نشریه پژوهش‌های کاربردی دورکاوی و اطلاعات مکانی

بارزسازی تغییرات اهداف با استفاده ازشبکه عصبی نگاشت خودسازمانده(SOM) در تصاویر ماهواره‌های با قدرت تفکیک مکانی بالا

۵
سال اول
بهار ۱۴۰۵

حمید قنبرزاده ۱

مقاله

تاریخ دریافت:
۱۴۰۴/۰۶/۰۷
تاریخ پذیرش:
۱۴۰۴/۱۰/۱۴
صص: ۹۵-۷۹

چکیده

آشکارسازی تغییرات پوشش زمین مربوط می‌شود به تجزیه و تحلیل سنجش‌ازدور تصاویر چندطیفی که در دو زمان متفاوت از یک منطقه جغرافیایی مشابه کسب شده است. امروزه شبکه‌های عصبی مصنوعی نیز به عنوان یک ابزار مهم برای پرداختن به بسیاری از مشکلات مربوط به پردازش تصاویر سنجش‌ازدور مورد استفاده قرار می‌گیرد که شامل هر دو روش طبقه‌بندی نظارت شده و همچنین طبقه‌بندی نظارت نشده می‌باشد. چند مزایای استفاده از شبکه‌های عصبی مصنوعی برای طبقه‌بندی تصاویر ماهواره‌ای به شرح زیر است: شبکه‌های عصبی محور اطلاعات و خود انطباقی هستند، از آنجایی که آنها خود را می‌توانند به داده‌ها، بدون هیچگونه خصوصیات عملکردی صریح و روشن، از مدل فیزیکی یا اصولی سازگار کنند. شبکه‌های عصبی می‌تواند تخمین‌هایی عملکردی یا تابعی جهانی ارائه دهد. طبقه‌بندی‌های عصبی نیاز به فرضیه‌های اولیه در توابع داده‌ها ندارد و آنها می‌توانند داده‌های ورودی غیر خطی و ناپیوسته را یاد بگیرند. در این تحقیق ما روش طبقه‌بندی نظارت نشده را برای آشکارسازی اهداف (با توجه به دردسترس نبودن آنها از نظر امنیتی) در تصاویر ماهواره‌ای چند زمانه با قدرت تفکیک مکانی بالا و چند طیفی را مورد ارزیابی قرار دادیم که نتیجه آن برای طبقه‌بندی تصاویر ماهواره WorldView2 در شبکه عصبی نگاشت خودسازمانده (SOM) با دقت کلی به میزان ۷٤.۰۹ درصد و مقدار ۰.٦۷ برای ضریب کاپا بدست آمد.

کلیدواژه‌ها: بارزسازی تغییرات، شبکه عصبی، نگاشت خودسازمانده SOM، سنجش از دور، طبقه‌بندی نظارت نشده

۱ کارشناس ارشد، رشته سنجش‌ازدور و سیستم اطلاعات جغرافیایی، hamid.kartography@gmail.com

مقدمه

یکی از مهمترین روش‌های استخراج اطلاعات اهداف دشمن و همچنین بروزرسانی و پایش تغییرات تجهیزات لجستیکی، سازه‌های اسکان، ساختمان‌های تخصصی و ... با استفاده از تصاویر سنجش از دور، طبقه‌بندی است که به ارگان‌های نظامی امکان تولید انواع اطلاعات مختلفی از قبیل نقشه‌های پوششی، نقشه‌های کاربری و نقشه تغییرات را می‌دهد. الگوریتم‌های طبقه‌بندی در حالت کلی به دو روش نظارت شده[1] و نظارت نشده[2] تقسیم‌بندی می‌شوند. در روش نظارت نشده، مرحله آموزش وجود ندارد و الگوریتم بر اساس مشخصات آماری داده‌های سنجش از دور مورد نظر، عمل دسته‌بندی را انجام می‌دهد. روش‌های طبقه‌بندی نظارت نشده معمولاً به نام روش‌های خوشه‌بندی[3] مطرح می‌گردند. در این حالت، تصویر به تعدادی کلاس با برچسب نامشخص طبقه‌بندی می‌شود؛ لذا کاربر پس از عمل طبقه‌بندی باید برچسب کلاس‌ها را بر اساس سایر منابع اطلاعاتی مشخص کند. دقت الگوریتم‌های طبقه‌بندی نظارت شده به مراتب بالاتر از الگوریتم‌های نظارت نشده است**[1]** در نوشتار حاضر به علت عدم دسترسی به اهداف دفاعی، نظامی با استفاده از الگوریتم نگاشت خودسازمانده (SOM)[4] که در زمره‌ی شبکه‌های عصبی نظارت نشده قرار می‌گیرد جهت طبقه‌بندی تصاویر ماهواره ***Worldview2*** استفاده شده است.

