

علوم و تکنولوژی محیط زیست، دوره بیست و چهارم، شماره نه، آذرماه ۱۴۰۱ (۱۲۶-۱۱۳)

توسعه و ارتقاء روش های طبقه بندی الگوریتم شبکه عصبی و شاخص پوشش جنگلی (FCD) در داده ماهواره ای با وضوح بالا GEOEYE. (مطالعه موردی: جنگل های هیرکانی رامسر-صفاورد)

امین مهدوی سعیدی^۱

ساسان بابایی کفاکی^{۲*}

babaie.rs.s@gmail.com

اسدالله متاجی^۲

تاریخ پذیرش: ۱۴۰۰/۸/۲۶

تاریخ دریافت: ۱۴۰۰/۵/۷

چکیده

زمینه و هدف: با عنایت به وضوح مکانی بالای داده های Geoeye، به دلیل توزیع گسترده تر پیکسل ها، نقشه های خروجی در دو روش طبقه بندی الگوریتم شبکه عصبی و شاخص پوشش جنگلی (FCD)، حساس تر و با جزئیات پیکسلی بیشتر همراه هستند. با توجه به حجم زیاد اطلاعات در سنسورهای جدید، هدف این مطالعه توسعه و ارتقاء عملکرد الگوریتم های طبقه بندی پیچیده تر، برای تفسیر داده های ماهواره ای مدرن است.

روش بررسی: طبقه بندی مدل پایه FCD براساس چهار شاخص اصلی، حساس به سایه، خاک بدون پوشش، شرایط و تراکم پوشش گیاهی، و بدون نیاز به نمونه تعلیمی، عمل می نماید. الگوریتم شبکه عصبی با حساسیت بالایی نسبت به باندهای تصویر اصلی و باندهای ایجاد شده و اضافه شده به تصویر و همچنین نمونه آموزشی معرفی شده، عمل می کند. نمونه های تعلیمی، تابستان ۱۳۹۵ و ۹۶ در سری ۵ و ۶ حوزه آبخیز ۳۰ رامسر، بررسی گردیدند.

یافته ها: با استفاده از روش یاد شده دقت ۲۴/۵٪ برای روش FCD و ۲۶/۲٪ برای روش شبکه عصبی بدست آمده است. با توجه به اینکه داده های استفاده شده از وضوح بالایی برخوردارند، نقشه خروجی در این روش توسعه یافته، با تراکم بالای پولی گون ها همراه است. بحث و نتیجه گیری: با توجه به دامنه ظهور پیکسل ها در نقشه های خروجی دو روش یاد شده، روش توسعه یافته ای برای تولید نقشه دقیق تر، با توجه به قدرت تفکیک مکانی زیاد سنجنده Geoeye، ارائه شده است. در این روش با طبقه بندی مجدد در محدوده حداکثر فراوانی پیکسل ها، مرزبندی پولی گون ها در ابعاد بسیار کوچکتر و دقیق تر قابل ملاحظه است.

واژه های کلیدی: داده وضوح بالا، شبکه عصبی، FCD، Density Slice، مراحل تحولی.

۱- دانشجوی دکترای جنگلداری. دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

۲- استاد گروه جنگلداری. دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. * (مسئول مکاتبات)

Development and Improvement of Neural network algorithm and forest cover index (FCD) classification methods in GEOEYE high resolution satellite data.

(Case study: Ramsar-Safarood Hyrcanian forests)

Amin Mahdavi Saeidi¹

Sasan Babaie Kafaky^{2*}

babaie.rs.s@gmail.com

Asadollah Mataji²

Admission Date: November 17, 2021

Date Received: July 29, 2021

Abstract

Background and Objective: Due to the high spatial resolution of Geoeeye data, due to the wider distribution of pixels, the output maps in Neural network algorithm and Forest cover index (FCD) classification methods are more sensitive and with more pixel detail. Considering the large amount of information in new sensors, the aim of this study is to develop and improve the performance of more complex classification algorithms for the interpretation of modern satellite data.

Material and Methodology: FCD model base classification is based on four main indicators: sensitive to shadow, uncovered soil, vegetation conditions and density, and without the need for a training sample. The Neural network algorithm operates with high sensitivity to the original image bands and the bands created and added to the image, as well as training samples. Training samples were determined in the summer of 2016-2017 from series 5 and 6 of 30 Ramsar watersheds.

Finding: Using this method, an accuracy of 24.5% was obtained for the FCD method and 26.2% for the Neural network method. Due to the high resolution of the data used, the output map developed in this method is associated with a high density of polygons.

Discussion & Conclusion: Due to the range of pixels in the output maps of the two methods, an extended method has been proposed to produce a more accurate map, due to the high spatial resolution of the Geoeeye sensor. In this method, by reclassifying within the maximum frequency range of pixels, the demarcation of polygons in much smaller and more accurate dimensions is considerable.

Keywords: High Resolution Data, Neural Network, FCD, Density Slice, Development Stages.

1- PhD Student. Department of Forestry, Faculty of Natural Resources and Environment, Science and Research Branch, Islamic Azad University, Tehran, Iran.

2- Professor. Department of Forestry, Faculty of Natural Resources and Environment, Science and Research Branch, Islamic Azad University, Tehran, Iran. **(Corresponding Author)*

مقدمه

از یک نقطه به زاویه دید، فاصله از نقطه نادیر و سایر متغیرها بستگی دارد (۱۲).

بر این اساس، استفاده از روشهای مدرن طبقه بندی داده های ماهواره ای، مانند الگوریتم شبکه عصبی، که با حساسیت بالایی نسبت به ترکیب باند تصویر کار می کند و روش FCD، که بر اساس شاخص های خاص، بدون وابستگی به نمونه های تعلیمی تولید می شود، می تواند در نظر گرفته شود.

اصولاً ماهواره های با وضوح بالا، به دلیل پوشش تکرار تصویر زیاد و وضوح بالا، عملاً برای ر صد آنچه در سطح زمین اتفاق می افتد و دسترس به آن دشوار است، استفاده می شوند. شاخص های سنجنش از دور در این پژوهش باید در محدوده طیفی سنسورهای ۴ باند اصلی Geoeye با قدرت تفکیک مکانی زیاد تعریف شوند. در سال ۲۰۱۱ وینا و همکاران (۱۳)، طیف وسیعی از پهنای باند طیفی را در سنسورهای مختلف مدنظر قرار داده و الگوریتم هایی را ارائه نمود که نمایانگر انواع مختلف شاخص های گیاهی برای هر نوع سنسور می باشد. کاربرد فناوری سنجنش از دور می تواند با در نظر گرفتن پدیده ای در مقابل پدیده ای دیگر به الگوهایی دست یابد که بر اثرات و پدیده ها در جغرافیای تصویر حاکم هستند. تفسیر بصری که توسط کاربر سنجنش از دور به عنوان اولین مرحله از طبقه بندی در نظر گرفته می شود، در واقع محصول حضور هر یک از پدیده ها در محورهای فضایی اقلیدسی است. در این فضا خوشه هایی از نقاط وجود دارد، در هر یک از آنها تراکم زیادی از نقاط وجود دارد. این خوشه ها الگوهای دقیق هر پدیده ای را در سطح زمین نشان می دهند. بعضی نقاط وجود دارد که در هیچ یک از خوشه ها قرار ندارد و از الگوهای معمول حذف می شود. درجه تفکیک خوشه ای با توجه به فاصله بین دو مرکز خوشه ای و توزیع نقاط بین آن مراکز تخمین زده می شود.

