

## بهره‌گیری از الگوریتم شبکه عصبی انتشار ناهمسانگرد جهت بهبود صحت طبقه‌بندی تصاویر چند طیفی

پرویز ضیاییان فیروز آبادی<sup>۱\*</sup>، سید محمد توکلی صبور<sup>۲</sup>، بهناز ترکمانی اصل<sup>۳</sup>

<sup>۱</sup> استاد گروه سنجش‌ازدور و سیستم اطلاعات جغرافیایی گرایش سنجش‌ازدور، دانشکده جغرافیای دانشگاه خوارزمی  
zeaiean@khu.ac.ir

<sup>۲</sup> استادیار گروه سنجش‌ازدور سیستم اطلاع جغرافیایی گرایش سنجش‌ازدور، دانشکده جغرافیای دانشگاه خوارزمی  
Tavakkoli@khu.ac.ir

<sup>۳</sup> دانشجوی کارشناسی ارشد سنجش‌ازدور و سیستم اطلاعات جغرافیایی گرایش سنجش‌ازدور، دانشکده جغرافیای  
دانشگاه خوارزمی  
Behnaz.torkaman@gmail.com

(دریافت: شهریور ۱۴۰۱، تصویب: اسفند ۱۴۰۴)

### چکیده

طبقه‌بندی تصاویر سنجش از دوری به منظور تفسیر و تهیه نقشه‌های موضوعی یکی از مهم‌ترین مباحث در علم سنجش از دور می‌باشد. با توجه به اهمیت این فرآیند در استخراج اطلاعات از تصاویر چندطیفی ماهواره‌ای، پژوهش حاضر تلاش دارد تا با بهره‌گیری از الگوریتم شبکه عصبی انتشار ناهمسانگرد (Anisotropic Diffusion Neural Network-ADNN) به همراه بهره‌گیری از بافت حاصل از تبدیل موجک، صحت طبقه‌بندی تصاویر ماهواره‌ای را بهبود داده و به دنبال یافتن بهترین سطح از سطوح پنجگانه الگوریتم برای الحاق به داده‌های در فرآیند طبقه‌بندی تصویر می‌باشد. این روش، مقادیر پیکسل‌های تصویر ورودی را با میانگین وزنی متوالی بر اساس پیکسل‌های همسایه در باندهای ورودی اصلاح می‌کند. عبارت دیگر، این الگوریتم، به عنوان یک فیلتر پایین‌گذر متغیر در فضا و زمان عمل می‌کند. الگوریتم مذکور تصویر چندطیفی ورودی را به پنج سطح مقیاس/وضوح انتقال می‌دهد. این الگوریتم می‌تواند همزمان اطلاعات طیفی تصویر و جزئیات بافت حاصل از تبدیل موجک را در یک نمایش چند مقیاسه پردازش کند. در این پژوهش، از تصاویر سطح ۲ لندست ۸ از منطقه میان‌دوآب در شهرستان آذربایجان غربی بهره گرفته شد. بعد از استخراج تصاویر سطوح مختلف از طریق الگوریتم ADNN، طبقه‌بندی تصاویر حاصله به همراه تصاویر اصلی سنجنده لندست در چهار کلاس خاک، آب، گیاه و منطقه مسکونی با استفاده از الگوریتم ماشین بردار پشتیبان (SVM) انجام شد. همچنین، برای ارزیابی عملکرد تصاویر حاصل از الگوریتم ADNN بر روی تصویر اصلی، از نمونه‌های اخذ شده از تصاویر همزمان و با وضوح بالای گول‌ارث استفاده گردید. با توجه به نمودارهای صحت کاربر می‌توان نتیجه گرفت که الگوریتم شبکه عصبی انتشار ناهمسانگرد در تشخیص آب عملکرد بسیار خوبی داشته و می‌توان از آن در پژوهش‌های مرتبط با تشخیص پهنه‌های آبی و خطوط ساحلی بهره برد. در نهایت، با همراه کردن خروجی تبدیل موجک، صحت کلی و ضریب توافق کاپا افزایش یافته و بهترین سطح شبکه ADNN، در هر دو حالت با و بدون همراه کردن خروجی تبدیل موجک به مجموعه داده‌ها، سطح ۲ شبکه ADNN بوده و بیشترین کاپای طبقه‌بندی‌ها را به خود اختصاص داده است.

**واژگان کلیدی:** شبکه عصبی انتشار ناهمسانگرد (ADNN)، طبقه‌بندی SVM، تبدیل موجک، تصاویر لندست، سنجش از دور

## ۱- مقدمه

طبقه بندی تصاویر یکی از روش های مهم در تفسیر تصاویر ماهواره ای است که کاربرد گسترده ای در بررسی تغییرات زمین دارد. داده های ماهواره ای به دلیل ارائه اطلاعات به روز، هزینه پایین و تنوع در ابزارهای موجود، به عنوان ابزاری مناسب برای آشکارسازی و بررسی تغییرات شناخته شده اند [۱].

استخراج ویژگی ها، کاربردی بنیادین در پردازش تصویر است و نگاه بسیاری از محققین در سراسر جهان را به خود جلب کرده است. حجم تحقیقات مرتبط با استخراج ویژگی برای طبقه بندی در سال های اخیر افزایش یافته است. روش ها و الگوریتم های دخیل در استخراج ویژگی تصویر شامل موارد زیر است، اما محدود به آنها نیست [۲]:

- استخراج ویژگی سطح پایین از طریق آشکارسازهای لبه
- استخراج ویژگی سطح بالا با انطباق شکل
- استخراج شکل انعطاف پذیر (تکنیک مارها و سایر تکنیک ها)
- توصیف شیء
- توصیف بافت، قطعه بندی و طبقه بندی

استخراج اطلاعات موضوعی از تصاویر ماهواره ای، جزء کلیدی تشخیص الگوها است و می تواند با استفاده از استراتژی های مختلف طبقه بندی پیاده سازی شود. تکنیک های استخراج اطلاعات پیکسل پایه و شیء مینا، دو دسته اصلی از این استراتژی ها هستند. یکی از چالش برانگیزترین موضوعات برای متخصصان سنجش از دور، بهبود صحت نقشه های تولید شده از طریق تکنیک های طبقه بندی تصویر است. همه تکنیک های طبقه بندی، چه با استفاده از الگوریتم های ساده مانند حداقل فاصله تا میانگین و چه با استفاده از مدل های پیچیده یادگیری عمیق مانند CNN، نیاز به داده ها و اطلاعات ورودی مناسب دارند. دانشمندان توجه زیادی به انواع مختلف داده های ورودی برای افزایش صحت خروجی ها داشته اند. محققان متعددی تلاش کرده اند تا صحت طبقه بندی را از طریق گنجاندن منابع داده مختلف از جمله اطلاعات کمکی و اطلاعات بر گرفته از تصویر مانند شاخص های پوشش گیاهی و سایر شاخص های طیفی بهبود بخشند.

[۳] روش ها و تکنیک های طبقه بندی تصویر را با هدف افزایش عملکرد طبقه بندی بررسی کردند. آنها به این نتیجه رسیدند که "استفاده مؤثر از ویژگی های چندگانه داده های سنجش از دور و انتخاب یک روش طبقه بندی مناسب، به ویژه برای بهبود صحت طبقه بندی بسیار مهم است و ویژگی پاسخ طیفی مهم ترین اطلاعات مورد استفاده برای طبقه بندی پوشش زمین است." آنها رویکردهایی را برای استفاده از ویژگی های چندگانه داده های سنجش از دور برای افزایش صحت طبقه بندی خلاصه کردند، از جمله:

- آمار مرتبه اول، دوم و سوم در حوزه مکانی به عنوان ویژگی های بافت، مانند ماتریس های هم رخدادی سطوح خاکستری (GLCM)
- اطلاعات فرکتالی
- تحلیل زمین آماری، شامل نیمه واریوگرام ها و فیلتر گابور
- ادغام داده های چند حسگری یا چند وضوحی، شامل داده های سنجش از دور فعال و غیرفعال
- روش های مختلف تبدیل، مانند پارتیشن بندی فازی، تحلیل رگرسیون گام به گام، تحلیل مؤلفه های اصلی (PCA)، تبدیل منگوله دار، تبدیل موجک، تبدیل چرخشی، تحلیل تفکیک مخلوط گاوسی، شاخص نواحی ساخته شده و تحلیل اختلاط طیفی
- استفاده از داده های چندزمانه، شامل تصاویر نوری و SAR
- استفاده از داده های با وضوح مکانی خوب
- استفاده از داده های فراطیفی

علاوه بر این، آنها در مورد مفید بودن داده های کمکی مانند توپوگرافی، خاک، جاده و داده های سرشماری - و ادغام آنها با داده های سنجش از دور برای بهبود عملکرد طبقه بندی بحث کردند.

[۴] یک شاخص مبتنی بر ویژگی طیفی-مکانی به نام شاخص شباهت همسایگی پیکسل (PNS) را برای بهبود صحت طبقه بندی معرفی کردند. آنها نتیجه گرفتند که "کیفیت عملکرد PNS در مقایسه با سایر ویژگی های طیفی-مکانی نسبتاً بالاتر بود." انواع اطلاعات به دست آمده از داده های سنجش از دور، مانند NDMI، NDSI، NDVI، NDBI، DEM و غیره، برای افزایش صحت طبقه بندی در تصاویر ماهواره ای گنجانده شده اند.