ویکتور نیگو[5] و همکاران با استفاده از الگوریتم‌های شبکه‌های عصبی و روش‌های آماری و طبقه‌بندی نظارت شده و بدون نظارت و تصویر ماهواره Landsat7 ETM+ مربوط به منطقه مارکاید[6] در کشور سوئد در سالهای ۲۰۰۲ تا ۲۰۰۶ که تعداد کل پیکسل‌های منطقه ۴۰۰×۴۰۰ پیکسل بوده است که فقط تعداد ۲۰۰۰ پیکسل آن برای آموزش شبکه و بقیه ۱۵۸۰۰۰ پیکسل برای تست استفاده شده است. بهترین نتیجه تجربی با استفاده از روش‌های نظارت شده شبکه عصبی پرسپترون چند لایه (MLP) با دقت ۸۸.۲۴٪ می‌باشد در حالی که در میان روش‌های بدون نظارت

1 - Supervise
2 - Unsupervise
3 - Clustering
4 - Self Organizing Map
5 - Victor-Emil Neagoe
6 - Markaryd

با استفاده از تمام پیکسل‌ها بهترین نتیجه مربوط به روش اختلاف مطلق پیکسل[1] (ADIP) با دقت ۲۲٪.۷۸ بدست آمد. نتایج تجربی در این تحقیق ثابت می‌کند که استفاده از روش‌های تشخیص تغییر شبکه‌های عصبی بهتر از آماری و فازی است[2].

در سطح ایران، مطالعات محدودی در زمینه استفاده از الگوریتم‌های نظارت شده و نظارت نشده در شبکه‌های عصبی مصنوعی در طبقه‌بندی تصاویر ماهواره‌ای صورت گرفته است. ولی بررسی‌های نگارنده حاکی از آن است که مطالعه در زمینه بارزسازی تغییرات با استفاده از شبکه‌های عصبی در کشور ما در آغاز راه است. در پژوهش حاضر ضمن ارائه طبقه‌بندی تصاویر منطقه مورد مطالعه با روش طبقه بندی نظارت نشده شبکه عصبی، به ارزیابی دقت و ارائه نتایج خروجی‌ها پرداخته شده است.

مواد و روش‌ها

شبکه عصبی مصنوعی از اجزای ساده محاسباتی به نام نرون‌ها تشکیل شده که در واقع ساختار آنها از ساختار نرون‌های عصبی بیولوژیکی انسان شبیه‌سازی شده است. مهمترین وظیفه‌ی 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 به منظور محاسبه پاسخ نرون به داده‌های ورودی و نهایتاً ارسال پاسخ محاسبه شده به سایر نرون‌های شبکه به عنوان ورودی جدید است. **[۳]** دو مرحله مهم در عملکرد شبکه عصبی عبارت‌اند از؛ آموزش شبکه و بازخوانی شبکه. در نوشتار حاضر از الگوریتم شبکه نگاشت خودسازمانده استفاده شده است.

شبکه‌های عصبی نگاشت خودسازمانده[2]

همانطور که در شکل شماره ۱ مشاهده می‌نمایید الگوریتم شبکه‌های نگاشت 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. **[۵,۴]** لایه خروجی *SOM* به صورت مجموعه‌ای

1 - Absolute Differences of Pixel
2 - SOM

از m نرون اســت که این نرون‌ها در نوعی توپولوژی ویژه در کنار یکدیگر قرار می‌گیرند. به هر نرون i مختصات (x_i, y_i) در فضای توپولوژی و بردار وزنی $w_i = (w_i^1, w_i^2, \dots, w_i^n)^T \in R^n$ اختصــاص داده می‌شــود، که ارتباط بین نرون‌های لایه ورودی و نرون‌های لایه خروجی را برقرار می‌سازد و در آن، n معرف ابعاد داده‌های ورودی است.

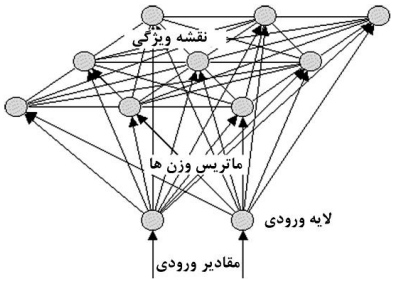

شکل ۱. شبکه نگاشت خودسازمانده

الگوریتم SOM در فراینـدی دو مرحلـه‌ای آموزش می‌بینـد. در مرحلـه اول، نرون برنـده در الگوریتم SOM بر مبنای معیار شباهت که معمولاً فاصله اقلیدسی یا منهتن است انتخاب می‌گردد. در مرحله دوم، به روزرسانی بردار وزن نرون‌ها در مرحله آموزش که عملی تکراری است صورت می‌پذیرد. رابطه (۱) نحوه به روزرسانی وزن‌ها را نشان می‌دهد؛

$$\underline{W_i}(t+1) = \underline{W_i}(t) + \eta(t) h_{si}(t)[\underline{X} - \underline{W_i}(t)] \quad (۱)$$

در این رابطـه پـارامتر h_{si} تـابع همســـایگی را در اطراف نرون برنـده (s)، $\eta \in [0,1]$ نرخ بروزرســانی بردار وزن‌ها، $\underline{W}$ بردار وزن، t نشــان دهنده تکرار و $i \in [1, m]$ شــماره نرون مورد بررســی اســت. تابع h_{si} می‌تواند مســتطیلی[1] با مقداری ثابت برای همســایه‌های نرون برنده در یک شعاع همسایگی و مقدار صفر برای دیگر نرون‌ها و یا به صورت تابع گوسین در نظر گرفته شود. پارامترهای مذکور معمولاً بر حســب ماهیت داده‌های ورودی و به صــورت ســعی و خطا تعیین

1 - Bubble

می‌شـــوند[۶]. همچنین واحد مرده[1] نیز که به دلیل شـــرکت نکردن یک نرون در رقابت به وجود می‌آید، نتایج الگوریتم *SOM* را تحت تأثیر قرار می‌دهد[7].