واکنش متقابل طیف های الکترومغناطیسی و عوارض و پدیده های مختلف در سطح زمین منشأ کشف و تمایز پدیده های موجود در تصویر است. شناخت و استفاده مناسب از باندهای طیفی تصاویر ماهواره ای و طبقه بندی دقیق این تصاویر، علاوه

سنجنش از دور در طیف گسترده ای از زمینه های علمی و پژوهشی عمل میکند. این فناوری علاوه بر افزایش سرعت تحقیق، از نظر دقت، زمان و هزینه نیز موثر است. تصاویر سنجنش از دور دارای قابلیت های زیادی هستند از جمله موارد زیر: تصویربرداری در مناطق مختلف طیف الکترومغناطیسی شامل مرئی، مادون قرمز، میکروویو. دید گسترده ای را برای مطالعه پدیده های بزرگ فراهم می کند (به ویژه پدیده هایی که در عکس های هوایی قابل تشخیص و دسترس نیستند). تکرار زمانی و تنوع وضوح مکانی و طیفی داده ها در تناسب با اهداف مطالعه مورد توجه است (۶-۱). ماهواره های رصدی زمین طیف گسترده ای از اطلاعات را با وضوح مکانی، زمانی، طیفی و رادیومتریک ارائه می دهند. این داده ها و باندهای طیفی از طریق تکنیک های مختلف، از جمله شاخص های پوشش گیاهی و تلفیق داده ها (data fusion)، در مطالعات مختلف مورد استفاده قرار گرفته اند (۷، ۸).

از داده های سنجنش از دور دیجیتال می توان برای به روزرسانی پایگاه داده آماری جنگل استفاده کرد. امروزه با توسعه سنجنش از دور و دستیابی به داده های مکانی و طیفی با وضوح بالا و همچنین توسعه حسگرهای فضایی، می توان نقشه های دقیقی از ساختار و ترکیب جنگل تولید کرد (۹). انعکاس طیفی گیاهان با ورود به محدوده مادون قرمز نزدیک افزایش می یابد، در حالی که تفاوت بین گونه های گیاهی در سنجنش از دور نیز عمدتاً به دلیل تفاوت در بازتاب است، که می تواند منجر به شناسایی گونه های گیاهی شود. روش طبقه بندی انتخاب شده به هدف مطالعه و داده های موجود وابسته است (۱، ۳، ۵، ۱۰).

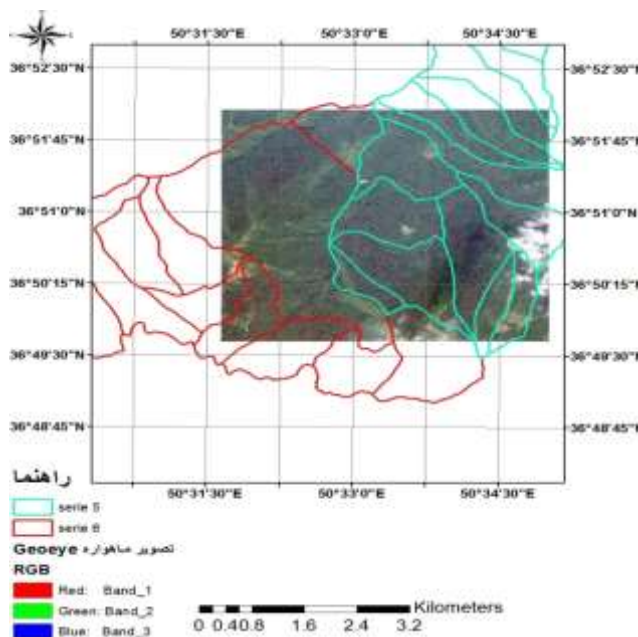
از داده های سنجنش از دور می توان برای افزایش کیفیت پایگاه داده استفاده کرد تا اطلاعات در بازه زمانی بیشتری برای ارتقاء فعالیت های مدیریت منابع فراهم گردد (۱۱). این نوع تشخیص اطلاعات می تواند براساس تفاوت نسبی در بازتاب طیفی یا نوع گیاه باشد. با این حال، باید تصدیق کرد که هیچ طیف انعکاسی ایده آلی برای هر یک از انواع پوشش گیاهی وجود ندارد و تابش

روش بررسی

محدوده مطالعه

منطقه مورد مطالعه در جنگل های هیرکانی، سری های ۵ و ۶ حوزه آبخیز ۳۰رامسر (صفا رود-چالکروود) با مساحت کل ۴۱۰۰ هکتار در حوزه اداره منابع طبیعی رامسر واقع شده و در تابستان ۱۳۹۵ و ۹۶ برای تعیین نمونه های تعلیمی مورد بررسی قرار گرفته است. داده ماهواره ای مورد استفاده، سنجنده Geoeye با وضوح مکانی: ۰/۴۱ متر در باند پانکروماتیک و ۱/۶۵ در تصاویر چندطیفی و خورشید مدار است. ماهواره Geoeye یکی از پیچیده ترین سنسورهای ماهواره های زمین را دارد. سطح پوشش کامل تصویر ماهواره ۳۵۰۰۰۰ کیلومتر مربع است و مدت زمان تکرار آن ۳ روز است. در مقابل کاهش تعداد طیف های تصویر، وضوح مکانی و وضوح رادیومتریکی به طور قابل توجهی افزایش یافته است. ارتفاع مدار این ماهواره ۷۷۰ کیلومتر، (478 MILES) است.

بر نمایش حالت صحیح توده های طبیعی، می تواند برای تهیه نقشه های پیش بینی توده های جنگل های طبیعی نیز مورد استفاده قرار گیرد. در این مطالعه برای تولید نقشه های خروجی دقیق از مجموعه اطلاعات با حجم زیاد داده های با رزولوشن بالا سنجنده GEOEYE، استفاده از خواص الگوریتم های تحلیل شبکه عصبی^۱ در کنار روش FCD مبتنی بر چهار شاخص حساس به سایه^۲ خاک بدون پوشش^۳، شرایط و تراکم پوشش گیاهی^۵ (جدول ۳) مدنظر قرار گرفته و همچنین روش نوینی برای ارتقاء عملکرد این الگوریتم ها بر پایه مفهوم طبقه بندی مجدد و در محیط GIS ارائه شده است.



