM با کمتر از تعداد تکرار ۲۰۰۰ همگرا شده است.

۳-۴- برچسب‌گذاری خوشه‌ها براساس الگوریتم MLP
پس از اعمال الگوریتم SOM تصویر به تعدادی خوشه برابر با تعداد نرون‌های شبکه SOM تفکیک می‌شود. الگوریتم طبقه‌بندی نظارت‌نشده SOM به تنهایی قادر به طبقه‌بندی و برچسب‌گذاری نتیجه نهایی به‌طور دقیق نیست. برای این هدف، با استفاده از الگوریتم MLP و داده‌های آموزشی حاصل از نقشه پوششی، برچسب هر نرون مشخص شده است.

ساختار MLP برای این هدف سه لایه طراحی گردید. ورودی MLP برداری است که حاوی بردار وزن نرون‌های شبکه SOM آموزش‌دیده است و نرون خروجی به تعداد کلاس‌ها دارای مقدار خروجی برای نشان دادن برچسب کلاس هر پیکسل از داده‌های آموزشی است. برای آموزش سریع و مناسب الگوریتم MLP از مقادیر بزرگ نرخ آموزش برای تکرارهای اول

برای تصویر IKONOS شش کلاس شامل منطقه شهری، خیابان، درخت، گیاه، خاک و جز اینها برای طبقه‌بندی با الگوریتم پیشنهادی در نظر گرفته شد. جدول ۲ تعداد داده‌های آموزشی و کنترل را برای کلاس‌های در نظر گرفته شده در تصویر ایکونوس نشان می‌دهد. برای این تصویر، از دو سری داده آموزشی برای الگوریتم پیشنهادی استفاده شده است. تعداد داده‌های آموزشی (۱) تقریباً دو برابر تعداد داده‌های آموزشی (۲) در نظر گرفته شده است.


۴-۲- خوشه‌بندی تصویر براساس الگوریتم SOM
تعداد نرون‌ها در الگوریتم SOM باید به مراتب بیشتر از تعداد کلاس‌های خروجی تصویر در نظر گرفته شود. اما با افزایش تعداد نرون‌ها میزان محاسبات لازم برای آموزش شبکه افزایش می‌یابد و همگرایی با سرعتی پایین صورت خواهد گرفت (Zurada, 1992). در پژوهش حاضر ابتدا تعداد نرون الگوریتم SOM (۱۵×۱۵) در نظر گرفته شد و سپس مقادیر مختلف تعداد نرون برای طبقه‌بندی تصویر ارزیابی گردید. همان‌طور که ذکر شد، نتایج الگوریتم‌های خوشه‌بندی به مقادیر اولیه خوشه‌ها حساسیت بالایی دارند. در مقاله حاضر برای کاهش محاسبات و همگرایی سریع الگوریتم SOM از الگوریتم PCA برای تعیین مقادیر اولیه بردار وزن‌ها استفاده شده است.

برای این منظور ابتدا براساس تبدیل PCA دو باند اصلی حاوی بیشترین اطلاعات و کمترین نویز انتخاب شد و سپس برحسب توزیع پیکسل‌های تصویری در این فضا، دامنه حضور غالب داده‌ها تعیین گردید.


با در نظر گرفتن شبکه‌های منظم از نقاط در دامنه منتخب و انجام تبدیل PCA معکوس، بردار وزن اولیه هر یک از نرون‌های شبکه خودسازمان‌ده تعیین می‌شود. لازم به ذکر است در تبدیل PCA معکوس، مقدار سایر باندهای PCA این مراکز صفر در نظر گرفته می‌شود.

پس از انتساب مقادیر اولیه به بردارهای وزن شبکه،

ارائه روشی ترکیبی از شبکه‌های عصبی نظارت‌شده و نظارت‌نشده در طبقه‌بندی تصاویر سنجش از دور



شکل ۵. نمودار خطای الگوریتم SOM در تعداد تکرار مختلف، همان‌طور که مشاهده می‌شود الگوریتم SOM به کار گرفته شده با کمتر از تعداد تکرار ۲۰۰۰ همگرا شده است.