منطقه مورد مطالعه

منطقه مورد مطالعه فرودگاه الأُبید[2] است. این فرودگاه در محدوده ″۳۵ ′۰۹ °۱۳ عرض شمالی (***N***) و ″۴۴ ′۱۳ °۳۰ عرض شرقی (***E***) و در جنوب شرق شهر الأُبید در کشور سودان واقع شده است. در این منطقه با توجه به بررسی تصاویر موجود تغییرات کاربری قابل ملاحظه‌ای اتفاق افتاده است. تصاویر مورد استفاده در این تحقیق تصاویر ماهواره worldview2 در دو تاریخ مختلف و در بازه زمانی یک ساله می‌باشند. تصویر اول در تاریخ ۲۲ اکتبر ۲۰۱۰ اخذ شده است و همچنین تصویر دوم نیز در تاریخ ۱۳ نوامبر ۲۰۱۱ به دست آمده است. این تصاویر دارای ۴ باند با اندازه پیکسل ۲ متر و ۱ باند پانکروماتیک با اندازه پیکسل ۰/۶ متر می‌باشند. این تصاویر زمین مرجع شده و در سیستم تصویر UTM در زون ۳۶ شمالی قرار دارند. بیضوی مبنای آن WGS84 می‌باشد.

تصاویر ماهواره‌ای مهمترین داده‌های مورد استفاده می‌باشد که در شکل ۲ و ۳ نشان داده شده است.



شکل ۳. تصویر منطقه مورد مطالعه به تاریخ ۱۳ نوامبر ۲۰۱۱ ـ ترکیب رنگی ***RGB*** باندهای (۱،۲،۳) ـ تصویر ***Time*** 2



شکل ۲. تصویر منطقه مورد مطالعه به تاریخ ۲۲ اکتبر ۲۰۱۰ ـ ترکیب رنگی **RGB** *باندهای (۱،۲،۳) ـ تصویر* **Time1**

مشخصات ماهواره WorldView2

1 - Dead unit
2 - El-Obeid AirPort

این ماهوارهٔ تجاری که توسط شرکت دیجیتال گلوب[1] طراحی و ساخته شده است، از پایگاه هوایی وندنبرگ[2] کالیفرنیا در تاریخ ۸ اکتبر ۲۰۰۹ در مدار قرار گرفت. پس از ماهواره‌های کوئیک برد، وردویو-۱ سومین ماهواره شرکت دیجیتال گلوب می‌باشد. در شکل ۳ ـــ ۱۱ آن را مشاهده می‌کنید.

تصاویر اخذ شده توسط ماهواره وردویو-۲[3] در باند پانکروماتیک دارای اندازه پیکسل ۰/۴۶ متر است و دارای ۸ باند چند طیفی با اندازه پیکسل ۱/۸۴ متر می‌باشند و به دلیل مقررات آمریکا، تصاویر با قدرت تفکیک ۰/۵۱ متر و ۲ متر برای باندهای پانکروماتیک و چند طیفی به کاربران ارائه می‌شود. این تصاویر، علاوه بر چهار باند استاندارد (Blue-Green-Red-NIR)، دارای چهار باند جدید نیز می‌باشند. باند جدید Coastal این ماهواره در طول موجی کوچکتر از باند Blue تصویربرداری می‌کند و به دلیل نفوذپذیری بهتر این بخش از امواج الکترومغناطیس در آب، این باند به منظور بررسی گیاهان آبزی و مطالعات ژرف‌سنجی طراحی شده است. [۹]

جدول1 - مشخصات باندهای طیفی ماهواره WorldView-2

باند	طول موج پایین (nm)	طول موج بالا (nm)	پهنای باند (km)	مرکز باند (nm)
MS(Coastal)	٤٠٠	٤٥٠	٥٠	٤٢٥
MS(Blue)	٤٥٠	٥١٠	٦٠	٤٨٠
MS(Green)	٥١٠	٥٨٠	٧٠	٥٤٥
MS(Yellow edge)	٥٨٥	٦٢٥	٤٠	٦٠٥
MS(Red)	٧٠٥	٦٩٠	٢٥	٦٧٢.٥
MS(Red Edge)	٧٠٥	٧٤٥	٤٠	٧٢٥
MS(NIR1)	٧٧٠	٨٥٠	٨٠	٨٥٠
MS(NIR2)	٨٦٠	١٠٤٠	١٨٠	٩٥٠
PAN	٤٠٠	٨٠٠	٤٠٠	٦٢٥

1 - DigitalGlobe
2 - Vandenberg
3 - WorldView-2

این ماهوارهٔ خورشـید آهنگ که در ارتفاع ۷۷۰ کیلومتری زمین قرار دارد متوسـط زمان بازبینی آن ۱.۱ روز اسـت و می‌تواند تصـاویر مونو یا اسـتریو با قدرت تفکیک رادیومتریکی ۱۱ بیت اخذ کند این ماهواره قابلیت دوران ۴۵ درجه‌ای نسـبت به نادیر را داشـته و باندی به پهنای ۱۶.۴ کیلومتر در نادیر را ثبت می‌کند.