[۵] تأثیر افزودن شاخص‌های پوشش گیاهی طیفی را بر دقت شناسایی نوع محصول ارزیابی کرد و نتیجه گرفت که اکثر شاخص‌ها به طور قابل توجهی صحت طبقه‌بندی را بهبود می‌بخشند.

به کارگیر توصیفگرهای شکل منحنی طیفی کلاسهای اطلاعاتی تصویر با هدف دخیل کردن این توصیفگرها در فرآیند طبقه بندی تصاویر ماهواره ای و بالا بردن صحت طبقه بندی تصاویر ماهواره ای توسط محققین ایرانی مورد بررسی و ارزیابی قرار گرفته است [۶].

در سال‌های گذشته، روش‌های مبتنی بر شبکه‌های عصبی مصنوعی به طور وسیع و گسترده در طبقه‌بندی داده‌های ماهواره‌ای مورد استفاده قرار گرفته‌اند [۷، ۲۰...]. فرآیند طبقه‌بندی تصاویر رقومی ماهواره‌ای به‌عنوان یکی از مهم‌ترین روش‌ها برای استخراج اطلاعات کاربردی از تصاویر محسوب می‌شود. این فرآیند پیچیده تحت تأثیر عوامل مختلفی قرار دارد. در راستای بهبود صحت طبقه‌بندی، پژوهشگران تلاش‌های متعددی در توسعه روش‌ها و تکنیک‌های پیشرفته انجام داده‌اند که از مهم‌ترین این روش‌ها می‌توان به شبکه‌های عصبی مصنوعی، منطق فازی و سیستم‌های هوشمند اشاره کرد [۲].

یکی از گام‌های مهم پیش از طبقه‌بندی، استفاده از فیلترهای حفظ لبه مبتنی بر معادله انتشار ناهمسانگرد است که در مقایسه با روش‌های دیگری نظیر فیلتر گوسی یا فیلترهای خطی پایین‌گذر، نتایج بهتری در بهبود طبقه‌بندی ارائه می‌دهد [۲۱]. این الگوریتم که به‌عنوان یک شبکه عصبی چندسطحی معرفی شده است، در هر سطح با استفاده از معادله انتشار ناهمسانگرد، مقادیر پیکسل‌های تصویر را با میانگین وزنی متوالی پیکسل‌های همسایه اصلاح می‌کند.

ویژگی برجسته این روش، پردازش هم‌زمان اطلاعات طیفی و بافتی تصاویر چندطیفی در پنج سطح مقیاس و قدرت تفکیک مکانی است. این الگوریتم به‌جای انجام طبقه‌بندی مستقیم، تصاویر را با کاهش تنوع شدت نامطلوب بهبود می‌بخشد و توانایی پردازش داده‌های چندطیفی را با جزئیات بافتی فراهم می‌کند [۲۲، ۲۳].

از مزایای این روش می‌توان به موارد زیر اشاره کرد: برخلاف فیلترهای خطی پایین‌گذر، این الگوریتم تصاویر را در چندین سطح مقیاس هموارسازی می‌کند، درحالی‌که روش‌های متداول تنها در یک سطح مقیاس انجام می‌شوند [۲۱].

تمام کانال‌های طیفی ورودی به‌طور هم‌زمان پردازش می‌شوند، درحالی‌که سایر فیلترها هر کانال را به‌طور مستقل پردازش می‌کنند [۲۴].

این الگوریتم از اطلاعات طیفی محلی و بافت برای اصلاح تصویر در یک سطح مشخص استفاده می‌کند. اطلاعات طیفی از تصویر ورودی و اطلاعات بافتی از نقشه‌های texture-context استخراج می‌شود [۲۴].

تفاوت اصلی این الگوریتم با روش‌های نظارت‌شده در این است که نیازی به مجموعه داده آموزشی ندارد و نقشه موضوعی تولید نمی‌کند. در واقع، عملکرد این روش به طرح‌های خوشه‌بندی نزدیک‌تر است، زیرا داده‌ها را به‌جای برچسب‌گذاری، تغییر شکل می‌دهد و ترکیبی از هموارسازی فضایی و خوشه‌بندی را در نظر می‌گیرد [۲۴].

الگوریتم انتشار ناهمسانگرد اولین بار توسط پرونا و مالک (۱۹۹۰) معرفی شد [۲۵]. این روش به دلیل توانایی تعیین دقیق لبه‌ها و کنترل مقیاس، بسیار مورد توجه قرار گرفته است. اصل کلی انتشار ناهمسانگرد به این صورت است که انتشار در مناطقی با شیب محلی کم انجام شده و در لبه‌های تصویر که شیب گرادیان بزرگ‌تر است، از انتشار جلوگیری می‌شود. این ویژگی موجب می‌شود هموارسازی درون منطقه‌ای بدون هموارسازی بین منطقه‌ای صورت پذیرد.

با عنایت به مطالب فوق الذکر، این تحقیق به دنبال پاسخ به این سوال می‌باشد که کدامیک از تصاویری پنج سطحی منتج شده از روش ADNN میتواند در افزایش صحت طبقه بندی تصاویر ماهواره موثرتر عمل کند. براین مبنا از دو روش طبقه بندی SVM و روش شبکه عصبی مصنوعی (NNC) بهره گیری شده است. این سوال به عنوان خلاء مطالعاتی در مطالعات گذشته در نظر گرفته شده است.

## ۲- مبانی نظری پژوهش


ویتکین (۱۹۸۳) یک تکنیک مقیاس-فضا را معرفی کرد که شامل اعمال فیلتر گوسی بر روی تصویر اصلی به‌منظور تولید تصاویری با وضوح متفاوت می‌شود [۲۶]. این تکنیک با هموارسازی تصویر، امکان بررسی ویژگی‌ها در مقیاس‌های مختلف را فراهم می‌کند.

پس از آن، پرونا و مالک (۱۹۹۰) ایده اصلی این رویکرد را توسعه داده و مدل ریاضی آن را توصیف کردند. تصویر خروجی در خانواده‌ای از تصاویر مشتق‌شده، از طریق فیلتر

کردن تصویر اصلی  $I_0(x, y)$  با یک هسته گاوسی بر حسب واریانس  $t$ ،  $G(x, y; t)$  به دست می آید شکل (۱). معادله کلی این فرآیند به صورت زیر بیان می شود [۲۵]:

$$I(x, y, t) = I_0(x, y) * G(x, y; t) \quad (1)$$

$t$  پارامتر مقیاس-فضاست و همچنین مقیاس های بزرگتر  $t$  با تصاویری با قدرت تفکیک مکانی بزرگتر مطابقت دارد.



شکل ۱- مجموعه ای از سیگنال های  $D-1$  که با فیلتر کردن تصویر اصلی  $I(x, t)$  (پایین) با یک هسته ی گاوسی که واریانس آنها از پایین به بالا افزایش می یابد به دست می آید [۲۵].

این مجموعه از پارامترها که از تصاویر مشتق شده اند، می توانند معادل راه حل انتقال حرارت یا فرآیند انتشار در نظر گرفته شوند. در پارادایم مقیاس-فضای استاندارد، موقعیت دقیق یک مرز در مقیاس های بزرگ به طور مستقیم قابل دسترس نیست. تنها راه برای یافتن موقعیت واقعی لبه های آشکار در مقیاس بزرگ، ردیابی آنها در طول فضای مقیاس تا رسیدن به موقعیت آنها در تصویر اصلی است [۲۵]. پرونا و مالک [۲۵] ویژگی های اصلی الگوریتم شبکه عصبی انتشار ناهمسانگرد را به شرح زیر بیان کردند اصلاح هم زمان همه باندهای طیفی ورودی: انتشار ناهمسانگرد به صورت چندطیفی بر روی تمامی کانال های طیفی اعمال می شود.

عملکرد در پنج سطح مقیاس و قدرت تفکیک مکانی: در این الگوریتم، هر سطح شبکه یک آرایه دوبعدی از گره ها است که حاوی تصاویر اصلاح شده فعلی در مقیاس و مکان مشخص است. سطح ابتدایی شبکه از یک گره برای هر پیکسل در قدرت تفکیک مکانی کامل (تصویر اولیه) تشکیل شده و این سطح با استفاده از تصاویر چندطیفی ورودی مقاداردهی اولیه می شود. در سطوح متوالی، نمونه برداری به صورت ۲:۱ انجام می شود.

استفاده هم زمان از اطلاعات طیفی محلی و بافتی: الگوریتم، میزان اصلاح سازی در هر سطح و مکان تصویر را بر اساس اطلاعات طیفی و بافت مشخص می کند. اطلاعات طیفی از تصویر چندطیفی ورودی و اطلاعات بافت از نقشه های texture-context استخراج می شود.