شکل ۶. نمودار خطای MLP در تکرارهای مختلف

MLP با تعداد پانزده نرون در لایه میانی و تعداد تکرار کمتر از ۴۰۰ همگرا شده است.

۴-۴- مقایسه و ارزیابی نتایج

جدول ۳ ماتریس خطای طبقه‌بندی حاصل از روش SOM-MLP را برای تصویر لندست نشان می‌دهد. در این جدول، کلاس نهم نتیجه حاصل از پیکسل‌هایی است که به هیچ کلاسی تعلق ندارند. مطابق این جدول بیشتر کلاس‌ها با دقتی بالا طبقه‌بندی شده‌اند. تنها

استفاده شد و در خلال یادگیری شبکه با پیشرفت فرآیند یادگیری مقدار ۱۱ به صورت یکنواخت تا مقدار ۰/۰۰۳ کاهش یافت. عامل دیگری که بر توانایی شبکه تأثیر می‌گذارد، تعداد تکرار و یا زمان توقف مرحله آموزش است.

در پژوهش حاضر، آموزش شبکه MLP زمانی متوقف می‌شود که مقدار خطا برابر ۰/۰۰۳ یا تعداد تکرار ۴۵۰ باشد. شکل ۶ نمودار خطای MLP را در تکرارهای مختلف نشان می‌دهد. مشاهده می‌شود که الگوریتم

عطاءالله حدادی و همکاران

جدول ۳. ماتریس خطای طبقه‌بندی، دقت تولیدکننده، دقت کاربر، دقت کلی و پارامتر کاپای حاصل از الگوریتم SOM-MLP برای تصویر لندست

Ind_class	target									Prod. Acc.	User Acc.
	1	2	3	4	5	6	7	8	9		
1	96	0	0	0	0	0	0	0	0	96.0	100
2	0	76	0	1	0	11	5	0	0	76.0	81.7
3	0	0	90	1	0	0	0	20	0	90.0	81.1
4	0	1	1	86	0	14	0	1	0	86.0	83.5
5	0	0	0	0	100	0	0	0	0	100	100
6	0	11	0	11	0	73	0	0	0	73.0	76.8
7	0	7	0	1	0	0	92	0	0	92.0	92.0
8	0	0	9	0	0	0	0	79	0	79.0	89.8
9	4	5	0	0	0	2	3	0	0		
Overall accuracy : 86.5											
kappa coefficient : 0.85											

جدول ۴. ماتریس خطا برای تصویر IKONOS به ازای داده‌های آموزشی (۱) در جدول ۲

	منطقه شهری	خیابان	درخت	گیاه	خاک	غیره	User Acc.	Prod. Acc.
منطقه شهری	179	0	0	0	1	0	99.40	88.20
خیابان	1	166	0	0	0	2	98.20	85.10
درخت	0	1	178	4	0	1	96.70	91.80
گیاه	0	0	13	165	0	0	92.70	93.80
خاک	15	0	0	0	161	0	91.50	91.00
غیره	7	28	3	7	15	156	72.20	98.10
نامشخص	1	0	0	0	0	0		
Overall accuracy :			91.00					
kappa coefficient :			89.25					

جدول ۵. ماتریس خطا برای تصویر IKONOS به ازای داده‌های آموزشی (۲) در جدول ۲

	منطقه شهری	خیابان	درخت	گیاه	خاک	غیره	User Acc.	Prod. Acc.
منطقه شهری	124	0	0	0	0	0	100.00	61.10
خیابان	1	154	0	0	0	2	98.20	79.00
درخت	0	1	185	15	0	1	96.70	95.40
گیاه	0	0	5	153	0	0	92.70	86.90
خاک	10	0	0	0	160	0	91.50	90/40
غیره	6	11	4	8	17	156	72.20	98.10
نامشخص	62	29	0	0	0	0		
Overall accuracy :			84.40					
kappa coefficient :			81.63					

۴-۴-۱- مقادیر متفاوت داده‌های آموزشی در

الگوریتم SOM

به منظور بررسی تأثیر تعداد داده‌های آموزشی بر عملکرد الگوریتم پیشنهادی، تعداد مختلفی از داده‌های آموزشی شامل ۳، ۵، ۱۰، ۱۵، ۲۰ و ۲۵ درصد پیکسل‌ها به منظور طبقه‌بندی تصویر IKONOS مورد استفاده قرار گرفت. برای این منظور از شبکه SOM با ۲۲۵ نرون و شبکه MLP با ۱۵ نرون در لایه میانی استفاده شده است. شکل ۷ دقت کلی و ضریب کاپا را به ازای مقادیر متفاوت داده‌های آموزشی نشان می‌دهد. براساس شکل ۷، استفاده از ۲۰ درصد پیکسل‌ها به‌عنوان داده‌های آموزشی کفایت می‌کند.