سـنجنده این ماهواره از نوع پوش‌بروم و شامل یک لنز با فاصله کانونی ۱۳.۳ متر است. هر خط تصویربرداری دارای بیش از ۳۵۰۰۰ آشکارساز با ابعاد ۸ میکرون در حالت پانکروماتیک می‌باشد و می‌تواند تصـویر را در دو حالت مونو و اسـتریو به روش Flexible با امکان دوران ±۴۵° از نادیر تهیه کند و پهنای تصویربرداری در نادیر ۱۶.۴ کیلومتر است. سـنجنده ماهواره دارای توان تفکیک مکانی کمتر از ۰.۵ متر (حدود ۰.۴۶ متر در نادیر) برای تصـــاویر پانکروماتیک و توان تفکیک مکانی ۱/۸۴ متر برای تصاویر چند طیفی است.

ارزیابی دقت طبقه‌بندی

لازمه استفاده از هر نوع اطلاعات موضوعی، آگاهی از میزان دقت و درستی آن است. صحت اطلاعات در واقع میزان «احتمال» درستی اطلاعات است. به عبارت دیگر بیانگر این نکته است که مثلاً بر روی یک نقشه تهیه شده به کمک طبقه‌بندی تصویر ماهواره‌ای، احتمال تعلق یک پدیده از روی زمین به همان گروه از پدیده‌ها به روی نقشـه چه مقدار خواهد بود. لذا باید نتایج حاصـل از تجزیه و تحلیل و طبقه‌بندی تصاویر به لحاظ دقت و درستی مورد بررسی قرار گیرند. به این ترتیب، کاربران خواهند توانست در مورد تناسب آن در مطالعات خود به خوبی تصمیم بگیرند[13].

بنابراین نداشـتن آگاهی از درسـتی طبقه‌بندی، قابلیت اعتماد نتایج به دسـت آمده از پردازش تصاویر و نقشه‌های موضوعی را مخدوش می‌سازد و باعث می‌شود تا کاربرد عملی استفاده از این نقشـــه‌ها را محدود سـازد. لذا جا دارد که روش‌هایی اصـولی و عملی تعیین و یا برآورد دقت طبقه‌بندی و عوامل مؤثر بر آن جهت استفاده از اطلاعات ماهواره‌ای، مقایسه آن به طور پیکسل به پیکسـل با واقعیت زمینی اسـت که با اسـتفاده از معیارهای بیان دقت، نتایج این مقایسـه به صـورت کمی بیان می‌گردد.[11]

یکی از متداولترین روش‌های بیان دقت طبقه‌بندی اسـتفاده از ماتریس خطای طبقه‌بندی یا ماتریس اغتشاش است. [10] ماتریس خطا، رابطه بین داده‌های مرجع شناخته شده (واقعیت زمینی)

و نتایج ذیربط یک طبقه‌بندی خودکار را، به صورت رده به رده مقایسه می‌کند. به منظور ارائه صحت طبقه‌بندی، گزارش‌های زیر استخراج می‌گردد:

دقت کلّی طبقه‌بندی[1] که عبارتست از نسبت تعداد پیکسل‌هایی که درست طبقه‌بندی شده‌اند (پیکسل‌های روی قطر اصلی ماتریس خطا) به تعداد کل پیکسل‌های تصویر.

خطای حذفی[2] شامل پیکسل‌هایی است که متعلق به کلاس مورد نظر هستند ولی در طبقه‌بندی اشتباهاً به کلاس‌هایی دیگر تعلق گرفته‌اند.

خطای مرتکب شده[3] شامل پیکسل‌هایی است که به یک کلاس مورد نظر تعلق یافته‌اند، در صورتی که در واقعیت زمینی جزء آن کلاس نیستند.

دقت تولید کننده[4] عبارتست از احتمال اینکه پیکسل طبق‌بندی شده، دقیقاً منطبق با واقعیت زمینی باشد.

دقت استفاده کننده[5] عبارتست از احتمال اینکه نمونه زمینی برداشت شده با پیکسل تصویر طبقه‌بندی شده، منطبق باشد.

یکی از نکات اساسی قابل بیان در ماتریس خطا این است که کمیّت دقت کلّی نمی‌تواند نشانگر دقت تصویر باشد. چرا که یک سری از پیکسل‌ها ممکن است بصورت تصادفی و شانسی، درست طبقه‌بندی نشده باشد. لذا برای اجتناب از این مسأله می‌توان از شاخص توافقی کاپا[6] (k) استفاده نمود.

ضریب کاپا: ضریب کاپا به عنوان معیار دیگری در بیان دقت نقشه ها، برای هر ماتریس به کمک عناصر قطری و حاشیه ای محاسبه شده و نشان دهنده آن است که طبقه بندی چقدر با داده‌های واقعیت توافق دارد. میزان کلی توافق برای هر ماتریس و بر پایه تفاوت بین توافق عملی طبقه‌بندی (توافق بین طبقه بندی رایانه‌ای و داده‌های واقعیت زمینی که توسط عناصر قطری جدول

1 - Overall Acuracy
2 - Omission Erorr
3 - Comission Erorr
4 - Producer Accuracy
5 - User Accuracy
6 - Conditional Kappa Coeficient

نمایش داده می‌شوند) و توافق شانسی ـــ که از مقادیر فرعی ستون‌ها و سطرها به دست می‌آید ـ محاسبه می‌گردد.

