

بهبود تخمین حجم زیست توده مناطق جنگلی با استفاده از داده‌های راداری و نوری سنجنده Sentinel و الگوریتم بهینه سازی ژنتیک (مطالعه موردی: مناطق جنگلی نور)

آوا توکلی دارستانی^۱، نیکروز مستوفی^{۲*}، آرمین مقیمی^۳

^۱ کارشناس ارشد سنجش از دور - دانشکده فنی و مهندسی - دانشگاه آزاد اسلامی واحد تهران جنوب
tavakoliava8@gmail.com

^۲ استادیار گروه مهندسی نقشه برداری - دانشکده فنی و مهندسی - دانشگاه آزاد اسلامی واحد تهران جنوب
mostofi_n@yahoo.com

^۳ دانشجوی دکتری فتوگرامتری - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
moghimiarmin@gmail.com

(تاریخ دریافت بهمن ۱۴۰۰، تاریخ تصویب تیر ۱۴۰۱)

چکیده

زیست توده جزء کلیدی در چرخه کربن می باشد، از این رو ارزیابی دقیق آن به منظور مدیریت جنگل و درک نقش آن در تغییرات آب و هوایی، اهمیت بسیاری دارد. امروزه استفاده از تکنیک های سنجش از دور با کمک داده های میدانی، تحولی شگرف را در برآورد زیست توده جنگل ها ایجاد کرده است. در این تحقیق به منظور بهبود دقت برآورد زیست توده مناطق جنگلی، از ویژگی های مستخرج از تصاویر اپتیک سنجنده Sentinel-2 و داده های راداری Sentinel-1 و همچنین داده های میدانی مناطق جنگلی نور، استان مازندران که نوع پوشش جنگلی آن، ممرز-بلوستان است و همچنین شامل گونه های نادر از جمله درختان سفید پلت می باشد که در این مطالعه در چهار کلاس پوشش گیاهی مخلوط، جنگل طبیعی، جنگل تخریب شده و ذخایر جنگلی مورد بررسی قرار گرفتند و روش بهینه سازی ژنتیک استفاده شده است. در این راستا، جهت مدلسازی بین داده های زمینی و ویژگی های راداری و نوری از روش رگرسیون خطی چند متغیره و رگرسیون ماشین بردار پشتیبان استفاده شده است. همچنین به منظور انتخاب ویژگی های بهینه مستخرج از تصاویر راداری و نوری از الگوریتم ژنتیک در طول فرآیند مدلسازی با استفاده از رگرسیون خطی چند متغیره استفاده شده است. ارزیابی نتایج نشان داد که استفاده از روش رگرسیون چند متغیره منجر به نتایج دقیق تری نسبت به روش رگرسیون ماشین بردار پشتیبان در منطقه مورد مطالعه شده است. همچنین، ارزیابی نتایج حاصل از اعمال رگرسیون خطی چند متغیره نشان می دهد که استفاده از ویژگی های انتخاب شده مبتنی بر الگوریتم ژنتیک، منجر به افزایش دقت ضریب تعیین R^2 به میزان ۰/۷۸، ۰/۸۷، ۰/۶۸، و ۰/۷۹ به ترتیب در کلاس های اول تا چهارم پوشش گیاهی انتخابی شده است. لذا نتایج حاصل نشان دهنده این است که بکارگیری الگوریتم ژنتیک به همراه روش رگرسیون چند متغیره موجب بهبود دقت برآورد زیست توده در این تحقیق شده است.

واژگان کلیدی: برآورد زیست توده، الگوریتم ژنتیک، تصاویر راداری و اپتیک، رگرسیون خطی چند متغیره

* نویسنده رابط

۱- مقدمه

زیست توده یکی از مهمترین پارامترها در ارزیابی سلامت جنگل‌ها می‌باشد، بطوریکه طبق تعریف FAO^۱، دلالت به مواد آلی بالای سطح زمین یا زیر این سطح (زنده و مرده) از قبیل درختان، محصولات کشاورزی (ذرت، گندم)، چمن و ریشه‌ها دارد [۳، ۲، ۱]. بنابراین، این پارامتر می‌تواند نقشی کلیدی در چرخه‌های کربن، مواد معدنی خاک و تجمع سوخت در اکوسیستم زمینی ایفا کند. توصیفی دقیق از توزیع زیست توده در مقیاس‌های محلی و ناحیه‌ای و جهانی، به شکل گسترده موجب کاهش ابهام در تجزیه و گسیل کربن، درک نقش کربن در باروری خاک، فرسایش و یا بازیابی زمین و پردازش محیط می‌شود [۴]. همچنین، برآورد زیست توده از برنامه‌ی بین‌المللی^۲ REDD+ (که شامل مواردی نظیر کاهش جنگل زدایی و تخریب جنگل‌ها، مدیریت پایدار جنگل‌ها، حفاظت و تقویت ذخایر کربن جنگل‌ها) است، پشتیبانی می‌کند [۳].