شکل ۱ - تصویر ماهواره Geoeye، به همراه مرز سری های ۵ و ۶ در حوزه آبخیز ۳۰ رامسر

Figure 1. Geoeye satellite image, along the boundaries of series 5 and 6 in the Ramsar's 30 watershed

عمل می کند، اما در الگوریتم شبکه عصبی، نمونه های آموزشی معرفی شده در محیط نرم افزار Envi، نقش مهمی

مدل طبقه بندی FCD بدون تکیه بر نمونه های آموزشی و بر اساس شاخص های خاص در محیط نرم افزار Geomatica

4- BI
5- AVI, VD

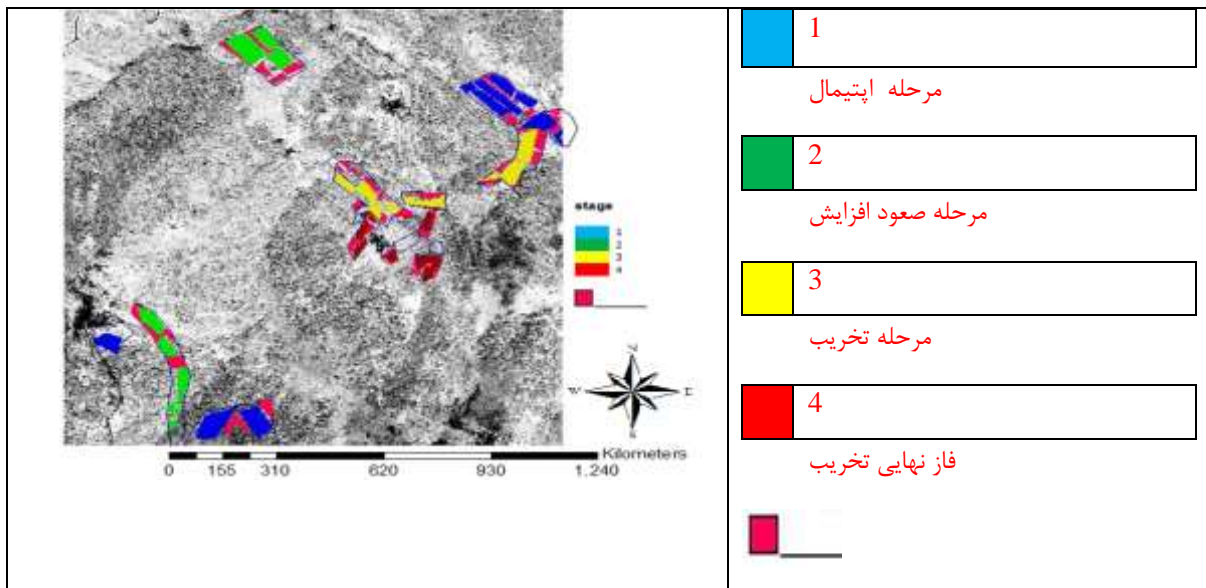
1- Neural Network
2- Forest Canopy Density
3- SI

گزارش های فیزیوگرافی نیز برای تحلیل بهتر وضعیت عرصه مورد توجه قرار گرفت. با بررسی دقیق عرصه های آماربرداری شده، پولی گون های مربوط به مراحل تحولی در نرم افزار GIS ترسیم گردید و نمودارهای مربوط به قطر و ارتفاع نیز مورد بررسی قرار گرفت. پولی گون هایی که دقیق ترین نمودارهای مبین هر یک از مراحل تحولی را ارائه می دادند، برای معرفی نمونه های تعلیمی به کار گرفته شدند. با توجه به ساختار پیکسلی پیچیده عناصر طبیعی موجود در تصویر، که در محل نمونه های تعلیمی این تصویر با وضوح مکانی بالا قرار دارند، می توان انتظار داشت که حجم بالایی از اطلاعات پیکسلی شامل داده های مکانی و طیفی و رادیومتریک در الگوریتم های طبقه بندی وجود داشته باشند. به طور مشابه، شاخص های سنجش از دور که در ادامه بحث خواهد شد با حساسیت بیشتری در این نوع داده های با وضوح بالا عمل می کنند (۱۵).

در عملکرد کلی سیستم شبکه عصبی تعریف شده دارند. بنابراین، هنگام استفاده از این الگوریتم، لازم است که نمونه های آموزشی به دقت تعریف شوند. همانطور که در شکل ۲ نشان داده شده است، نمونه های تعلیمی دقیق از مکان های نشان داده شده در تصویر به نرم افزار ارائه می شوند. هر یک از این نمونه ها یکی از مراحل تکاملی جنگل طبیعی را نشان می دهد.

مطالعات جنگل شناسی _ تعیین مراحل تحولی

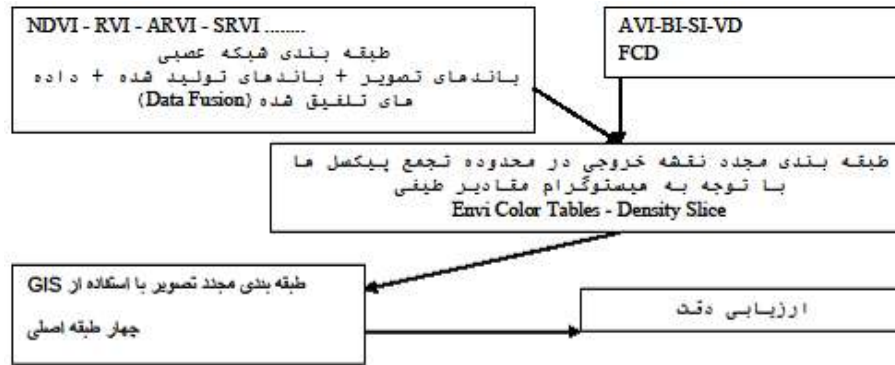
نمونه های تعلیمی بر اساس فهرستی از شاخص های جنگل شناسی، که مبین مراحل تحولی در جنگل های طبیعی هستند (۱۴)، تعیین شده اند. با مراجعه به عرصه جنگلی، مساحتی در حدود ۲۰۰ هکتار مورد آماربرداری قرار گرفت. ۴ شاخص اصلی قطر، ارتفاع، قطرتاج و نوع گونه برداشت گردید. همچنین مشخصه های کلی در عرصه مانند حفره های زادآوری و برخی



شکل ۲- نمونه های تعلیمی برای تعیین مراحل تحولی همراه با پولی گون های تعیین دقت - نمایش داده شده بر شاخص

NDVI

Figure 2. Learning samples to determine the Development stages with accuracy polygons -displayed on the NDVI index



شکل (فلوچارت) ۳ - عملیات توسعه سنجش از دور

Figure 3. Remote Sensing Development Operation

شاخص های طیفی اعمال شده

جدید به تصویر اضافه می شوند و در طبقه بندی تصویر به کار می روند.

شاخص های تولید شده در محیط نرم افزار Geomatica علاوه بر عملکرد تفکیک و تشخیص پدیده ها، به عنوان باندهای

جدول ۱ - شاخص های طیفی تولید شده و اضافه شده به عنوان باندهای فرعی تصویر (۸)

Table 1. Spectral indicators generated and added as sub-bands of the image (8)

$NDVI = [(NIR - R) / (NIR + R)]$	شاخص پوشش گیاهی نرمال شده
$SAVI = [(NIR - Red) / (NIR + Red + L)] * (1 + L)$	شاخص پوشش گیاهی با اصلاح اثر خاک SAVI
$RVI = R / NIR$	شاخص پوشش گیاهی بر اساس نسبت RVI
$ARVI = (NIR - RB) / (NIR + RB)$ $RB = R - \gamma (B - R)$	شاخص پوشش گیاهی مقاوم در برابر اثرات جوی ARVI

یافته ها

ادغام داده ها (Data Fusion)

شود، در نتیجه یک تصویر با بالاترین اطلاعات طیفی ممکن، با اندازه پیکسل های باند پانکروماتیک سنجنده با بالاترین وضوح مکانی ایجاد میگردد (۱۹، ۲۰).