انتشار ناهمسانگرد یک تکنیک هموارسازی سازگار است که به دلیل توانایی آن در حفظ محلی سازی لبه ها و کنترل مقیاس، مورد توجه قرار گرفته است [۲۴]. در سال های اخیر، طرح های مشابه مبتنی بر انتشار ناهمسانگرد توسعه یافته و مورد مطالعه قرار گرفته اند که در بخش های بعدی به آنها اشاره خواهد شد.

## ۲-۱- ساختار شبکه عصبی انتشار ناهمسانگرد

شبکه عصبی انتشار ناهمسانگرد یک شبکه پنج سطحی است که در آن پایین ترین سطح شامل یک گره به ازای هر پیکسل از تصویر با قدرت تفکیک مکانی اصلی است. سطوح بعدی این شبکه به صورت درخت چهار تایی به یکدیگر متصل می شوند.


در این ساختار پایین ترین سطح شبکه با خروجی مربوط به بیشترین فرکانس نقشه بافت در همان موقعیت مکانی متصل می شود.

سطوح متوالی شبکه به طور پیوسته به فرکانس های پایین تر نقشه بافت متصل می شوند.

این ویژگی به شبکه اجازه می دهد که هم زمان اطلاعات دقیق مربوط به بافت های محلی و طیفی را در مقیاس های مختلف پردازش کرده و جزئیات تصاویر را با دقت بیشتری حفظ کند [۲۲].

$$I_t = \text{div}(c(x, y, t)\nabla I) = c(x, y, t)\Delta I + \nabla c \cdot \nabla I \quad (2)$$

این معادله (۲) فرمول کلی شبکه عصبی انتشار ناهمسانگرد را ارائه می دهد. در این شبکه، هر سطح از معادله انتشار ناهمسانگرد پیروی می کند و با استفاده از اتصالات چهار همسایه در یک شبکه مربعی پیاده سازی می شود شکل (۲). این روش نخستین بار توسط پرونا و مالک پیشنهاد شد و اساس آن بر تعامل بین گره های همسایه در شبکه است:



شکل ۳- ساختار شبکه‌ای که اجرای انتشار ناهمسانگرد را توصیف میکند. شارژ خازن در هر گره ی شبکه نشان دهنده روشنایی تصویر در یک پیکسل است. مقاومت های خطی انتشار خطی همسانگرد تولید می کنند. مقاومت هایی با مشخصه ۱-۷ مانند انتشار غیر همسانگرد را ایجاد می کنند [۲۲].

مقدار گرادیان را می توان بر روی ساختارهای همسایگی مختلف محاسبه کرد و به نتایج متفاوتی بین دقت و محل دست یافت. ساده ترین انتخاب عبارت است از تقریب مقیاس گرادیان در هر محل قوس با قدر مطلق همان تصویر در امتداد جهت قوس:

$$\begin{aligned} C_{N_{i,j}}^t &= g(|\nabla_N I_{i,j}^t|) \\ C_{S_{i,j}}^t &= g(|\nabla_S I_{i,j}^t|) \\ C_{E_{i,j}}^t &= g(|\nabla_E I_{i,j}^t|) \\ C_{W_{i,j}}^t &= g(|\nabla_W I_{i,j}^t|) \end{aligned} \quad (۶)$$

باید توجه داشت که شکل (۲) گسسته سازی دقیقی از فرمول کلی انتشار ناهمسانگرد (۲) نیست، بلکه یک معادله انتشار مشابه است که در آن تانسور رسانایی مورب با ورودی های  $g(|I_x|)$  و  $g(|I_y|)$  به جای  $g(|\nabla I|)$  و  $g(|\nabla I|)$  می شود. این طرح گسسته، ویژگی مهم حفظ مقدار کل روشنایی تصویر را که خاصیت معادله پیوسته (۳) است، حفظ می کند.

علاوه بر این، "شار" روشنایی از طریق هر قوس شبکه تنها به مقادیر روشنایی در دو گره مجاور آن بستگی دارد. این ویژگی باعث می شود که طرح مذکور به یک انتخاب طبیعی برای اجرای VLSI آنالوگ تبدیل شود (شکل ۳) [۲۶]. می توان تأیید کرد که برای هر تقریب گرادیان انتخاب شده، این طرح گسسته همچنان اصل حداکثر و حداقل را برآورده می کند، به شرط آنکه تابع  $g$  بین ۰ و ۱ محدود شده باشد [۲۶]. پرونا و مالک همچنین بیان کردند که میتوان به طور مستقیم از فرمول (۳) با استفاده از اصل  $(Im)_{i,j}^t = \max [0, \lambda]$  و  $c \in [0, 1]$  اثبات کرد که


$$I_{i,j}^{t+1} = I_{i,j}^t + \lambda [c_N \cdot \nabla_N I + c_S \cdot \nabla_S I + c_E \cdot \nabla_E I + c_W \cdot \nabla_W I]_{i,j}^t \quad (۳)$$

که در آن (۲)  $c_N, c_S, c_E$  و  $c_W$  به ترتیب ضرایب هدایت در جهت های شمال، جنوب، شرق و غرب در زمان  $t$  تعریف میشود و مقدار  $\lambda$  به عنوان نرخ بروز رسانی بین [۰, ۱.۴] در نظر گرفته میشود. پرونا و مالک برای این ضرایب هدایت، مقادیری پیشنهاد کردند که با گرادیان روشنایی محلی در جهت های مختلف متناسب است. گرچه ضرایب رسانایی دیگری نیز معرفی شده اند، اما هیچ یک از این ضرایب برای تصاویر چندطیفی به کار نرفته اند و همگی تنها به اطلاعات گرادیان از همان مقیاس وابسته هستند شکل (۳) [۲۲].

$$\begin{aligned} \nabla_N I_{i,j} &\equiv I_{i-1,j} - I_{i,j} \\ \nabla_S I_{i,j} &\equiv I_{i+1,j} - I_{i,j} \\ \nabla_E I_{i,j} &\equiv I_{i,j-1} - I_{i,j} \\ \nabla_W I_{i,j} &\equiv I_{i,j+1} - I_{i,j} \end{aligned} \quad (۴)$$

ضرایب هدایت در هر تکرار به عنوان تابعی از گرادیان روشنایی به روز می شوند:

$$\begin{aligned} C_{N_{i,j}}^t &= g(\|(\nabla I)_i^t + (1/2)_{i,j}\|) \\ C_{S_{i,j}}^t &= g(\|(\nabla I)_i^t + (1/2)_{i,j}\|) \\ C_{E_{i,j}}^t &= g(\|(\nabla I)_i^t + (1/2)_{i,j}\|) \\ C_{W_{i,j}}^t &= g(\|(\nabla I)_i^t + (1/2)_{i,j}\|) \end{aligned} \quad (۵)$$



شکل ۲- ساختار طرح محاسباتی گسسته برای شبیه سازی معادله انتشار (۳). مقادیر روشنایی  $i$ ، با گره های یک شبکه و ضرایب هدایت  $c$  با قوس ها مرتبط است. یک گره از شبکه و چهار همسایه شمالی، شرقی، غربی و جنوبی آن نشان داده شده است [۲۲].

جدید (برای حداکثر یا حداقل) باید به داخل یا بالای تابع روشنایی  $I(x,y,t_f)$  در مقیاس درشت  $t_f$  تعلق داشته باشد. به عبارت دیگر، معیار علیت زمانی برقرار است که بتوان نشان داد تمام ماکزیمم‌ها و مینیمم‌های موجود در فضای مقیاس به تصویر اصلی تعلق دارند.

معادله انتشار (۳) یک حالت خاص از یک کلاس جامع‌تر از معادلات بیضوی است که از اصل حداکثر پیروی می‌کند. این اصل بیان می‌کند که تمام نقاط حداکثر در حل معادله (در فضا و زمان) تنها به شرایط اولیه (تصویر اصلی) و مرزهای ناحیه موردنظر تعلق دارند، مشروط بر آنکه ضریب هدایت مثبت باشد.

در این حالت، به دلیل استفاده از مرزهای آداباتیکی، اصل حداکثر به‌طور قوی‌تری برقرار است؛ بدین معنا که حداکثرها فقط به تصویر اصلی تعلق دارند [۲۵].

### ۲-۲-۲- شفاف سازی لبه

فیلتر پایین‌گذر ساده و انتشار خطی که معمولاً برای حذف نویز و اجرای الگوریتم‌های فضای مقیاس استفاده می‌شوند، باعث محو شدن لبه‌ها می‌شوند. این محو شدن می‌تواند تشخیص و محلی‌سازی مرزها را دشوار کند [۲۷]. برای بهبود لبه‌ها و بازسازی تصاویر تار، می‌توان از فیلتر بالاگذر یا اجرای معادله انتشار به عقب در زمان استفاده کرد. این روش‌ها با وجود پتانسیل بهبود تصاویر، با مشکلات محاسباتی ناپایدار و عددی همراه هستند، مگر آنکه مسئله به‌طور مناسب محدود یا دوباره فرموله شود.

در این بخش نشان داده می‌شود که اگر ضریب هدایت به‌طور مناسب تابعی از گرادیان تصویر انتخاب شود، می‌توان از انتشار ناهمسانگرد رو به جلو در مقیاس زمان برای بارزسازی لبه‌ها استفاده کرد. این امر همچنین طبق اصل حداکثر به پایداری انتشار درون منطقه‌ای کمک می‌کند.