۴-۴-۲- تعداد مختلف نرون در الگوریتم SOM

در تعیین تعداد نرون‌ها در الگوریتم SOM قاعده خاصی وجود ندارد، اما تعداد نرون‌ها باید بیشتر از تعداد کلاس‌ها در نظر گرفته شود. در پژوهش حاضر، مقادیر متفاوتی برای تعداد نرون‌ها در الگوریتم SOM در نظر گرفته شد. شکل ۸ نتایج دقت کلی و ضریب کاپای حاصل از بررسی استفاده از مقادیر مختلف نرون‌ها را در الگوریتم SOM نشان می‌دهد.

شکل ۸ مؤید این مطلب است که تعداد کم نرون‌ها دقت طبقه‌بندی را تحت تأثیر قرار می‌دهد. از طرفی استفاده از تعداد نرون خیلی زیاد، تنها زمان محاسبات را بالا می‌برد و نتایج را چندان بهبود نمی‌بخشد. مطابق این نمودار، تعداد نرون مابین 10×10 تا 15×15 برای الگوریتم پیشنهادی بهینه به‌نظر می‌رسد.

۴-۴-۳- تعداد مختلف نرون در الگوریتم MLP

به منظور بررسی تأثیر تعداد نرون‌های شبکه MLP بر عملکرد الگوریتم پیشنهادی، تعداد مختلفی از نرون‌ها مورد بررسی قرار گرفت. شکل ۹ نتایج دقت کلی و ضریب کاپای حاصل از بررسی استفاده از مقادیر مختلف نرون‌ها را در الگوریتم MLP نشان می‌دهد.

کلاس ششم (باتلاق - درخت) به دلیل وجود تشابه طیفی بالا با کلاس دوم (جنگل‌های پرتراکم مختلط) و کلاس چهارم (جنگل‌های پرتراکم میوه مخروطی) دارای دقت پایین‌تری است. ضریب کاپای حاصل نیز 0.85 است که برای فرایند طبقه‌بندی دارای دقت مناسبی است. جدول ۴ و جدول ۵ نیز ماتریس خطای طبقه‌بندی حاصل از روش SOM-MLP را برای تصویر ایکونوس به ازای حالات مختلف داده‌های آموزشی در جدول ۲ نشان می‌دهد.


مطابق این نتایج، الگوریتم پیشنهادی مناسب برای طبقه‌بندی تصویر با رزولوشن متوسط و تصویر با رزولوشن بالاست و برای داده‌های آموزشی اندک مناسب است. در هر دو حالت، داده‌های آموزشی برای تصویر ایکونوس با دقت بالا و تقریباً نزدیک به یکدیگر به‌دست آمده است.

به منظور بررسی پایداری الگوریتم پیشنهادی تعداد داده‌های آموزشی که از تصویر برای الگوریتم SOM در نظر گرفته می‌شود، تعداد مختلف نرون‌های الگوریتم SOM و تعداد مختلف نرون‌ها در لایه میانی الگوریتم MLP مورد بررسی قرار گرفت، که نتایج آن به ترتیب در بخش‌های ۴-۴-۱، ۴-۴-۲ و ۴-۴-۳ ارائه شده است.