الگوریتم شبکه عصبی

همانطور که قبلاً گفته شد، شاخص های سنجش از دوری تولید شده، به همراه باندهای اصلی تصویر، به عنوان نورون ورودی برای پیاده سازی الگوریتم طبقه بندی شبکه عصبی استفاده می شوند. تعداد سلولهای عصبی در لایه خروجی به تعداد سلولهای عصبی در لایه ورودی بستگی دارد. در همین حال، لایه میانی یا لایه پنهان مهمترین قسمت پردازش در شبکه عصبی است که تعداد آنها برای نوع شبکه و تعداد نورونهای ورودی و خروجی طراحی شده است. این لایه پنهان در واقع وظیفه اختصاص دادن وزن مخصوص شبکه به هر نورون را دارد. تعیین نمونه

برای بهبود وضوح مکانی، با استفاده از باند پانکروماتیک سنجنده، عملیات تلفیق و ادغام تصویر انجام می شود. با استفاده از تکنیک های Fusion، داده هایی با وضوح طیفی (چند طیفی) بالا در کنار داده های با وضوح مکانی بالا قرار می گیرند. روش معمول در این کار روش Pc و استفاده از نرم افزار Geomatica است، به این ترتیب باند پانکروماتیک، جانشین مولفه اصلی تصویر چند طیفی می شود و سپس باندهای جدید با باندهای چند طیفی جایگزین می شوند (۱۸-۱۶). این بدان معنی است که Pci، بیشترین اطلاعات را از تصویر دارد (شامل تمام باندهای تصویر همراه با اطلاعات مکانی). با شروع عملیات تحت نرم افزار، الگوریتم به طور خودکار ایجاد می شود و سپس با یک باند پانکروماتیک (با وضوح مکانی بالاتر) جایگزین می

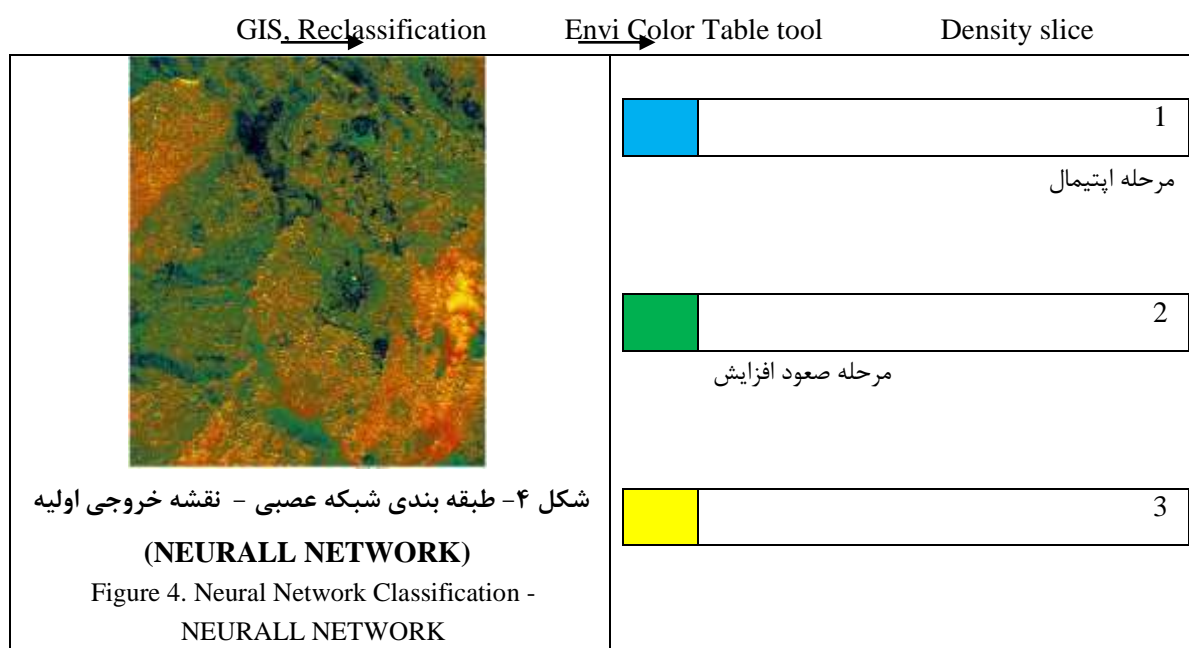
منطقه حضور پیکسل ها، محدوده ای بسیار کوچک است که این امر بیشتر از هر عاملی به دلیل وضوح مکانی زیاد سنجنده رخ داده است.

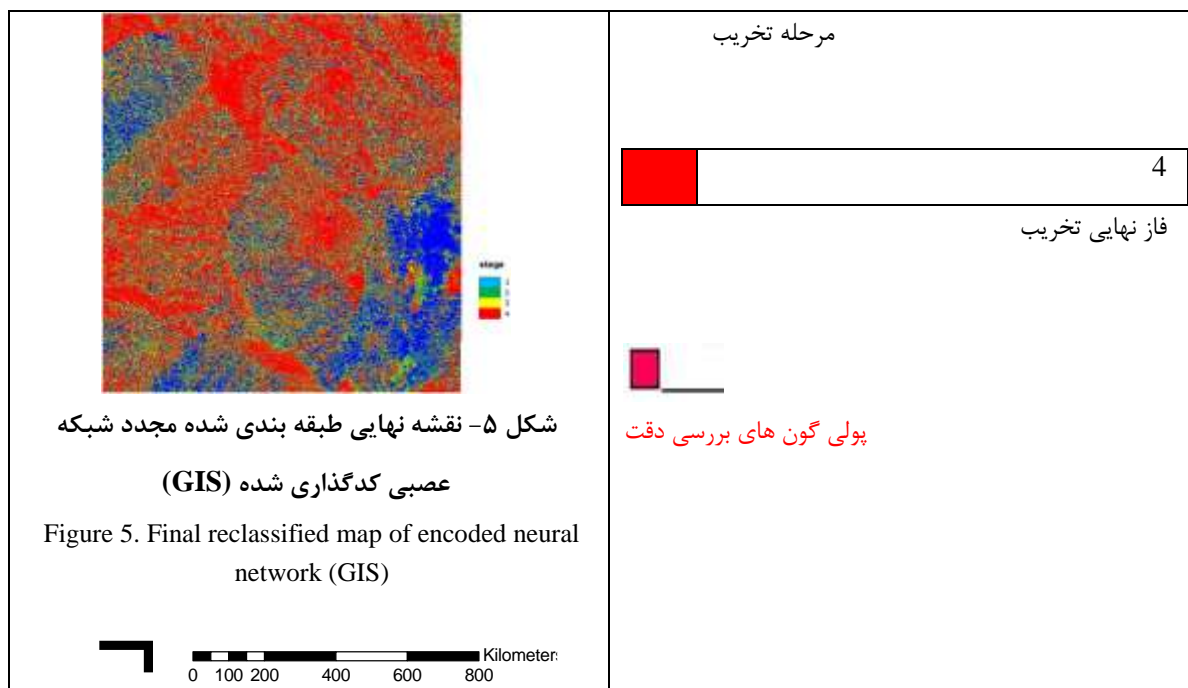
از ابزار Envi Color Table برای طبقه بندی مجدد لایه خروجی استفاده می شود. با استفاده از این روش، با توجه به هدف مطالعه، می توان محدوده پیکسل های نقشه خروجی را دوباره طبقه بندی کرد. لازم به توجه است که عملیات شبکه عصبی طراحی شده محدود به نمونه های تعلیمی ترسیم شده توسط ابزار Roi tools می باشد. در مرحله بعدی، تحت محیط نرم افزار GIS، عملیات طبقه بندی مجدد (Reclassify) بر روی این نقشه حاصل از عملیات Envi Color انجام می شود. کلاسها با توجه به مقدار طیفی پیکسلهای موجود، در جدول اطلاعات توصیفی در محیط GIS کدگذاری می شوند. نقشه حاصل در واقع خروجی اصلی این روش طبقه بندی ارتقاء یافته، با تفکیک کامل چهار کلاس هدف است. (فلوچارت). در واقع به دلیل حساسیت متقابل این حسگر و شبکه عصبی و الگوریتمهای FCD، انجام دو مرحله طبقه بندی و کدگذاری مجدد، با توجه به دامنه پیکسل های موجود در نقشه خروجی این دو روش، ضروری است.