در این مدل، لبه‌ها به‌عنوان یک تابع پله‌ای در نظر گرفته می‌شوند که با هسته گاوسی ترکیب می‌شود شکل (۴). برای سادگی و بدون از دست دادن کلیت مدل، فرض می‌شود که لبه‌ها با محور  $y$  هم‌راستا هستند. در این صورت، عملگر واگرایی به عبارت زیر ساده می‌شود [۲۵]:

$$\text{div}(c(x,y,t)\nabla I) = \frac{\partial}{\partial x}(c(x,y,t)I_x) \quad (10)$$

$(I_M)_{i,j}^t = \min \{(I, I_N, I_S, I_E, I_W)_{i,j}^t, \{(I, I_N, I_S, I_E, I_W)_{i,j}^t\}$  }  
 } حداکثر و حداقل های همسایگی  $I_{i,j}$  در تکرار  $t$  است.

$$(I_M)^t \leq I_{i,j}^{t+1} \leq (I_M)_{i,j}^t \quad (7)$$

یعنی هیچ ماکزیمم و مینیمم (محلی) در فضای داخلی مقیاس-فضای گسسته امکان پذیر نیست. در حقیقت:

$$\begin{aligned} I_{\{i,j\}}^{t+1} &= I_{i,j}^t + \lambda [c_N \cdot \nabla_N I + c_S \cdot \nabla_S I \\ &\quad + c_E \cdot \nabla_E I + c_W \cdot \nabla_W I]_{i,j}^t \\ &= I_{i,j}^t (1 \\ &\quad - \lambda(c_N + c_S + c_E \\ &\quad + c_W)_{i,j}^t \\ &\quad + \lambda(c_N \cdot I_N + c_S \cdot I_S \\ &\quad + c_E \cdot I_E + c_W \cdot I_W)_{i,j}^t) \\ &\leq I_{M_{i,j}}^t \left( 1 \right. \\ &\quad \left. - \lambda(c_N + c_S + c_E \right. \\ &\quad \left. + c_W)_{i,j}^t \right. \\ &\quad \left. + \lambda I_{M_{i,j}}^t (c_N + c_S + c_E \right. \\ &\quad \left. + c_W)_{i,j}^t = I_{M_{i,j}}^t \right) \end{aligned} \quad (8)$$

و به همین ترتیب:


$$\begin{aligned} I_{\{i,j\}}^{t+1} &\geq I_{m_{i,j}}^t \left( 1 - \lambda(c_N + c_S + c_E \right. \\ &\quad \left. + c_W)_{i,j}^t \right. \\ &\quad \left. + \lambda I_{m_{i,j}}^t (c_N + c_S + c_E \right. \\ &\quad \left. + c_W)_{i,j}^t = I_{m_{i,j}}^t \right) \end{aligned} \quad (9)$$

طرح عددی مورد استفاده پرونا و مالک برای به دست آوردن تصاویر همان است که با معادلات (۳)، (۴) و (۶) با استفاده از تصویر اصلی به عنوان شرط اولیه و شرایط مرزی آداباتیکی، یعنی تنظیم ضریب هدایت به سمت صفر در مرزهای تصویر می‌باشد.

### ۲-۲- ویژگی های شبکه عصبی انتشار ناهمسانگرد

#### ۲-۲-۱- اصل حداکثری

شبکه عصبی انتشار ناهمسانگرد مستلزم آن است که در فرآیند انتقال از مقیاس ریز به مقیاس درشت در فضای مقیاس، هیچ ویژگی جدیدی در تصویر ایجاد نشود. در این مفهوم، اگر ویژگی‌های تصویر را با حباب‌های تابع روشنایی  $I(x,y,t)$  برای مقادیر مختلف پارامتر مقیاس  $t$  ایجاد یک لکه



شکل ۵- انتخابی از  $\phi$  (°) که باعث افزایش لبه میشود [۲۵].


یک مقدار آستانه مشخص وجود دارد برای  $K$  و  $a$  که قبل از آن به طور یکنواخت  $\phi$  (°) افزایش و فراتر از آن به طور یکنواخت کاهش می‌یابد که نتیجه مطلوب آن تار شدن نا پیوستگی های کوچک و شفاف و تیز شدن لبه‌ها می‌باشد. همچنین توجه داشته باشید که در یک همسایگی از شیب دارترین ناحیه یک یال، انتشار ممکن است رو به عقب در نظر گرفته شود زیرا  $\phi'(I_x)$  در فرمول (۱۲) منفی است، این مورد ممکن است نگران کننده باشد زیرا انتشار با ضریب ثابت که به رو به عقب اجرا می‌شود ناپایدار است و تولید نویز را تقویت میکند که پرونا و مالک بیان میکنند در مورد این روش بنا بر اصل حداکثری این نگرانی بی مورد است و نویزی تولید نمیشود و به طور تجربی در نواحی  $\phi'(I_x)$  منفی است به سرعت کوچک میشوند و فرایند پایدار می‌ماند [۲۵].

سایر طرح های مشابه مبتنی بر انتشار ناهمسانگرد از آن زمان مورد مطالعه قرار گرفته اند از جمله [۲۸،۲۹،۳۰] که روشهایشان بر اساس فرمول اصلی پرونا و مالک ساخته شده بود که نتیجه آن وضوح و پدیدار شدن لبه‌ها و همچنین هموارسازی سطوح یکسان و متشابه بوده است. [۳۱] پیشنهاد میکنند انتشار ناهمسانگرد رو به جلو و رو به عقب با فرایند تلفیقی خنک سازی که باعث میشود نویز تصویر را هنگام نمایان کردن لبه‌ها حذف کنید، ترکیب کنید. [۳۲] با ترکیب از معادله پرونا و مالک با معادله گرما به الگوریتمی کاربردی جهت حذف نویز و تشخیص لبه‌ها دست یافتند.

### ۳- روش تحقیق

#### ۳-۱- منطقه مورد مطالعه

منطقه میان‌دوآب در استان آذربایجان غربی به دلیل تنوع پوشش‌های طبیعی و انسانی مانند بافت‌های شهری و روستایی، پوشش گیاهی، وجود رودخانه‌ها و دریاچه‌های متعدد و همچنین زمین‌های بکر و بایر انتخاب شده است.



شکل ۴- از بالا به پایین یک لبه نرم شده و مشتقات اول دوم و سوم آن [۲۵].

که  $C$  به عنوان تابعی از گرادیان  $I$  انتخاب میشود:  $c$   
 $\phi(I_x) = g(I_x)$  و  $(x, y, t) = g(I(x, y, t))$  طبق شکل (۲)  
 $I_x$  نشان دهنده ی شار  $I_x$  می‌باشد.  
 سپس معادله یک بعدی انتشار میشود [۲۵]:

$$I_t = \frac{\partial}{\partial x} \phi(I_x) = \phi'(I_x) \cdot I_{xx} \quad (11)$$

سپس در نتیجه ی مشاهده تغییر شیب لبه در مقیاس های مختلف زمان؛ اگر  $\partial t(I_x) / \partial t > 0$  تابع  $c$  تابع  $\partial t(I_x) / \partial t$  صاف است و ترتیب اختلاف‌ها ممکن است معکوس شود [۲۵]:

$$\frac{\partial}{\partial t} (I_x) = \frac{\partial}{\partial x} (I_t) = \frac{\partial}{\partial x} \left( \frac{\partial}{\partial x} \phi(I_x) \right) \quad (12)$$

$$= \phi'' \cdot I_{xx} + \phi' \cdot I_{xxx}$$

فرض کنید لبه به گونه ای باشد که  $I_x > 0$  و در نقطه عطف  $I_{xx} = 0$  و  $I_{xxx} \ll 0$  زیرا در نقطه عطف برابر با شکل (۴) بیشترین شیب را دارد و همچنین در همسایگی نقطه عطف  $\partial / \partial t(I_x)$  علامت عکس  $\phi(I_x)$  را دارد. اگر  $\phi(I_x) > 0$  (شیب لبه با گذشت زمان کاهش می‌یابد و بر عکس اگر  $\phi(I_x) < 0$  شیب لبه با گذشت زمان افزایش می‌یابد. توجه کنید که این افزایش شیب نمیتواند ناشی از مقیاس گذاری مرزها باشد، زیرا این امر اصل حداکثری را نقض میکنند در نتیجه لبه تیزتر میشود [۲۵].


چندین گزینه ممکن برای  $\phi$  (°) وجود دارد، به عنوان مثال  $g(I_x) = C / (1 + (I_x/K)^{1+a})$  و  $a > 0$  با توجه به شکل (۵).

#### ۴- روش انجام کار

مراحل انجام تحقیق بطور خلاصه در روند نمای ۱ ارایه شده است. همانطور که مشاهده میشود، الگوریتم ADNN بر روی تصاویر ماهواره ای با و بدون استفاده از اطلاعات بافت تصویر (بدست آمده از اعمال الگوریتم تبدیل موجک) به کارگیری شده است (بخش A و B در روند نمای ۱).