همچنین برای ارزیابی الگوریتم پیشنهادی، هر قسمت از الگوریتم با الگوریتم‌های دیگر جایگزین شد و نتایج به‌دست آمده با الگوریتم پیشنهادی مقایسه گردید. در ابتدا به جای الگوریتم SOM از الگوریتم‌های نظارت‌نشده K-Means و FCM و به جای الگوریتم MLP برای تعیین برجسب نرون‌های الگوریتم SOM از الگوریتم KNN استفاده گردید. همچنین از الگوریتم‌های بیشترین شباهت، کمترین فاصله و الگوریتم پس‌انتشار خطا نیز برای طبقه‌بندی تصویر استفاده شد و نتایج این الگوریتم‌ها نیز با الگوریتم پیشنهادی مقایسه گردید. نتایج این بخش تنها بر روی تصویر لندست بررسی شد. نتایج حاصل به ترتیب در بخش‌های ۴-۴-۴ و ۴-۴-۵ ارائه شده است.



شکل ۷. دقت کلی و ضریب کاپا در حالت استفاده از درصد داده های آموزشی که برای آموزش الگوریتم SOM به کار برده می شود.



شکل ۸. نتایج طبقه بندی به ازای تعداد نرون های مختلف در توپولوژی SOM در الگوریتم SOM-MLP



شکل ۹. نتایج طبقه بندی به ازای تعداد نرون های مختلف در لایه میانی الگوریتم MLP

۴-۴-۴- بررسی تأثیر اجزای محاسباتی روش

پیشنهادی

به‌منظور بررسی تأثیر روش SOM بر عملکرد الگوریتم پیشنهادی، روش‌های طبقه‌بندی نظارت‌نشده FCM و K-means جایگزین SOM گردید و به‌منظور بررسی تأثیر روش MLP بر عملکرد الگوریتم پیشنهادی، روش طبقه‌بندی نظارت‌شده KNN جایگزین MLP گردید. نتایج این بخش بر روی تصویر لندست آزمون شد. در الگوریتم‌های FCM و K-Means (Nascimento et al., 2000) تعداد ۵۰ خوشه در نظر گرفته شد و از توزیع یکنواخت برای تعیین خوشه‌های اولیه در این دو روش استفاده گردید. معیار شباهت فاصله اقلیدسی و شرط توقف نیز تعداد تکرار ۱۵۰۰ برای هر دو الگوریتم در نظر گرفته شد. نتایج حاصل در جدول ۶ نشان داده شده است.

همان‌طور که مشاهده می‌شود در الگوریتم SOM-MLP و SOM-KNN مقدار کاپا از ۷۶ درصد به ۸۶/۵ درصد و مقدار دقت کلی از ۷۹ درصد به ۸۶/۵ درصد افزایش یافته است. همچنین نتایج SOM-KNN از دو الگوریتم FCM-MLP و K-Means-MLP بیشتر است و این اختلاف برای الگوریتم SOM-MLP بیشتر است.

۴-۴-۵- جایگزین کلی روش SOM-MLP با سه

الگوریتم بیشترین شباهت، الگوریتم کمترین فاصله و الگوریتم MLP

همچنین الگوریتم پیشنهادی با دیگر الگوریتم‌های

طبقه‌بندی نظارت‌شده شامل الگوریتم بیشترین شباهت^۱ (MLC)، الگوریتم کمترین فاصله^۲ (MD) و الگوریتم MLP غیر ترکیبی مقایسه شد. برای الگوریتم MLP غیر ترکیبی نیز ساختاری سه‌لایه طراحی شد، که تعداد نرون لایه میانی را به صورت سعی و خطا مشخص ساخت. در این حالت بهترین نتیجه طبقه‌بندی با استفاده از پنج نرون در لایه میانی به‌دست آمد. دیگر پارامترهای الگوریتم MLP مطابق با آنچه که در بخش ۴-۳ بیان شد در نظر گرفته شد و عمل طبقه‌بندی انجام گرفت. نتایج حاصل در جدول ۶ ارائه شده است.

نتایج SOM-MLP در مقایسه با الگوریتم MD بهتر و تقریباً برابر با MLC است. در این میان دقت الگوریتم MLP کمترین دقت طبقه‌بندی را داراست، که علت آن نیز استفاده از تعداد کم پیکسل‌های آموزشی است. الگوریتم بیشترین شباهت دارای دقت بالایی است که دلیل آن، سازگاری داده‌ها با تابع توزیع نرمال است. برای ارزیابی بهتر الگوریتم پیشنهادی و ارائه برتری روش پیشنهادی، از دو مجموعه داده آموزشی که در جدول ۲ ارائه شده است برای طبقه‌بندی تصویر ایکونوس با الگوریتم بیشترین شباهت استفاده گردید و نتایج با الگوریتم پیشنهادی مقایسه شد. نتایج این مقایسه در جدول ۷ برای الگوریتم پیشنهادی و الگوریتم بیشترین شباهت نشان داده شده است.