های دقیق آموزش شی در تعیین وزن مخصوص شبکه که به لایه پنهان به هر نورون اختصاص داده شده است، بسیار موثر است. در عمل، طراحی شبکه عصبی با معرفی نورونهای ورودی، تعیین و معرفی نورونهای لایه پنهان، تعیین نوع عملکرد آستانه و قانون یادگیری و سپس تنظیم ضرایب آنها انجام می شود (۲۳-۲۱).

ارتقا نقشه خروجی

در مطالعه حاضر، بر اساس وضوح بالای سنسور GEOEYE و حجم بالای داده های پیکسلی استخراج شده، باندهای اصلی این سنسور، به همراه ۴ باند اصلی Fusion در کنار ۴ شاخص تولید شده به عنوان نورون ورودی به شبکه عصبی قرار می گیرد. پردازش این روش طبقه بندی در محیط نرم افزار ENVI انجام می شود. نمونه های تعلیمی برای مرحله اول طبقه بندی در روش حاضر، توسط برداشت های میدانی عرصه به دست آمده است. سپس عملیات طبقه بندی با طراحی شبکه عصبی انجام می شود. به این ترتیب اولین نقشه خروجی حاصل از این الگوریتم و مولفه های آن حاصل میگردد. پس از آن لازم است هیستوگرام مقدار طیفی نقشه خروجی و محدوده با بیشترین فرکانس پیکسل بررسی شود. این منطقه حضور پیکسل ها در هیستوگرام نقشه خروجی مجدداً طبقه بندی می شود. این





تحقیقاتی که مرزبندی ها در آنها در اشل و مسافت کوتاهتر مدنظر هستند (فازهای تحولی)، توجه گردد.

روش FCD

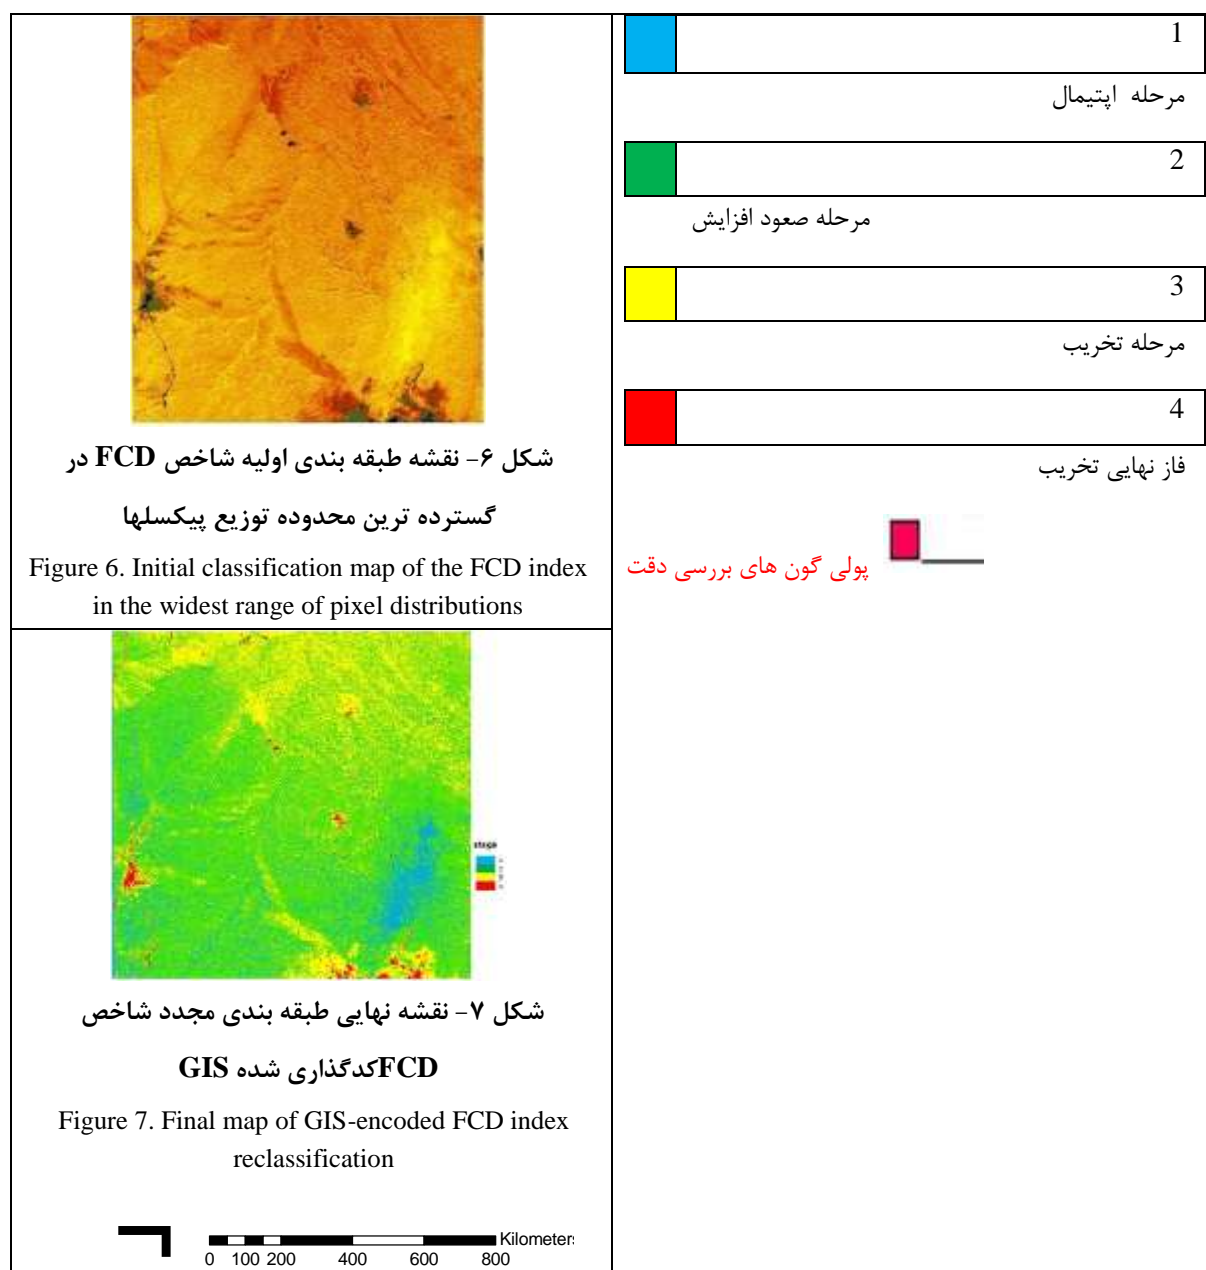
این روش بر اساس مدل تراکم تاج پوشش FCD است. این شاخص ها در محدوده ۰ تا ۱۰۰ نرمال هستند و شاخص FCD نهایی نیز در آن حد نرمالیزه می گردد. در حقیقت، روش مدل پایه FCD، برخلاف روش های Pixel base و Object base که بر اساس شناسایی نمونه های تعلیمی دقیق و وجود پیکسل در محدوده نمونه های تعلیمی کار می کنند، بر اساس مقادیر کمی و عددی حاصل از عملکرد چهار شاخص اصلی خود (جدول ۲) عمل میکنند. به این ترتیب در روش FCD، از تهیه داده های زمینی فقط برای بررسی صحت طبقه بندی استفاده می شود و در این روش از نمونه های تعلیمی استفاده نمی شود. در این تحقیق نقشه نهایی با طبقه بندی شاخص FCD در محدوده ۰ تا ۱۰۰ مقادیر طبقه بندی، برای چهار طبقه اصلی مراحل تحولی، ارائه می شود (۲۴، ۲۵).