بنابراین ضریب کاپا نشان دهنده توافق دقت کلی با حالت موجود در طبیعت است. برای مثال اگرچه دقت کلی یک طبقه بندی می‌تواند ۸۰ درصد باشد ولی این درصد به اندازه کاپا که برای آن تعیین شده با طبیعت توافق دارد. در صورت کوچک بودن کاپا می‌توان چنین تفسیر کرد که این دقت بالا، احتمالاً ناشی از دخالت طبقه‌های بزرگ بوده که خوب تفکیک نشده است. بهترین طبقه‌بندی زمانی است که دقت کلی و ضریب کاپا هر دو بالا باشد.

ضریب کاپا از رابطه (۲) محاسبه می‌گردد:

$$\boldsymbol{K = \frac{\theta_1 - \theta_2}{1 - \theta_2}} \qquad (۲)$$

که در آن :

$\boldsymbol{\theta_1}$= صحت کلی $= \boldsymbol{\frac{1}{N}\sum_{i=1}^{m} Pii}$

$\boldsymbol{\theta_2}$= توافق شانسی $= \boldsymbol{\frac{1}{N^2}\sum_{i=1}^{m} Pi_0 \times Pi}$

عناصر قطر اصلی = $\boldsymbol{Pii}$، جمع ردیف‌ها = $\boldsymbol{Pi}$

جمع ستون‌ها = $\boldsymbol{Pi_0}$ ، تعداد طبقه‌ها = $\boldsymbol{m}$

تعداد کل نمونه‌های آزمایشی در تمام طبقات = $\boldsymbol{N}$

میزان این ضریب می‌تواند بین صفر و یک متغییر باشد که ضریب کاپا معادل یک به مفهوم توافق و همسوئی صد در صد بین حاصل طبقه بندی و واقعیت زمینی می‌باشد.[11]

به منظور دستیابی به یک طبقه‌بندی صحیح، با استفاده از اطلاعات کمکی و شناسایی طیف‌های مختلف، از پوشش‌های مختلف نواحی آموزشی انتخاب گردید. در این تحقیق با توجه به قدرت تفکیک مکانی و طیفی بالای ماهواره Worldview-2 شش کلاس آموزشی عمده شامل؛ مناطق مسکونی، خیابان، پوشش گیاهی، پهنه‌های آبی، فرودگاه و مناطق بدون استفاده (اراضی بایر) تعریف گردید.

نقاط کنترل زمینی که به منظور آموزش، تست و اعتبارسنجی شبکه‌ها مورد نیاز است که با استفاده از روش بصری در نرم افزار گوگل ارث[1] استخراج و در ادامه جدول شماره ۲ و شکل شماره ۴، نقشه پراکندگی نقاط نشان داده شده است[14].

جدول ۲- نقاط کنترل زمینی استخراج شده در گوگل ارث

کلاس ها	تصویر اول	تصویر دوم
آب	۷۳	۷۳
پوشش گیاهی	۲٦٤	۲٦٤
بدون کاربری	۳۰۳	۳۰۳
جاده	۲۰۷	۲۰۷
ساختمان	۲۸۹	۲۸۹
فرودگاه	۲٤۲	۲٤۲

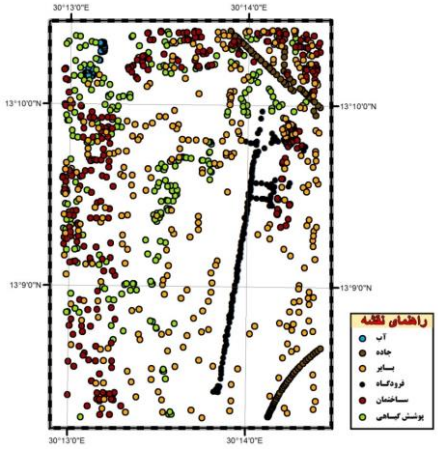

شکل ٤- نقشه پراکندگی نقاط کنترل زمینی استخراج شده از گوگل‌ارث

1 - Google Earth

نتایج و بحث

برای پیاده‌سازی الگوریتم‌های مورد استفاده در این مقاله از نرم افزار 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 نرم افزار ENVI انجام گرفت.

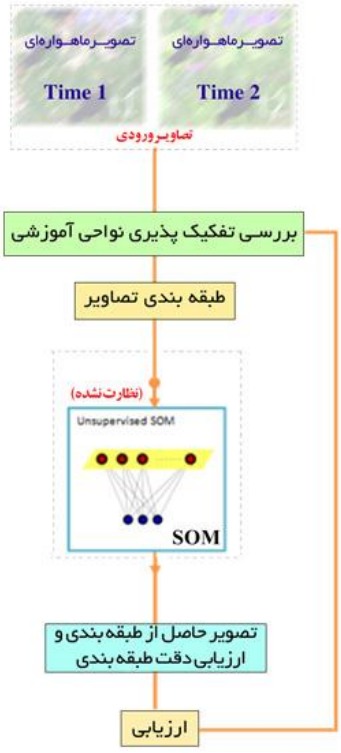

شکل ۵- نمودار جریانی مراحل مختلف تحلیل برای بارزسازی تغییرات با استفاده از الگوریتم نگاشت خودسازمانده

در ادامه، روند اجرایی و نتایج حاصل از پیاده‌سازی الگوریتم SOM تشریح شده است.