جدول ۶. دقت کلی و ضریب کاپا برای الگوریتم پیشنهادی و الگوریتم‌های دیگر برای تصویر لندست

الگوریتم	الگوریتم SOM-MLP	الگوریتم SOM-KNN	الگوریتم K-means-MLP	الگوریتم FCM-MLP	الگوریتم MLP	الگوریتم بیشترین شباهت	الگوریتم کمترین فاصله
ضریب کاپا (%)	۸۴/۶	۷۶/۰	۶۹/۰	۷۱/۸	۶۸/۹	۸۵/۰	۸۱/۱
دقت کلی (%)	۸۶/۵	۷۹/۰	۷۲/۹	۷۵/۴	۷۲/۶	۸۷/۱	۸۳/۵

1. Maximum Likelihood Classifier
2. Minimum Distance

جدول ۷. دقت کلی و ضریب کاپا برای الگوریتم پیشنهادی و الگوریتم بیشترین شباهت برای تصویر ایکونوس به ازای دو مجموعه داده آموزشی

الگوریتم	داده‌های آموزشی (۱)		داده‌های آموزشی (۲)	
	دقت کلی (%)	ضریب کاپا (%)	دقت کلی (%)	ضریب کاپا (%)
SOM-MLP الگوریتم	۹۱/۰۰	۸۹/۲۵	۸۴/۴۰	۸۱/۶۳
الگوریتم بیشترین شباهت	۹۰/۲۰	۸۸/۲۷	۷۶/۳۰	۷۱/۳۱

مطابق این نتایج در هر دو حالت داده‌های آموزشی کم و داده‌های آموزشی زیاد، الگوریتم پیشنهادی دارای دقتی تقریباً همسان است، اما الگوریتم بیشترین شباهت تنها در حالت استفاده از داده‌های آموزشی زیاد دارای دقتی بالاست. لذا الگوریتم پیشنهادی برخلاف الگوریتم بیشترین شباهت مناسب برای تصاویری که دارای داده‌های آموزشی زیادی نیستند مناسب می‌نماید. تنها مشکل الگوریتم پیشنهادی در مقایسه با الگوریتم بیشترین شباهت، زمان محاسبات بالاست.

۵- نتیجه‌گیری و پیشنهادها

در مقاله حاضر ترکیبی از الگوریتم SOM و MLP برای طبقه‌بندی تصاویر سنجش از دور پیشنهاد شد. در الگوریتم پیشنهادی ابتدا با استفاده از الگوریتم SOM تصویر خوشه‌بندی گردید و سپس با استفاده از الگوریتم MLP، برچسب نرون‌های الگوریتم SOM تعیین شد. در این پژوهش به منظور افزایش سرعت همگرایی الگوریتم در تعیین مقادیر اولیه بردار وزن نرون‌های SOM ضمن استفاده از الگوریتم PCA تنها بخشی از تصویر اولیه به منظور آموزش الگوریتم SOM مورد استفاده قرار گرفت. به منظور بررسی پایداری الگوریتم پیشنهادی، تأثیر تغییرات داده‌های آموزشی و تعداد نرون‌های الگوریتم SOM و همچنین تعداد نرون‌های لایه میانی الگوریتم MLP در نتیجه نهایی مورد بررسی قرار گرفت. نتایج حاصل از این قسمت مؤید این مطلب است که تعداد کم نرون‌ها در الگوریتم SOM دقت طبقه‌بندی را تحت تأثیر قرار می‌دهد و در