با عملیات صورت گرفته بر روی نقشه خروجی اولیه الگوریتم شبکه عصبی، با توجه به دو عامل مقدار ارزش طیفی هر پیکسل و فرکانس مقادیر پیکسل ها در هر یک از نمودارهای هیستوگرام هر طبقه (محدوده اشباع فراوانی)، نقشه خروجی ارتقاء یافته، تولید شده است. بر این اساس دقت کلی در نقشه نهایی روش شبکه عصبی کدگذاری شده (شکل ۵) معادل ۲۶٪/۱۲۴ با ضریب کاپا معادل ۰/۰۳ بدست آمده است. شایان ذکر است که صحت کلی بدست آمده، با مقایسه مرزبندی پولی گون های نقشه نهایی حاصل از الگوریتم شبکه عصبی و پولی گون های تخصیص یافته برای سنجش دقت، حاصل شده است. از آنجاییکه پولی گون های تخصیص یافته برای سنجش دقت، بر مبنای مراحل تحولی تعیین شده اند و طبعاً طول بیشتری را شامل میشوند، لذا دقت طبقه بندی برای مراحل تحولی در حد مناسب نمیباشد. لیکن لازم است که به توانایی این روش طبقه بندی جدید بر مبنای محدوده و دامنه حضور پیکسل ها، برای

جدول ۲- شاخص های اصلی، روش FCD (۲۴)

Table 2. Main indicators of FCD method (24)

$AVI = ((Band5(4) + 1) \cdot (2048 - Band4) \cdot (Band5(4) - Band4))^{1/3}$ جایگزینی باند ۴ این سنجنده در فرمول، به دلیل توانایی مادون قرمز نزدیک در تشخیص گیاهان 2048= با توجه به وضوح رادیومتریک این سنجنده با رزولوشن بالا.	_AVI شاخص های گیاهی پیشرفته
$BI = (((B6(4) + B4) - (B5(4) + B2)) / (((B6(4) + B4) + (B5(4) + B2))) \times 100 + 100$	_BI شاخص خاک بدون پوشش
$SI = ((2048 - Band2) \cdot (2048 - Band3) \cdot (2048 - Band4))^{1/3}$	_SI شاخص سایه
$VD = BI + VI$	_VD تراکم پوشش گیاهی
$FCD = (VD \times SSI + 1)^{1/2} - 1$	_FCD شاخص تراکم تاج پوشش جنگل



مقدار صفر باشد، طبقه بندی کاملاً تصادفی است، و اگر مقدار منفی بدست آید، نمایانگر بروز خطایی در طبقه بندی است (۲۸).

بحث و نتیجه گیری

نظارت، پیش بینی، برنامه ریزی یا توسعه عرصه های طبیعی، هر یک بر اساس هدف مطالعه دارای تأثیرات و عملکردهایی است، که با کمک سنسورهای جدید با دقت بالا امکان پذیر هستند. وضوح مکانی بالا در سنسورهای پیشرفته ای مانند Geoeye، با دقت بسیار زیاد، در ترسیم پدیده های خاص، مانند مراحل تحولی در جنگل های طبیعی، بسیار مفید است. با بهبود قابلیت جداسازی انواع سنسورها، امکان توسعه بیشتر نرم افزارهای تجزیه و تحلیل تصویر ماهواره وجود دارد. به این ترتیب از ابزارهای جدید در این برنامه ها استفاده می شود و خروجی آنها با دقت بالاتری ارائه می شود که در تحقیق حاضر به برخی از این ابزارها و توانمندی ها اشاره شده است. انتخاب سنسور و تهیه داده های ماهواره اساساً به دلیل نوع مطالعه انجام می شود. وضوح مکانی، تعداد و نوع باندهای تصویربرداری، وضوح مکانی باندهای اصلی، همراه با باند پانکروماتیک انواع مختلف سنسورها، در دستیابی به اهداف مطالعه موثر است. لازم به ذکر است که با وضوح بالای تصویر، به تنهایی نمی توان به اهداف تحقیق دست یافت و لازم است داده ماهواره ای متناسب با هدف تحقیق انتخاب شود. انتخاب سنسورهای Geoeye برای این تحقیق با در نظر گرفتن تفکیک پذیری زیاد مکانی این سنسور و همچنین نزدیکی بودن زمان تصویربرداری با زمان عملیات برداشت میدانی منطقه جنگلی انجام شده است (۲۹، ۳۰).

در مطالعه حاضر، دو روش طبقه بندی، که تفاوت قابل توجهی با یکدیگر دارند، لیکن برای بررسی توانایی تفکیک مکانی بالای سنسور Geoeye، به منظور شناسایی مراحل تحولی در جنگل، به عنوان یک پدیده خاص، مفید هستند، مورد استفاده قرار گرفته اند.