نتایج طبقه‌بندی با روش شبکه عصبی نگاشت خودسازمانده

تعداد عصب‌های موجود در لایه‌های ورودی و خروجی، یک شبکه‌ی نگاشت خود سازمانده را تعریف می‌کند. تعداد عصب‌های ورودی با تعداد عوارض ورودی برابر است. با این حال، هیچ قاعده‌ی صریحی درباره‌ی تعداد عصب‌های خروجی وجود ندارد.[14]

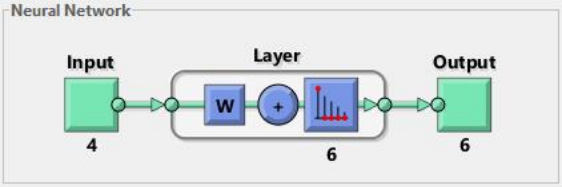

شکل ۶- نمودار شماتیک از تعداد ورودی ها، لایه پنهان و لایه خروجی الگوریتم نگاشت خود سازمانده

عموماً، لایه‌ی خروجی یک شبکه نگاشت خودسازمانده یک لایه‌ی دو بعدی ساخته شده از عصب‌های $\boldsymbol{n \times m(n,m > 1)}$ است، که هر عصب در ارتباط با یک وضعیت ثابت در فضای دو بعدی خروجی می‌باشد. گرچه یک لایه‌ی خروجی یک بعدی ممکن است، ولی چنین ترتیبی به ندرت در کاربردهای سنجش از دور دیده می‌شود. فرض می‌شود که عصب‌های مجاور در ردیف‌ها و ستون‌های لایه‌ی خروجی به اندازه یک فاصله‌ی اقلیدسی واحد از هم جدا هستند. عصب‌های لایه‌ی ورودی و لایه‌ی خروجی توسط وزن‌های سیناپسی $\boldsymbol{w_{ji}}$ لینک شده‌اند که $\boldsymbol{i}$ و $\boldsymbol{j}$ معرف عصب‌های ورودی و خروجی هستند [12].

وزن‌های $\boldsymbol{w_{ji}}$ به طور تصادفی مقداردهی شده و سپس به طور متوالی در طول آموزش تنظیم می‌شوند تا روابط میان الگوهای ورودی سازماندهی شود. تا زمانی که آموزش کامل شود، وزن‌های نهایی $\boldsymbol{w_{ji}}$ شرح می‌دهند که چه چیزی یک *فضای ویژگی توپولوژیکی* نامیده می‌شود، که در واقع توصیف عوارض ورودی در قالب وزن‌هاست استراتژی تعلیمی نگاشت خود سازمانده بر اساس مفهوم *آموزش رقابتی*[1] است. عصب‌های موجود در لایه‌ی ورودی با دیگر عصب‌های موجود در لایه‌ای که «برنده»ی فرصت تعامل با الگوی ورودی است، رقابت دارند [12].

نتیجه این است که وزن‌ها لایه‌ی ورودی را به عصب برنده متصل می‌کنند و همسایه‌های آن به طور همزمان تنظیم می‌شوند، در حالی که دیگر وزن‌ها بدون تغییر باقی می‌مانند. سرانجام، عصب‌هایی که نزدیک‌تر به هم هستند خصوصیات مشابه خواهند داشت (از نظر مقدار وزن).

1- Competitive Learning

در این تحقیق پس از معرفی ورودی‌ها و تعیین تعداد خروجی شبکه اقدام به آموزش گردید و نمودار خروجی و روابط بین وزن‌ها در شکل‌های ۷ و ۸ نشان داده شده است.

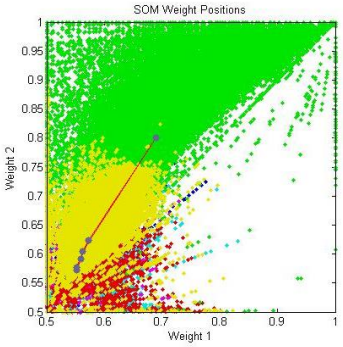

شکل ۷- خروجی موقعیت وزن‌ها در تصویر ماهواره‌ای Time1-2010

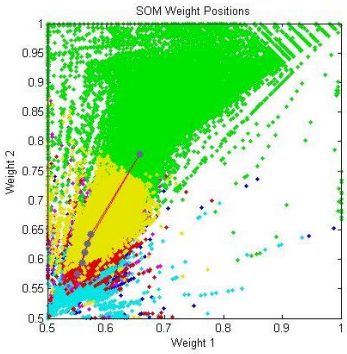

شکل ۸- خروجی موقعیت وزن‌ها در تصویر ماهواره‌ای Time2-2011

در ادامه پس از معرفی ورودی‌ها و تعیین تعداد خروجی شبکه اقدام به آموزش گردید. نقشه طبقه‌بندی شده در شکل‌های ۹ و ۱۰ نشان داده شده است.