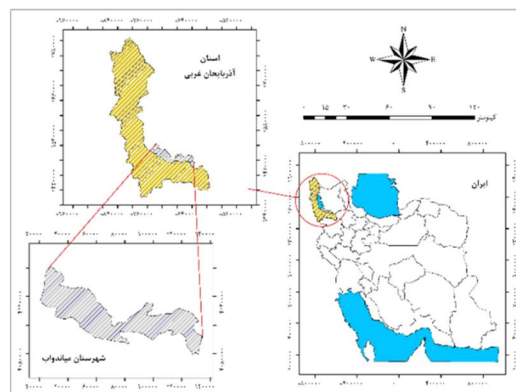
اغلب مراحل ذکر شده در روند نمای ۱ در نرم افزار PCI-GEOMATICA بر مبنای تحقیقات انجام گرفته توسط رایت [۲۵] و [۳۴]، [۳۳] انجام پذیرفت. تصاویر اخذ شده چند طیفی (منطبق شده با اندازه پیکسل یکسان)، به ابعاد ۲۰۴۸ در ۲۰۴۸ بعنوان ورودی به افزونه Unsupervised Texture Segmentation (AVG) در این نرم افزار معرفی شده و بعد از تنظیم پارامترهای ورودی و انتخاب باندهای مناسب جهت استخراج بافت، عملیات ایجاد تصاویر سطوح مختلف الگوریتم ADNN، انجام پذیرفت. در اینجا، باندهای ۲، ۳، ۴، ۵ و ۶ تصاویر لندست ۸ به عنوان تصویر اصلی و باند ۷ آن به منظور استخراج تصویر بافت با استفاده از تبدیل موجک انتخاب شدند. آنالیز بافت از طریق تبدیل موجک، با استفاده از افزونه MAL انجام پذیرفت.

در نهایت، خروجی شبکه عصبی انتشار ناهمسانگرد در پنج سطح به دست آمد شکل ۸ و ۹ نشان دهنده خروجیهای این پنج سطح الگوریتم ADNN به ترتیب با به کارگیری تصویر بافت و بدون به کارگیری آن می باشد.



شکل ۸- خروجی طبقه بندی ۵ سطحی الگوریتم شبکه عصبی انتشار ناهمسانگرد (ADNN) بر روی تصویر لندست ۸ با بهره گیری از اطلاعات طیفی و بافت

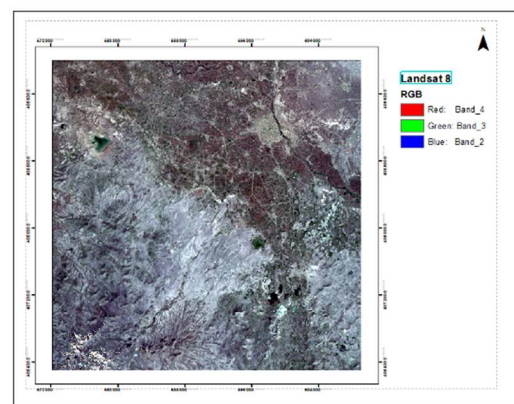
این منطقه در فاصله ۱۶۴ کیلومتری از ارومیه و در جنوب استان قرار دارد. مساحت تقریبی این منطقه ۲۶۹۴ کیلومتر مربع است و در طول جغرافیایی ۴۶ درجه و ۶ دقیقه شرقی از نصف النهار گرینویچ و در عرض جغرافیایی ۳۶ درجه و ۵۸ دقیقه شمالی از خط استوا واقع شده است. منطقه میاندوآب در وسط جلگه های منتهی به دریاچه ارومیه و با ارتفاع ۱۳۱۴ متر از سطح دریا قرار دارد.




شکل ۶- موقعیت منطقه میاندوآب در استان آذربایجان غربی کشور ایران

#### ۳-۲- داده ها

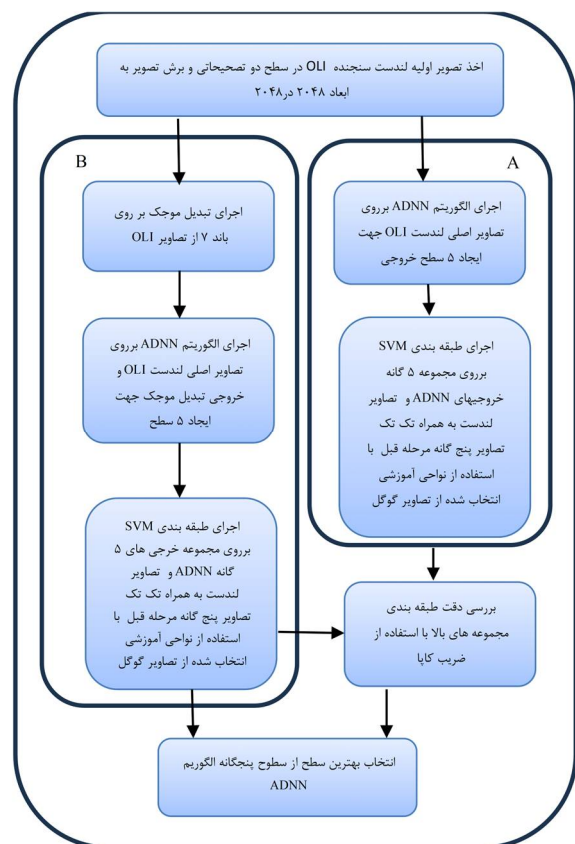
در این پژوهش از دو نوع تصویر از منطقه میاندوآب با سنجنده های مختلف برای بررسی الگوریتم استفاده شده است. تصویر ماهواره ای لندست ۸ در سطح ۲ که مربوط به تاریخ ۲۰ اسفند ۱۴۰۰ می باشد مورد استفاده قرار گرفته است. بر روی این تصویر، تصحیحات اتمسفری و رادیومتریک انجام شده است. این تصویر سپس برای استخراج نقشه بافت و طبقه بندی به کار گرفته شده اند.



شکل ۷- تصویر لندست ۸ ترکیب باند های FCC (باند ۴و۳و۲) اخذ شده در تاریخ ۱۴۰۰/۱۲/۲۰ از منطقه مورد مطالعه



شکل ۹- خروجی طبقه بندی ۵ سطحی الگوریتم شبکه عصبی انتشار ناهمسانگرد (ADNN) بر روی تصویر لندست ۸ با بهره گیری از اطلاعات طیفی و بدون اطلاعات بافت



روند نمای ۱- مراحل انجام تحقیق

همانطور که شکل ۸ و ۹ مشاهده می‌شود، خروجی الگوریتم ADNN شامل طبقه‌بندی و جدا سازی عوارض نمی‌شود. با توجه به اینکه این الگوریتم طبقه‌بندی انجام نمی‌دهد و رویکرد آن بیشتر شبیه به فیلتر کردن تصاویر و آنالیز مولفه های اصلی (PCA) است، برای مقایسه آن، خروجی هر سطح از الگوریتم در هر دو مرحله A, B روندنمای 1 با باندهای تصویر اصلی همراه شده تا مجموعه ای از باندهای اصلی ماهواره ای و هر یک از تصاویر سطوح پنج گانه شکل ۸ و ۹ تشکیل شود. سپس برای طبقه‌بندی

تصاویر در چهار کلاس خاک، آب، گیاه و منطقه شهری، از الگوریتم SVM (ماشین بردار پشتیبان) استفاده شد. همچنین جهت مقایسه نتایج بروی مجموعه مجزای خروجی های پنجگانه الگوریتم ADNN طبقه بندی SVM انجام گرفت (اشکال ۱۰ و ۱۱). جهت برآورد میزان صحت طبقه بندی‌ها فوق، از تعداد ۴۶۱ نمونه های آموزشی برداشت شده از تصاویر همزمان و با وضوح بالای گوگل ارث استفاده شد.

جدول ۱ و ۲ نشان‌دهنده میزان ضریب توافق کاپا برای مجموعه های تصاویر به کار گرفته شده به همراه تصاویر سطوح مختلف الگوریتم ADNN و مجموعه ۵ گانه منتج شده از ADNN در دو حالت با و بدون بهره گیری از تصویر تبدیل موجک است.