صورت استفاده از تعداد نرون خیلی زیاد تنها زمان محاسبات بالا می‌رود و نتایج چندان بهبود نمی‌یابد. تعداد نرون‌ها در الگوریتم MLP نیز تأثیر چندانی روی نتیجه نهایی ندارد، همچنین تنها ۲۰ درصد از تصویر ایکونوس برای آموزش الگوریتم SOM مناسب به نظر می‌رسد. علاوه بر این، برای مقایسه الگوریتم پیشنهادی با دیگر الگوریتم‌ها و رسیدن به ترکیبی مناسب، هر قسمت از الگوریتم پیشنهادی با الگوریتم‌های دیگر جایگزین شد و نتایج به دست آمده با الگوریتم پیشنهادی مقایسه گردید. در ابتدا به جای الگوریتم SOM از الگوریتم‌های نظارت‌نشده K-Means و FCM و به جای الگوریتم MLP برای تعیین برچسب نرون‌های الگوریتم SOM از الگوریتم KNN استفاده گردید. علاوه بر این، از الگوریتم‌های بیشترین شباهت، کمترین فاصله و الگوریتم MLP نیز برای طبقه‌بندی تصویر استفاده شد و نتایج این الگوریتم‌ها نیز با الگوریتم پیشنهادی مقایسه گردید. نتایج حاصل از این مقایسه نشان داد که الگوریتم پیشنهادی و الگوریتم بیشترین شباهت، دارای دقت بالایی هستند. برای مقایسه بهتر الگوریتم پیشنهادی و الگوریتم بیشترین شباهت، تأثیر داده‌های آموزشی بر روی این دو الگوریتم مورد ارزیابی قرار گرفت که مطابق نتایج ترکیب الگوریتم‌های SOM و MLP به دلیل دارا بودن ویژگی‌های هر دو الگوریتم، حساسیت کمتری به داده‌های آموزشی دارد. تنها اشکال الگوریتم پیشنهادی در مقایسه با الگوریتم‌های دیگر، زمان محاسبات بالاست و پیشنهاد می‌شود که به منظور افزایش کارایی، تحقیقاتی برای کاهش زمان محاسبات انجام شود.

۷- منابع

- Atkinson P.M., Tatnall, A.R.L., 1997, **Neural Networks in Remote Sensing**, Int. J. Remote Sensing, Vol. 18, No. 4, pp. 699-709.
- Attik M., Bougrain L., Alexandre F., 2005, **Self-organizing Map Initialization**, Lecture Notes in Computer Science, Springer Berlin / Heidelberg, Volume 3696/2005, pp.1611-3349.
- Bogdanov A.V., 2008, **Neuroinspired Architecture for Robust Classifier Fusion of Multisensor Imagery**, IEEE Trans. on Geoscience and Remote Sensing, Vol. 46, No. 5, pp. 1467-1487.
- Chini M., Pacifici F., Emery W.J., Pierdicca N., Del Frate F., 2008, **Comparing Statistical and Neural Network Methods Applied to Very High Resolution Satellite Images Showing Changes in Man-Made Structures at Rocky Flats**, IEEE Trans, on Geoscience and Remote Sensing, Vol. 46, No. 6, pp. 1812-1811.
- Del Frate F., Pacifici F., Schiavon G, Solimini C., 2007, **Use of Neural Networks for Automatic Classification from High-Resolution Images**, IEEE Trans. on Geoscience and Remote Sensing, Vol. 45, No. 4, pp. 800-809.
- Del Frate F., Pacifici F., Solimini D., 2008, **Monitoring Urban Land Cover in Rome, Italy, and Its Changes by Single-Polarization Multitemporal SAR Images**, IEEE J. of Selected Topics in Applied Earth Observations And Remote Sensing, Vol. 1, No. 2, pp. 87-97.
- Ghosh S., Patra S., Ghosh A., 2009, **An Unsupervised Context-sensitive Change Detection Technique based on Modified Self-organizing Feature Map Neural Network**, International Journal of Approximate Reasoning, Vol. 50, pp. 37-50.
- Goncalves M.L., Andrade Netto M.L., Zullo Junior J., 1998, **A Neural Architecture For The Classification of Remote Sensing Imagery with Advanced Learning Algorithms**, IEEE Trans. Geosc. Remote Sens., pp. 577-586.
- Hara Y., Atkins, R.G. Yueh, S.H. 1994, **Application of Neural Networks to Radar Image Classification**, IEEE Trans. Geosc. Remote Sens., Vol. 32, No. 1, pp. 100-109.
- Haykin S., 1999, **Neural Network a Comprehensive Foundation**, 2th edition, Pearson prentice hall.
- Hosokawa M., Hoshi T., 2002, **Polarimetric SAR Data Classification Method Using the Self-Organizing Map**, Geosc. and Remote Sens. Symposium, 2002. IGARSS '02. 2002 IEEE International Vol. 6, pp. 3468-3470.
- Hosokawa M., Ito Y., Hoshi T., 1999, **A remote Sensing Data Classification Method Using Self-organizing Map**, Geosc. and Remote Sens. Symposium. IGARSS apos; 99 Proceedings. IEEE 1999 International, Vol. 3, pp. 1606-1608.
- Kohonen T., 1995, **Self-Organizing Maps**, Springer, Berlin, Heidelberg, New-York: Springer, Berlin.