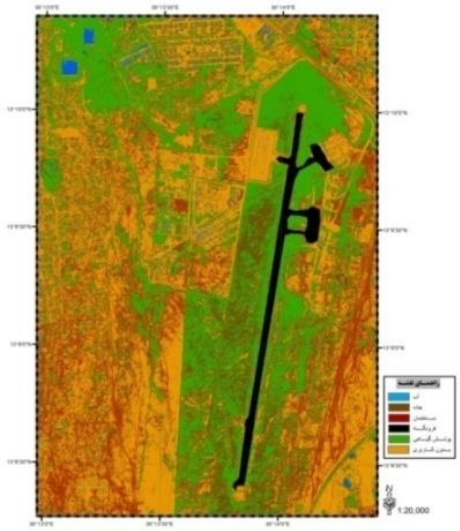

شـــکل ۹- نقشـــه طبقه‌بندی حاصـــل از الگوریتم نگاشـــت خودسازمانده (SOM) برای تصویر ماهواره‌ای Time1-2010

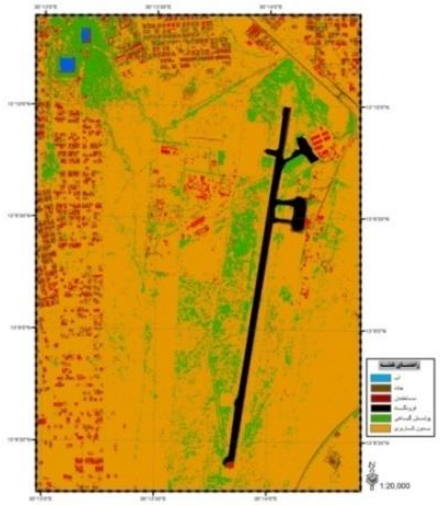

شـــکل ۱۰. نقشـــه طبقه‌بندی حاصـــل از الگوریتم نگاشـــت خودسازمانده (SOM) برای تصویر ماهواره‌ای Time2-2011

ارزیابی دقت کلی نقشه‌های طبقه‌بندی شده

گام نهایی در هر فرایند طبقه‌بندی برآورد دقت اســت. با برآورد دقت، میزان اطمینان بر روی نتایج مشـخص می‌شـود. متداولترین راه برای بیان کردن دقت طبقه‌بندی، اسـتفاده از ماتریس خطا[1] اسـت. برمبنای ماتریس خطا پارامترهای متعددی برای بیان دقت استخراج می‌گردد که از آن جمله می‌توان دقت کلی، ضـریب کاپا، دقت کاربر و دقت تولید کننده را نام برد[1]. هر چقدر درصـد دقت کلی و ضـریب کاپا به ۱۰۰ نزدیکتر باشـد، الگوریتم طبقه‌بندی کننده عملکرد بهتری از خود نشـان خواهد داد. برای ارزیابی طبقه‌بندی‌های انجام شـده از نمونه‌های آموزشـی اسـتفاده شـد و ماتریس خطا برای ارزیابی طبقه‌بندی در هر دو تصـویر ایجاد شـد. در جداول شـماره ۳ و۴، اعداد واقع بر روی قطر اصلی نشان دهنده پیکسل‌هایی هستند که صحیح طبقه‌بندی شده‌اند و سایر اعداد واقع بر قطر غیر اصلی نشان دهنده پیکسل‌هایی می‌باشند که به اشتباه طبقه‌بندی شده‌اند.

جدول ۳- ماتریس خطای طبقه بندی عوارض در تصویر زمانی اول

طبقه‌بندی / نام کلاس ها	آب	ساختمان	جاده	فرودگاه	بدون کاربری	پوشش گیاهی	Total	User's accuracy
آب	٦٠	١١	٠	٠	٨	٨	٨٧	٦٨.٩٦٥٥١٧٢٤
ساختمان	٨	٢٢٣	٧	٩	٢٣	٣٣	٣٠٣	٧٣.٥٩٧٣٥٩٧٤
جاده	٠	١١	١٥٣	٨	١٢	١٨	٢٠٢	٧٥.٧٤٢٥٧٤٢٦
فرودگاه	٠	٦	٣١	٧٧	٧	٦	١٢٧	٦٠.٦٢٩٩٢١٢٦
بدون کاربری	١	١٦	٢٨	١٢	٢٤٦	٤	٣٠٧	٨٠.١٣٠٢٩٣١٦
پوشش گیاهی	٤	٢٢	٠	٩	٧	١٩٥	٢٣٧	٨٢.٢٧٨٤٨١٠١
Total	٧٣	٢٨٩	٢١٩	١١٥	٣٠٣	٢٦٤	١٢٦٣	
Producer's accuracy	٨٢.١٩١٧٨	٧٧.١٦٢٦٣	٦٩.٨٦٣٠١	٦٦.٩٥٦٥٢	٨١.١٨٨١٢	٧٣.٨٦٣٦٤		
Overall accuracy	٧٥.٥٣٤٤٤							
Kappa coefficient	٠.٦٩٦٧٢							