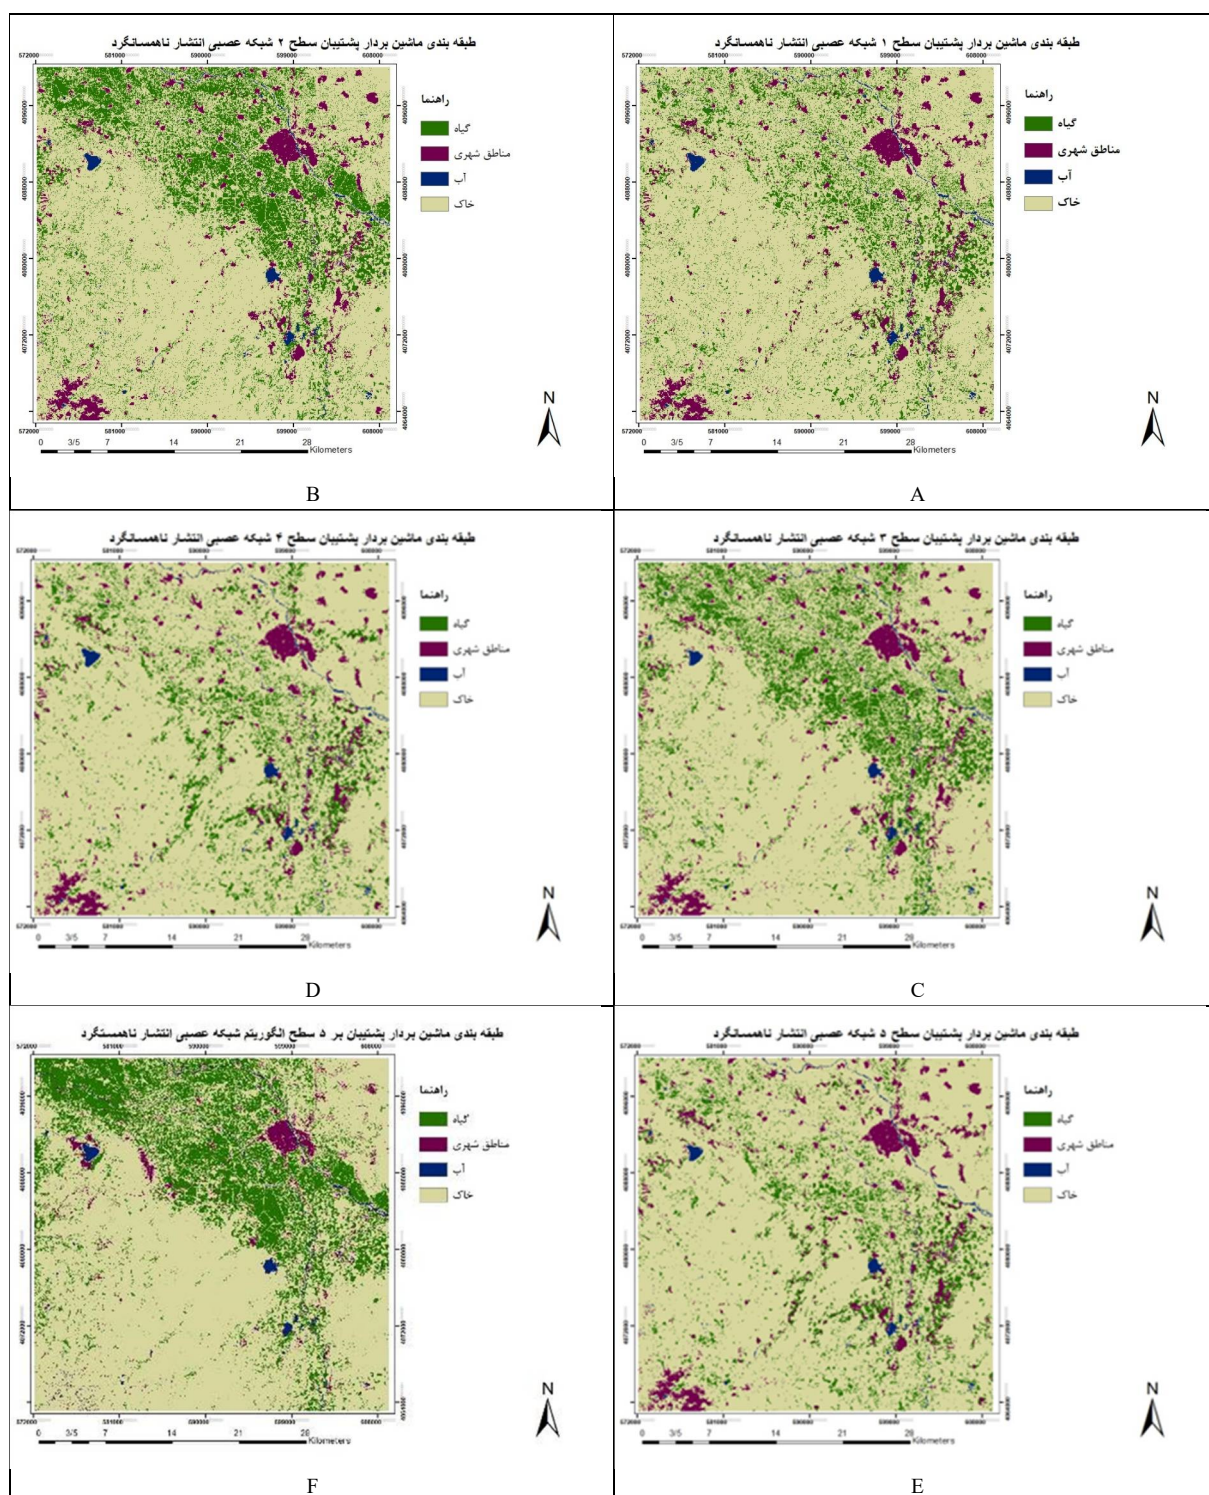
جدول ۱- ضریب کاپای طبقه بندی مجموعه داده های تصاویر به همراه تصاویر سطوح پنجگانه ADNN بدون اعمال تبدیل موجک

مجموعه داده‌ها	ضریب کاپا خروجی‌های SVM
سطح ۱	۰.۸۴
سطح ۲	۰.۸۶
سطح ۳	۰.۸۰
سطح ۴	۰.۷۶
سطح ۵	۰.۶۳
مجموعه همه پنج سطح ADNN	۰.۶۹

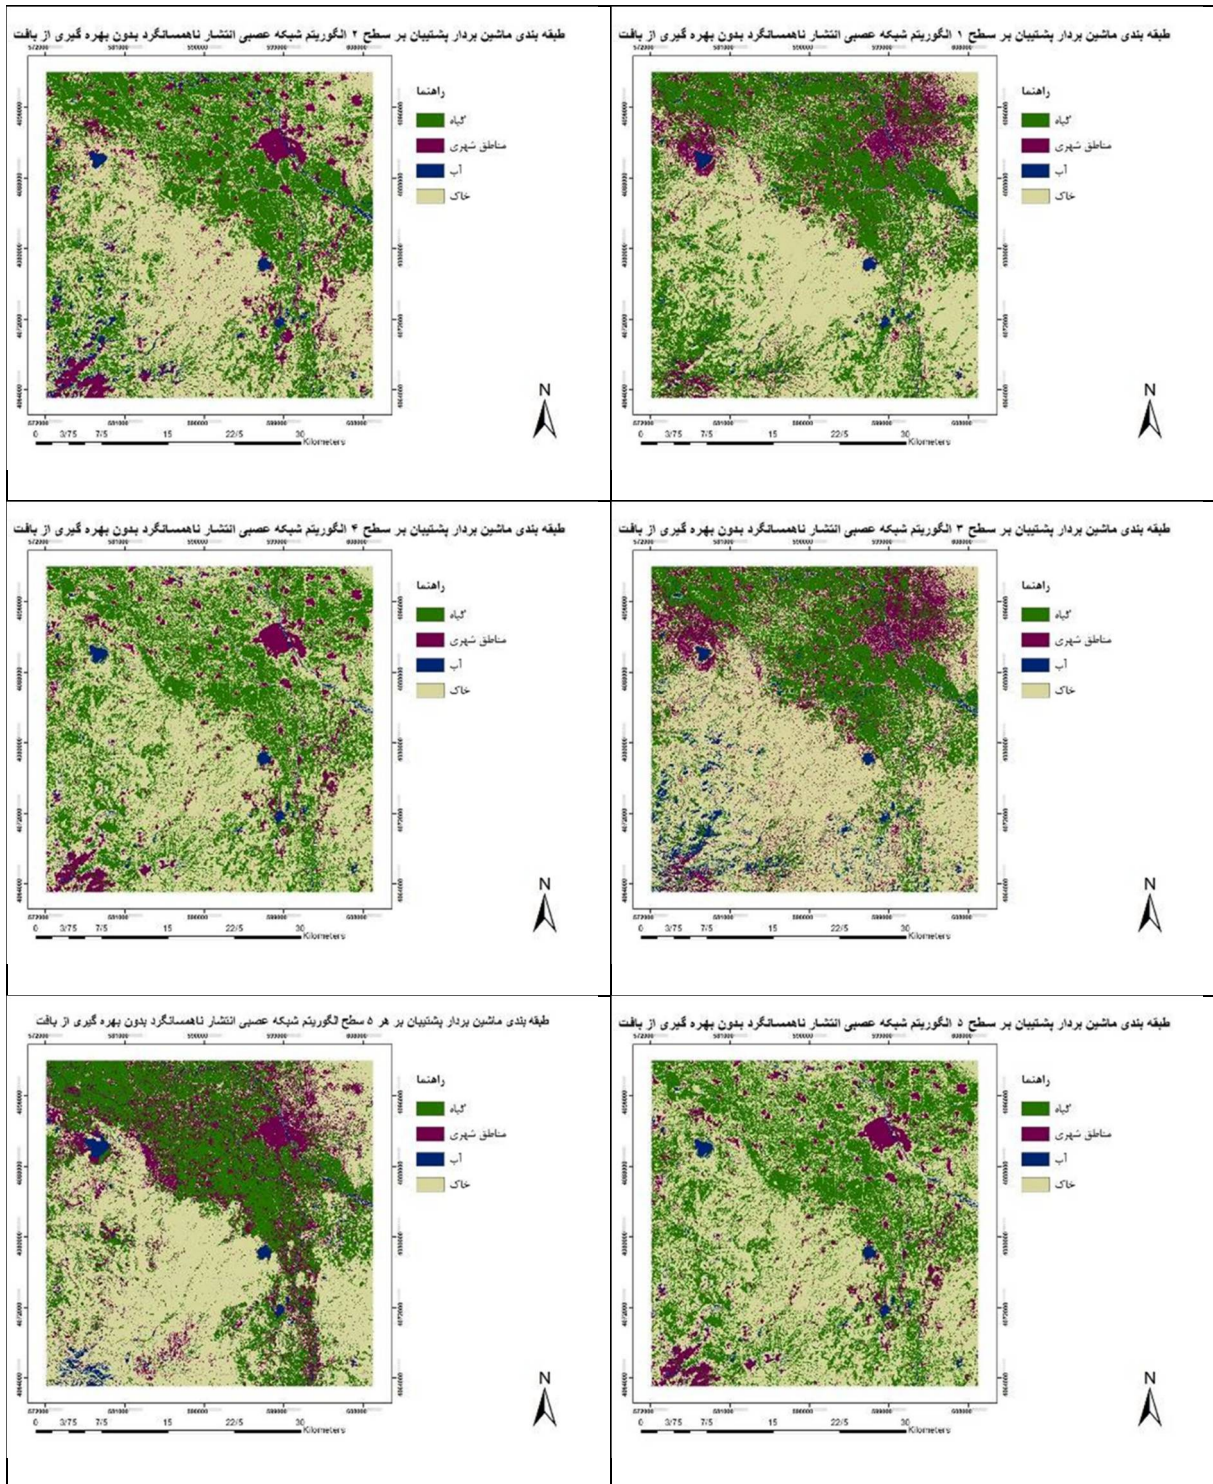
جدول ۲- ضریب کاپای طبقه بندی مجموعه داده های تصاویر به همراه تصاویر سطوح پنجگانه ADNN با اعمال تبدیل موجک