- Kohonen T., Kaski S., Lagus K., Salojarvi J., Honkela J., Paatero V., Saarela A., 2000, **Self Organization of a Massive Document Collection**, IEEE Trans. ON NEURAL NETWORKS, Vol. 11, No. 3, pp. 574-585.
- Lee S., Lathrop R.G., 2006, **Subpixel Analysis of Landsat ETM+ Using Self-Organizing Map (SOM) Neural Networks for Urban Land Cover Characterization**, IEEE Trans. on Geoscience and Remote Sensing, Vol. 44, No. 6, pp. 1642-1654.
- Menhaj M.B., 2002, **Introduction to Artificial Neural Network**, the publication center of AmirKabir University.
- Martorella M., Giusti E., Capria A., Berizzi F., Bates B., 2009, **Automatic Target Recognition by Means of Polarimetric ISAR Images and Neural Networks**, IEEE Trans. on Geoscience and Remote Sensing, Vol. 47, No. 11, pp. 3786-3794.
- Mokhtarzade M., Valadan Zoej M.J., 2007, **Road Detection from High-resolution Satellite Images Using Artificial Neural Networks**, International Journal of Applied Earth Observation and Geoinformation, Vol. 9, pp. 32-40.
- Nascimento S., Mirkin B., Mourca-Pires F., 2000, **A Fuzzy Clustering Model of Data and Fuzzy C-Means**, the 19th International Meeting of the North American Fuzzy Information Processing Society.
- Pacifici F., Del Frate F., Solimini C., Emery W. J., 2007, **An Innovative Neural-Net Method to Detect Temporal Changes in High-Resolution Optical Satellite Imagery**, IEEE Trans. on Geoscience and Remote Sensing, Vol. 45, No. 9, pp. 2940-2952.
- Putignano C., Schiavon G., Solimini D., Trisasonko B., 2006, **Self-organizing Neural Networks for Unsupervised Classification of Polarimetric SAR Data on Complex Landscapes**, Geosc. Remote Sens. Symposium, 2006. IGARSS 2006. IEEE International Conference, pp 504-506.
- Richards J. A., Jia X., 2006, **Remote Sensing Digital Image Analysis an Introduction**, 4th Edition, Chapter 1, Springer, Germany, Berlin, Heidelberg.
- Simard M., Saatchi S., Grandi G.D., 2000, **The use of Decision Tree and Multiscale Texture for Classification of JERS-SAR Data Over Tropical Forest**, IEEE Trans. Geosc. Remote Sens., Vol 38, NO. 5. Part 1, pp. 2310-2321.
- Su M.C., Chang H.T., 2000, **Fast Self-Organizing Feature Map Algorithm**, IEEE TRANS. ON NEURAL NETWORKS, Vol. 11, No. 3, pp. 721-733.
- Villmann T., Merenyi E., Hammer B., 2003, **Neural Maps in Remote Sensing Image Analysis**, Neural Networks, Vol.16, pp. 389-403.
- Wilkinson G.G., Kontoes C., Murray C.N., 1992, **Recognition and Inventory of Oceanic Clouds From Satellite Data Using an Artificial Neural Network Technique**, Proceedings of the International Symposium on Dimethylsulphide, Oceans, Atmosphere and Climate, Belgirate, Italy, Commission of the European Communities.
- Zurada J., 1992, **Introduction to Artificial Neural Network**, West published company.