الگوریتم شبکه عصبی به باند های اصلی تصویر و باند های فرعی تولید شده از شاخص های سنسور از دوری، به عنوان نرون های

شاخص FCD به عنوان یک مقدار طیفی، در گسترش یافته ترین بخش هیستوگرام، همراه با حضور پیکسل ها در محدوده ۵۵ تا ۷۵ درصد است. بنابراین، در این مرحله، خروجی طبقه بندی با این شاخص به یک کلاس محدود می شود. چنین تأثیراتی در عملکرد شاخص ها در مطالعات زی آو و همکاران و وینا و همکاران (۲۶، ۲۷، ۱۳)، مشاهده می شود. به همین دلیل، از روش طبقه بندی مجدد و ارتقاء یافته، با در نظر گرفتن دامنه توزیع پیکسل ها استفاده می شود که با استفاده از آن دقت کلی طبقه بندی معادل ۲۴/۵٪ و ضریب کاپا ۰/۰۷۵ (شکل ۷) بدست آمده است. شایان ذکر است که استفاده از این روش بر اساس مفهوم تفکیک طیفی و مکانی سنسور و در حداکثر دامنه توزیع پیکسل ها در نقشه خروجی الگوریتم، صورت می پذیرد. این عملیات در گام اول، از طریق Envi Color Tables - Density Slice، و سپس کدگذاری و طبقه بندی مجدد در نرم افزار GIS، انجام می شود.

لازم به ذکر است که تصویر به دست آمده از ابزار Envi Color در واقع بر اساس فرکانس حضور پیکسل ها در یک محدوده خاص از هیستوگرام ارزش های طیفی شاخص FCD (محدوده پیکسل های با ارزش ۵۰-۷۵) عمل کرده است. این امر از نظر تکنیک طبقه بندی برای کاربر داده ماهواره ای رزولوشن بالا حائز اهمیت می باشد. روش جدید معرفی شده تکنیک مناسبی برای ارتقاء عملکرد الگوریتم های مذکور در داده های ماهواره ای مشابه ارائه می نماید. در طبقه بندی نهایی (شکل ۷) کدگذاری و طبقه بندی مجدد تصویر خروجی Envi Color Tables - Density Slice، در محیط نرم افزار GIS (Reclassification)، انجام شده است.

ارزیابی صحت طبقه بندی

پارامترهای اصلی برای ارزیابی دقت طبقه بندی بر اساس ماتریس خطا محاسبه می شوند. در این مطالعه، از دو شاخص صحت کلی و ضریب کاپا برای ارزیابی صحت طبقه بندی استفاده شده است. برای تحلیل مناسب تر دقت کلی، از شاخص کاپا با هدف مقایسه دقت در طبقه بندی استفاده می شود. شاخص کاپا پیکسل های طبقه بندی شده نادرست را در نظر می گیرد. حالت ایده آل برای ضریب کاپا ۱ است. اگر این

آمده اند، که هدف اصلی این تحقیق برای ارتقاء طبقه بندی با داده رزولوشن بالای Geoeye بوده است. امروزه با افزایش فوق العاده فن آوری های برداشت و ضبط تصاویر ماهواره ای، خصوصاً توسعه روزافزون توانایی سنجنده های جدید در رابطه با قدرت تفکیک مکانی، لازم است الگوریتم ها و مدل ها و ابزار تجزیه و تحلیل داده های ماهواره ای، با توجه به حجم زیاد اطلاعات جدید، مورد بازبینی و ارتقاء قرار گیرند. بر این اساس دو نکته عمده در این مطالعه مورد توجه بوده است. اول توجه به هیستوگرام ارزش های طیفی نقشه های خروجی اولیه، و دوم ارائه روشی جدید برای استخراج طبقات هدف از محدوده حداکثر اشباع فراوانی پیکسل ها در هیستوگرام مذکور. به طور کلی نقشه های طبقه بندی خروجی حاصل، شامل چگالی زیاد پیکسل ها و همچنین تنوع پولی گونی زیاد در الگوریتم شبکه عصبی، و تنوع پولی گونی کم، در مدل FCD هستند. این امر باعث کاهش دقت طبقه بندی در هر دو روش شده است. روش توسعه و ارتقاء طبقه بندی ارائه شده در این تحقیق باعث شد تا نقشه خروجی در هر دو روش، مناسب تر و با تفکیک بهتر طبقات نسبت به شرایط قبل از اجرای روش جدید همراه باشد. به این ترتیب بنا بر نحوه کار الگوریتم ها، تکنیک نوینی برای دستیابی به اهداف طبقه بندی، همراه با استفاده از وضوح مکانی بالا سنجنده ارائه شده است.

References

1. Desclée, B., Bogaert, P. and Defourny, P. (2006). Forest change detection by statistical object-based method. *Remote Sensing of Environment*, 102(1-2), 1-11.
2. Chen, G., Hay, G.J., Carvalho, L.M., Wulder, M.A. (2012). Object-based change detection. *International Journal of Remote Sensing*, 33(14), 4434-4457.
3. Kavzoglu, T., Colkesen, I. and Yomralioglu, T. (2015). Object-based classification with rotation forest ensemble learning algorithm using very-high-resolution WorldView-2

ورودی شبکه، و همچنین به عملکرد لایه پنهان برای وزن دهی به نرون های ورودی و تدقیق عملکرد نمونه های تعلیمی، وابسته است. در روش های طبقه بندی مبتنی بر حساسیت بالا بر روی مقدار طیفی پیکسل ها، مانند روش شبکه عصبی، تفاوت های جزئی در مقدار طیفی پیکسل ها در تولید نقشه خروجی نقش مهمی بازی می کند. بنابراین، در نقشه های تولید شده توسط این الگوریتم، محاط بسیار کوچکی برای مراحل تحولی تفکیک شده است، که در بحث هایی مانند فازهای تحولی در جنگل های طبیعی مفید هستند، که البته تشخیص و بستن مرزپلی گون ها در آنها دشوار است. با استفاده از خروجی های روش طبقه بندی شبکه عصبی، می توان انتظار داشت که این الگوریتم دقت بالاتری را در مطالعات پدیده هایی با ابعاد محدود تر، ارائه نماید. اجرای مدل (FCD) وابسته به نمونه های تعلیمی معرفی شده به نرم افزار، حاصل از نمونه برداری های میدانی نمی باشد. این امتیاز از طریق عملکرد ۴ شاخص دقیق در این روش بدست می آید. اصولاً در حین طراحی سنسورهای با وضوح بالا (مکانی یا طیفی)، دقت سنسور بسیار مد نظر است. بنابراین، در سنجنده Geoeye در مقابل وضوح مکانی بالا، محدوده برداشت طیفی سنسور محدود است، اما در این محدوده طیفی (۴ باند)، با حجم رادیومتریک زیادی از داده های پیکسلی با دقت بالای مکانی مواجه هستیم. بر این اساس دو روش بیان شده در این پژوهش با هدف شناسایی پدیده خاص (مراحل تحولی)، طراحی شده و ارتقاء یافته اند. علاوه بر این، با عملکرد روشهای FCD و الگوریتم شبکه عصبی، طبقه بندی نقشه خروجی در محدوده گستره کوچکی از مقادیر ارزش های طیفی پیکسل ها در هیستوگرام نقشه خروجی صورت گرفت. در نتیجه، با تجمع پیکسل ها در یک فضای کوچک هیستوگرامی، خروجی نقشه ها مناسب نبوده است (بنا بر تاثیر قدرت تفکیک مکانی بالای سنجنده Geoeye و ایجاد محدوده اشباع فراوانی پیکسل ها). برای غلبه بر این مشکل، طبقه بندی مجدد این نقشه های خروجی بر اساس مفهوم، محدوده اشباع فراوانی پیکسل ها، صورت پذیرفت. که بعد از طبقه بندی مجدد در نرم افزار GIS، حاصل آن نقشه هایی با تفکیک مناسب طبقات هدف بدست