مجموعه داده‌ها	ضریب کاپا خروجی‌های SVM
سطح ۱	۰.۸۸
سطح ۲	۰.۸۹
سطح ۳	۰.۸۵
سطح ۴	۰.۸۲
سطح ۵	۰.۷۲
مجموعه همه پنج سطح ADNN	۰.۸

همانگونه که در جدول ۱ و ۲ مشاهده میشود، خروجی الگوریتم ADNN در سطح ۲ (ابعاد تصویری ۱۰۲۴ در ۱۰۲۴) با کاپای طبقه‌بندی ۰.۸۹ و ۰.۸۶، صحت بالاتری نسبت به سایر سطوح دارد.



شکل ۱۰- نتیجه طبقه بندی ماشین بردار پشتیبان بر مجموعه داده ای متشکل از تصویر اصلی لندست ۸ به همراه خروجیهای الگوریتم ADNN بدون اعمال الگوریتم موجک و طبقه بندی شبکه SVM بر خروجیهای هر ۵ سطح تبدیل ADNN لندست ۸. تصویر اصلی لندست ۸ به همراه: سطح ۱ (A)، سطح ۲ (B)، سطح ۳ (C)، سطح ۴ (D)، سطح ۵ (E) و نتیجه طبقه بندی SVM بر خروجیهای هر ۵ سطح تبدیل ADNN لندست ۸ (F).




شکل ۱۱- نتیجه طبقه بندی ماشین بردار پشتیبان بر مجموعه داده ای متشکل از تصویر اصلی لندست ۸ به همراه خروجیهای الگوریتم ADNN منتج از اعمال الگوریتم موجک و طبقه بندی SVM بر خروجیهای هر ۵ سطح تبدیل ADNN لندست ۸  
تصویر اصلی لندست ۸ به همراه: سطح ۱ (A) ، سطح ۲ (B) ، سطح ۳ (C) ، سطح ۴ (D) ، سطح ۵ (E) ، نتیجه طبقه بندی SVM بر خروجیهای هر ۵ سطح تبدیل ADNN لندست ۸ (F).

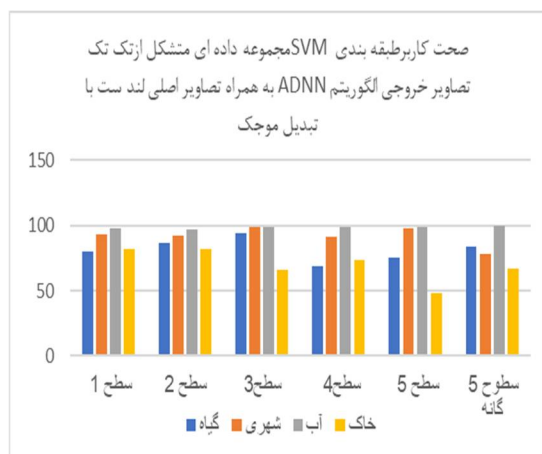
خاص، اگر تصویر اولیه دارای ابعاد  $512 \times 512$  پیکسل باشد، خروجی سطح اول شبکه همان اندازه تصویر اصلی خواهد بود. در سطح دوم، اندازه تصویر به  $256 \times 256$

حتی مجموعه همه پنج سطح حاصل از الگوریتم ADNN نتوانسته کاپایی بیشتر از ۰.۸ را بخود اختصاص دهد و در رده پنجم ( یکی مانده به آخر) قرار گرفته است. به طور

به سایر مجموعه های داده ای برای مجموعه های با و بدون بهره گیری از تبدیل موجک موفق تر عمل کرده است.



شکل ۱۲- نمودار صحت کاربر طبقه بندی SVM مجموعه داده ای متشکل از تک تصاویر خروجی الگوریتم ADNN به همراه تصاویر اصلی لندست بدون اعمال تبدیل موجک



شکل ۱۳- نمودار صحت کاربر طبقه بندی SVM مجموعه داده ای متشکل از تک تصاویر خروجی الگوریتم ADNN به همراه تصاویر اصلی لندست با اعمال تبدیل موجک

## ۵- نتیجه گیری

در مقالات داخلی و خارجی، استفاده از این الگوریتم در طبقه بندی تصاویر سنجش از دور به طور قابل توجهی صورت نگرفته است. به عنوان مثال، در تحقیقات پیشین، تنها از تبدیل موجک و شبکه عصبی بر انتشار ناهمسانگرد برای آشکارسازی تغییرات استفاده شده است. همچنین الگوریتم بخش بندی سوپر میزان مبتنی بر انتشار ناهمسانگرد (ADS) به منظور بهبود دقت مرز سوپر میزان ها و تصحیح انحرافات مرزی در تصاویر پیچیده سنجش از دور معرفی شده است. تاکنون مقایسه صحت این الگوریتم در پژوهش های مشابه

پیکسل کاهش می یابد و سطوح بعدی به همین ترتیب با ضرایب توان دو کوچک تر می شوند (در این حالت، سطح اول باید  $2048 \times 2048$  پیکسل باشد). با همراه کردن خروجی تبدیل موجک، صحت کلی و ضریب توافق کاپا افزایش یافته و بهترین سطح شبکه ADNN، در هر دو حالت با و بدون همراه کردن خروجی تبدیل موجک به مجموعه داده ها، سطح ۲ شبکه ADNN بوده و بیشترین کاپای طبقه بندی ها را به خود اختصاص داده است.

همان طور که در شکل های ۸ و ۹ مشاهده می شود، سطح اول تصاویر دارای نویز (لکه) زیادی است و در مقیاس سوم به بعد، جزئیات از بین رفته اند. به این ترتیب، می توان نتیجه گرفت که مناسب ترین سطح برای انجام طبقه بندی، تصویر خروجی سطح دوم می باشد.

## ۴- ارزیابی

تشخیص و جدا سازی عوارض در هر سطح با توجه به تعریف صحت کاربر، که احتمال طبقه بندی یک کلاس خالص مطابق با همان کلاس در نقشه واقعیت زمینی را بیان می کند، در این بخش به بررسی اینکه کدام سطح از شبکه در تشخیص و جداسازی عوارض مختلف تا چه میزان موفق عمل کرده است پرداخته میشود. همچنین بررسی میشود که در تشخیص عوارض شاخص، کدام سطح ها بهتر عمل کرده اند. با توجه به نمودار شکل ۱۲ و ۱۳، خروجی طبقه بندی در سطح ۲ شبکه عصبی انتشار ناهمسانگرد بدون اعمال تبدیل موجک در تشخیص مناطقی با پوشش گیاهی صحت ۹۰.۸ درصد، موفق تر از سایر سطوح بوده است. این در حالیست که سطح سوم همین الگوریتم با اعمال تبدیل موجک با کاپای ۹۳.۷۵ برای به نقشه در آوردن گیاه بهتر عمل کرده است.