1 - Error matrix or Confusion matrix

جدول ۴- ماتریس خطای طبقه بندی عوارض در تصویر زمانی دوم

طبقه‌بندی نام کلاس ها	آب	ساختمان	جاده	فرودگاه	بدون کاربری	پوشش گیاهی	Total	User's accuracy
آب	٦٨	٣١	٣	٠	٨	٤	١١٤	٥٩.٦٤٩١٢٢٨١
ساختمان	١	١٨٦	٥	٦	٢٩	٣٤	٢٦١	٧١.٢٦٤٣٦٧٨٢
جاده	٠	٣٨	١٧٥	٩	٦	٣٠	٢٥٨	٦٧.٨٢٩٤٥٧٣٦
فرودگاه	٠	٣	١٧	٨٧	١٢	٥	١٢٤	٧٠.١٦١٢٩٠٣٢
بدون کاربری	١	١٦	٨	٨	٢٣٤	٢٤	٢٩١	٨٠.٤١٢٣٧١١٣
پوشش گیاهی	٣	١٥	١١	٥	١٤	١٦٧	٢١٥	٧٧.٦٧٤٤١٨٦٥
Total	٧٣	٢٨٩	٢١٩	١١٥	٣٠٣	٢٦٤	١٢٦٣	
Producer's accuracy	٩٣.١٥٠٦٨	٦٤.٣٥٩٨٦	٧٩.٩٠٨٦٨	٧٥.٦٥٢١٧	٧٧.٢٢٧٧٢	٦٣.٢٥٧٥٨		
Overall accuracy	٧٢.٦٠٤٩١							
Kappa coefficient	٠.٦٦٢٧٣٨							

نتیجه گیری

در یک دهه‌ی اخیر، شاهد رشد شتابان کاربرد فناوری شبکه‌های عصبی مصنوعی در پردازش و طبقه‌بندی داده‌های رقومی سنجش از دور بوده‌ایم. زیرا محققان بر این باورند که این تکنیک در مقایسه با شیوه‌های آماری کلاسیک مانند روش حداکثر احتمال[1]، از قابلیت‌ها، توانمندی‌ها و انعطاف‌پذیری بیشتری برخوردار می‌باشد و این خود موجب ارتقاء و بهبود کیفیت نتایج حاصل از تشخیص و طبقه‌بندی الگوهای موجود در تصاویر رقومی سنجش از دور شده است.

عدم نیاز به اتخاذ پیش‌فرض‌هایی در مورد توزیع داده‌ها، یکی دیگر از فاکتورهای مهم در توجه روز افزون به تکنیک‌های پردازشی مبتنی بر شبکه‌های عصبی است. این وضعیت، به ویژه در شرایطی که تعداد نمونه‌های تعلیمی اندک باشند و در نتیجه، استنباط‌های آماری را با مشکل روبه رو سازند؛ از اهمیت بسیار زیادی برخوردار است.

در این تحقیق به منظور آشکارسازی تغییرات، منطقه الأبید در کشور سودان انتخاب گردید که نتیجه آن برای طبقه‌بندی تصاویر ماهواره WorldView2 در شبکه عصبی نگاشت خودسازمانده (SOM) با دقت کلی به میزان ۷۴.۰۹ درصد و مقدار ۰.۶۷ برای ضریب کاپا بدست آمد.

1 - Maximum likelihood

منابع

[1] Richards J. A., Jia X., 2006, Remote Sensing Digital Image Analysis an Introduction**, 4th Edition, Chapter 1, Springer, Germany, Berlin, Heidelberg.**

[2] Neagoe V E, Neghina M, Datcu M. 2012. Neural network techniques for automated land-cover change detection in multispectral satellite time series imagery. International Journal of Mathematical Models and Methods in Applied Sciences, 6:130-139

[3] Atkinson P.M., Tatnall, A.R.L., 1997, Neural Networks in Remote Sensing, Int. J. Remote Sensing, Vol. 18, No. 4, pp. 699-709.

[4] Kohonen T., 1995, Self-Organizing Maps, Springer, Berlin, Heidelberg, New-York: Springer, Berlin.

[5] 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.

[6] 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.

[7] Menhaj M.B., 2002, Introduction to Artificial Neural Network, the publication center of AmirKabir University.

[8] Haykin S., 1999, Neural Network a Comprehensive Foundation, 2th edition, Pearson prentice hall**.**

[9] Worlview-2 Imagery Products: Product Guide, DigitalGlobe, Longmont, CO, Feb. 2006. [Online]. vailable: http://digitalglobe.com

[10] Lillesand, T.M. and R.W. Kiefer. 1994. Remote Sensing and Photo Interpretation, 3rd. ed. John Wiley & Sons: New York. 750 p.

[11] *فتاحی م م. ۱۳۹۰. سنجش از دور کاربردی.چاپ اول. تهران: مرز دانش، آبنگاه، ۱۴۵ صفحه.*

[12] *کلامی هریس س م. ۱۳۹۱. مجموعه آموزشی شبکه‌های عصبی مصنوعی، بخش یازدهم و دوازدهم: شبکه‌های عصبی رقابتی و نگاشت‌های خود سازمان ده یا* SOM *(الف) و (ب).* www.faradars.org.

[13] *حسینی اصل ا. ۱۳۸۳. بارزسازی تغییرات پوشش زمین در داده‌های سنجش از دور بر اساس شبکه‌های عصبی مصنوعی. پایان نامه کارشناسی ارشد، دانشکده علوم زمین، دانشگاه شهید بهشتی.*

[14] *حدادی ع، ۱۳۸۸. ارائه روشی ترکیبی از شبکه های عصبی نظارت شده و نظارت نشده در طبقه‌بندی تصاویر سنجش از دور. مجله سنجش از دور و* GIS *ایران. سال اول، ۳: ۳۳-۵۰.*