- of k-NN, SVR and random forest regression algorithms. *International journal of remote sensing*, 33(19), 6254-6280.
11. Aronoff.S. "Remote Sensing for GIS Managers" . Esri Press.2005.
 12. Math(z)er.P.M. "Computer Processing of Remotely-Sensed Images". 1996.
 13. Vina, A, Gitelson, A, Robertson, A, Peng, Y, 2011, *Comparison of different vegetation indices for the remote assessment of green leaf area index of corps, Remote sensing of Environment*. <https://doi.org/10.1016/j.rse.2011.08.010>.
 14. Mataji, A., Sagheb-Talebi, K. and Eshaghi-Rad, J.(2014) *Deadwood assessment in different developmental stages of beech (Fagus orientalis Lipsky) stands in Caspian forest ecosystems. International Journal of Environmental Science and Technology*, 11(5): 1215-1222.
 15. Stoffels, J, Hill, J, Sachtleber, T, Mader, S, Buddenbaum, H, Stern, O, 2015, *Satellite based derivation of high resolution forest information layers for operational forest management. Forests*. Vol6. iss6. <https://doi.org/10.3390/f6061982>.
 16. Hill, J.; Diemer, C.; Udelhoven, T. 2003. *A Local Correlation approach for the fusion of image bands with different spatial resolutions. Bull. Soc. Fr. Photogramm. Télédélect.* 2003, 169.
 17. Deghani.H. *Multi-spectral classification. Multi-satellite remote sensing based on decision-making integration. Master's Degree Electronic Thesis. Tarbiyat Modares University 2002.*
 18. Deghani.H. *Processing and interpreting remote sensing images. image. Remote Sensing Letters*, 6(11), 834-843.
 4. Bulut, S., Günlü, A. and Keleş, S. (2019). Estimation of forest development stage and crown closure using different classification methods and satellite images: A case study from Turkey. *Journal of Forest Science*, 65(1), 18-26.
 5. Al-Doski, J., Mansori, S.B. and Shafri, H.Z.M. (2013). Image classification in remote sensing. Department of Civil Engineering, Faculty of Engineering, University Putra, Malaysia. *Journal of Environment and Earth Science*,3(10), 141-148.
 6. Morales, R.M. (2012). Using Remotely Sensed Imagery for Forest Resource Assessment and Inventory. *FOREST ECOSYSTEMS–MORE THAN JUST TREES*, p.165.
 7. Osio, A., Lefèvre, S., Ogao, P. and Ayugi, S. (2018). OBIA-based Monitoring of Riparian Vegetation Applied to the Identification of Degraded Acacia Xanthophloea along Lake Nakuru, Kenya. *Espace pour le développement (ESPACE DEV); Société T.E.T.I.S.,GEOBIA'2018–Montpellier*, 18-22 June 2018. <https://hal.univ-reunion.fr/hal-01960341>.
 8. Xue, J. and Su, B. 2017. Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 17pp. <https://doi.org/10.1155/2017/1353691>.
 9. Waring.R.H and Running.S.W. "Forest Ecosystems: Analysis at Multiple Scales". Academic Press.1988.
 10. Shataee, S., Kalbi, S., Fallah, A. and Pelz, D. (2012). Forest attribute imputation using machine-learning methods and ASTER data: comparison

- Disaster Areas at Kelud Mountain, East Java. 2nd International Conference of Indonesian Society for Remote Sensing (ICOIRS) 2016. <https://www.researchgate.net/publication/312190068>
<https://doi.org/10.1029/2005GL023647>.
25. Pak-khesal.E, Baniyad.A, 2013. Canopy cover canopy classification by using FCD model (Case study of Shafarood Gilan Basin), Journal of Forest and Poplar Research, No.1. 92,114_99 p.
 26. Xiao, X., He, L., Salas, W., Li, C., Moore, B., Zhao, R., et al. (2002). *Quantitative relationships between field-measured leaf area index and vegetation index derived from vegetation images for paddy rice fields. International Journal of Remote Sensing*, 23, 3595–3604. <http://www.tandf.co.uk/journals>.
 27. Viña, A., Gitelson, A.A.(2005). *New developments in the remote estimation of the fraction of absorbed photosynthetically active radiation in crops. Geophysical Research Letters*,32,L17403.
 28. Congalton, R.G. and Green, K. (1999). *Assessing the accuracy of remotely sensed data: principles and practices*", Boca Raton: Lewis Publications. Second Edition (Mapping Science) 2nd Edition.183 pp.
 29. Kempeneers, P.; Sedano, F.; Seebach, L.; Strobl, P.; San-Miguel-Ayanz, J. 2011. Data fusion of different spatial resolution remote sensing images applied to forest-type mapping. *IEEE T. Geosci. Remote* , 49, 4977–4986. lucia.seebach@jrc.ec, Digital Object *Malek ashtar Industrial University Press*. 2013. ISBN 978-600-5665-51-2.
 19. Rashidi.F, Babaei Khafaki, Sasan, Metaji, Asadullah, 2009. A survey on the capability of ETM+ sensor digital data in separating forest types (Case study of Lefebvre Savadkou region), *Journal of Forest and Poplar Research*, No. 1, 88. 63_51 p.
 20. Crowson et al. 2018. A comparison of satellite remote sensing data fusion methods to map peat swamp forest loss in Sumatra, Indonesia. *Remote Sensing in Ecology and Conservation* published by John Wiley & Sons. DOI: 10.1002/rse2.102.
 21. Nadoushan.M.A, S, Salyanian. A, Khajeeddin. Seyyedmalamdin, 2009, Preparation of Arak Landslide Survey Map Using Artificial Neural Network Classification Methods and Maximum Likelihood, *Natural Geography Research*, No. 69, 88. 98_83 p.
 22. Molai.Z, Zahiri.J, Jalili.S, Ansari.M.R, Taghizadeh.A, 2016 Remote Sensing and Artificial Neural Network Application in Estimation of Suspended Sediment in River (Case Study of Karun River), *Journal of Water and Soil Science* No. 2, year 97. 259_249 p.
 23. Hilbert, D.W., Muzzenberg, J.V.D. Using an artificial neural network to characterize the relative suitability of environments for forest types in a complex tropical vegetation mosaic. *Diversity and Distributions* 5(6): 263-274., 1999.
 24. Himayah, S, Hartono, Danoedoro, P, 2016. The Utilization of Landsat 8 Multitemporal Imagery and Forest Canopy Density (FCD) Model for Forest Reclamation Priority of Natural

and linear spectral mixture analysis.
Silva Fenn, 41, 441–456.
<http://www.metla.fi/silvafennica/full/sf41/sf413441.pdf>.

Identifier
10.1109/TGRS.2011.2158548.
30. Vohland, M.; Stoffels, J.; Hau, C.; Schüler, G.2007. Remote sensing techniques for forest parameter assessment: Multispectral classification