همچنین، در تشخیص و طبقه بندی مناطق شهری، سطوح ۳ و ۵ با و بدون به کار گیری تبدیل موجک به ترتیب با کاپای ۹۱.۸۲ و ۹۸.۹۴ درصد نسبت به سایر سطوح عملکرد بهتری داشته است.

در تشخیص آب، به کار گیری همه خروجی های پنجگانه الگوریتم ADNN در هر دو حالت با و بدون بهره گیری از تبدیل موجک با کاپای ۱۰۰ درصد بهترین گزینه شناسایی میشود. در تشخیص مناطق با عارضه خاک نیز، سطوح ۱ و ۲ با کاپای ۸۱.۵۵ و ۷۹.۵۱ درصد نسبت

بررسی نشده است. این امر نوآوری این پژوهش را در کاربرد الگوریتم شبکه عصبی انتشار ناهمسانگرد برای بهبود صحت طبقه‌بندی تصاویر ماهواره‌ای تایید می‌کند. جهت تایید نتایج فوق، مراحل موجود در روند نمای ۱ بر روی داده‌های سنتینل ۲ نیز انجام گرفت. نتایج نشان داد که در تصویر سنتینل ۲، طبقه‌بندی ماشین بردار پشتیبان بر روی سطح ۲ شبکه عصبی انتشار

ناهمسانگرد با کاپای ۰.۸۳ نسبت به شبکه عصبی مصنوعی که کاپای ۰.۸۲ داشت، عملکرد بهتری را نشان داده است. با توجه به نمودارهای صحت کاربر در این مطالعه می‌توان نتیجه گرفت که الگوریتم شبکه عصبی انتشار ناهمسانگرد در تشخیص آب عملکرد بسیار خوبی داشته و می‌توان از آن در پژوهش‌های مرتبط با تشخیص پهنه‌های آبی و خطوط ساحلی بهره برد.

## مراجع

- [۱] A. Ehsani, and M. Shakeryari, "Determining the optimal method of land use classification and mapping by comparing artificial neural network algorithms and support vector machines using satellite data (Case study: Hamoon International Wetland)", *Environmental Science and Technology*, Volume 20, 2018 [Persian].
- [۲] S. Nixon, Mark, and S. Aguado Alberto, "Feature Extraction and Image Processing", *Academic Press, Elsevier Ltd.*, 2000.
- [۳] D. Lu, , and Q. Weng, "A survey of image classification methods and techniques for improving classification performance", *International Journal of Remote Sensing*, 28(5), 823-87, 2007, <https://doi.org/10.1080/01431160600746456>.
- [۴] K. Zhang, Y. Chen, W. Wang, Y. Wu, B. Wang, and Y. Yan, "A method for remote sensing image classification by combining Pixel Neighborhood Similarity and optimal feature combination", *Geocarto International*, VOL. 38, NO. 1, 2158948, 2023, <https://doi.org/10.1080/10106049.2022.2158948>.
- [۵] M. Pasternak, and K. Pawluszczak-Filipiak, "The Evaluation of Spectral Vegetation Indexes and Redundancy Reduction on the Accuracy of Crop Type Detection", *Appl. Sci.*, 12, 5067, 2022, <https://doi.org/10.3390/app12105067>.
- [۶] P. Zeaieanfiroozabadi, and M. Salahian, , "Introducing Shape Descriptors of Spectral Reflectance Curve (DSRC) for Improving Image Classification Accuracy", *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, X-5/W2-2025, 725-731, 2025, <https://doi.org/10.5194/isprs-annals-X-5-W2-2025-725-2025>, 2025.
- [۷] J. Bendiktsson, E. Swain, and O. Ersoy, , "Neural network approaches versus statistical methods on classification of multisource remote sensing data". *IEEE Transactions on Geoscience and Remote Sensing*, 28, 540-552, 1990
- [۸] G. Carpenter, and S. Grossberg, "A massively parallel architecture for a self-organizing neural pattern recognition machine", *Computer Vision, Graphics, and Image Processing*, 37, 54-115, 1987.
- [۹] G. Carpenter, and S. Grossberg, "ART2: Self-organization of a stable category recognition codes for analog input patterns", *Applied Optics*, 26, 4919-4930, 1987.
- [۱۰] G. Carpenter, and S. Grossberg, "ART3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures", *Neural Networks*, 3(2), 129-152, 1990.
- [۱۱] G. Carpenter, and S. Grossberg, "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system", *Neural Networks*, 4, 759-771, 1991.
- [۱۲] G. Carpenter, S. Grossberg, and D. Rosen, "Fuzzy-ART: An adaptive resonance algorithm for rapid, stable classification of analog patterns", *International Conference on Neural Networks*, pp. 416, Seattle, WA, USA, 1991.
- [۱۳] J. Favela, J. Torres, H. Hidalgo, and R. Granillo, "Loadbalancing for the neural network classification of remote sensing data in an heterogeneous network of workstations", *Proc. 7th International Conference on Parallel and Distributed Processing*, pp. 302-307, Las Vegas, NA, USA, 1994.
- [۱۴] S. Grossberg, "Studies of Mind and Brain. Boston", *Reidel, MA: D.*, 1982.
- [۱۵] Y. Hara, R. Atkins, S. Yueh, , R. Shin, and J. Kong, "Application of neural networks to radar image classification". *IEEE Transactions on Geoscience and Remote Sensing*, 32(1), 10-109, 1994.

- [۱۶] E. Heermann, and N. Khazenie, "Classification of multi-spectral remote sensing data using a back-propagation neural network", *IEEE Transactions on Geoscience and Remote Sensing*, 30(1),81-8, 1992.
- [۱۷] G. Hepner," Artificial neural network classification using a minimal training set: comparison to conventional supervised classification", *Photogrametric Engineering and Remote Sensing*, 56(4), 469-473, 1990.
- [۱۸] Y. Pao, " Pattern Recognition and Neural Networks", *Addison-Wesley, Reading, MA*, 1989.
- [۱۹] J. Richards, " Remote Sensing Digital Image Analysis", *Springer-Vedag, New York, NY*, 1986.
- [۲۰] J. Tones, "Application of Remote Sensing for the recognition of geomorphic units in the Colorado River Delta", *M.Sc. Thesis, Universidad Autonoma de Baja California, Mexico*, 1994 [in Spanish].
- [۲۱] Y.Wang, R. Niu, and X. Yu, "Anisotropic Diffusion for Hyperspectral Imagery Enhancement. " *IEEE Sens J.*, 10(3):469-77, 2010.
- [۲۲] R.A. Fernandesl, and M.E. Jernigan," Unsupervised Segmentation of Multi-Level Multispectral Images", *Neural Networks for Signal Processing II Proceedings of the 1992 IEEE Workshop*. pp. 363-372, 1992.
- [۲۳] J. Daryaei, "Digital Change Detection Using Multi-scale Wavelet Transformation & Neural Network", *MSC Thesis. In International Institute for Aerospace survey and Earth Sciences(ITC)* , 2003.
- [۲۴] H. Richmond, "PCI Geomatics User's Guide. " *Ontario, Canada*, 2008.
- [۲۵] P. Perona, and J. Malik, "Scale-space and edge detection using anisotropic diffusion. " *IEEE Trans Pattern Anal Mach Intell.*, 12(7):629-39, 1990
- [۲۶] A.P. Witkin, "Scale-Space Filtering", *International Joint Conference on Artificial Intelligence*, 2, 1019-1021, 1983.
- [۲۷] J. Canny,"A Computational Approach to Edge Detection. " , *IEEE Trans Pattern Anal Mach Intell*, 1986.
- [۲۸] M. Lenone, , G. Mercier. and L. Hubert-Moy, "Nonlinear filtering of hyperspectral images with anisotropic diffusion". *IEEE International Geoscience and Remote Sensing Symposium*, 2018.
- [۲۹] K. Pope, and S.T. Actone," Modified mean curvature motion for multispectral anisotropic diffusion", *IEEE Southwest Symposium on Image Analysis and Interpretation*, 1998.
- [۳۰] Y. Wang, L. Zhang. and P. LI, " Nonlinear multispectral anisotropic diffusion filters for remote sensed images based on MDL and morphology", *IEEE International Geoscience and Remote Sensing Symposium*, 2005.
- [۳۱] B. Smolka, and R. Lukac, "On the combined forward and backward anisotropic diffusion scheme for the multispectral image enhancement" , *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2002.
- [۳۲] Z. Guo, J. Sun., D. Zhang. and B. Wu, "Adaptive Perona-Malik Model Based on the Variable Exponent for Image Denoising", *IEEE Transactions on Image Processing. a Publication of the IEEE Signal Processing Society*. 2012 Mar;21(3):958-967. DOI: 10.1109/tip.2011.2169272. PMID: 21947525, 2011.
- [۳۳] G. Wright, "Feature Selection For Texture Discrimination", *M.A.Sc. Thesis, Department of Systems Design, University of Waterloo, Canada*, 1988
- [۳۴] S. Mallat, "A Theory of Multiresolution Signal Decomposition: the Wavelet Representation" , *IEEE Trans. PAMI*, Vol. II, No. 7, pp. 572-693,1989.