زیست توده به طور عمده معمولاً به دو روش برآورد می‌گردد؛ روش سنتی این اندازه‌گیری استفاده از مشاهدات و اندازه‌گیری میدانی و روش بروز آن استفاده از تکنولوژی سنجش از دور است. اندازه‌گیری‌های میدانی از جمله روش‌های سنتی در برآورد زیست توده می‌باشند، که می‌توانند دقیق‌ترین مقادیر زیست توده را ارائه دهند. با این حال، این روش‌ها نه تنها پرهزینه، زمان‌بر و از نظر مکانی محدود هستند، بلکه در پاره‌ای از مواقع موجب تخریب محیط زیست به خصوص در مناطق بکر جنگلی می‌شوند [۵، ۶]. با ظهور تکنولوژی سنجش از دور و رشد روز افزون پرتاب ماهواره‌های مجهز به سنجنده‌های مختلف، امکان دسترسی به داده‌های قابل توجه از مناطق مختلف کره زمین و با قدرت تفکیک‌های مکانی، طیفی و زمانی مختلف، به طور چشمگیری افزایش یافته‌است. چنین مزیتی باعث شده‌است که بر خلاف روش‌های میدانی، استفاده از داده‌های سنجش از دوری به روشی محبوب در جهت برآورد کم‌هزینه و سریع زیست توده جنگل‌ها در مقیاس‌های مختلف تبدیل شود. برآورد زیست توده جنگل‌ها می‌تواند مبتنی بر پردازش داده‌های سنجش از

دوری اخذ شده توسط سنجنده‌های فعال (به عنوان مثال لیدار و رادار) و سنجنده‌های غیرفعال (به عنوان مثال سنجنده‌های نوری) باشد [۹، ۷، ۸].

در اکثر تحقیقات پیشین، عمدتاً از شاخص‌های پوشش گیاهی (مانند NDVI، RVI، SAVI) جهت تخمین زیست توده استفاده شده‌است [۱۰]. به عنوان مثال، Clerici و همکاران (۲۰۱۶) برای برآورد زیست توده جنگل‌هایی در نزدیکی بوگاتای کلمبیا از تصاویر با وضوح بالای GeoEye-1 و Pleiades-1A و شش شاخص پوشش گیاهی (TVI، NDGI، RVI، VIN، NDVI) استفاده نمودند. نتایج نشان داد که در میان این شاخص‌ها، شاخص پوشش گیاهی RVI منجر به تخمین بهتر زیست توده در منطقه مورد مطالعه شد [۱۱]. Baloloy و همکاران (۲۰۱۸) به منظور برآورد زیست توده‌ی جنگل‌های حرا در فیلیپین از باندهای چندطیفی و متغیرهای بیوفیزیکی و شاخص‌های پوشش گیاهی NDVI، SAVI، GNDVI، SR، SRre حاصل از تصاویر نوری Sentinel-2، Rapid eye، Planet space استفاده کردند. نتایج نشان داد که استفاده از شاخص‌های پوشش گیاهی مستخرج از داده‌های ماهواره‌ای Rapid Eye، Sentinel-2 منجر به نتایج بهتری در برآورد زیست توده از منطقه‌ی مورد مطالعه شد که ناشی از قدرت تفکیک بالای طیفی این تصاویر نسبت به تصاویر Planet space بود [۱۲].

با وجود آنکه استفاده از داده‌های مستخرج از سنجنده‌های نوری منجر به نتایج ارزشمندی شده‌است، عملکرد این نوع سنجنده‌ها حساسیت زیادی به پارامترهایی نظیر شرایط اتمسفری و زاویه‌ی ارتفاعی دارند. به عنوان مثال، بطوری که حضور ابر در منطقه‌ی مورد مطالعه یکی از جدی‌ترین موانع در استفاده از داده‌های اینگونه سنجنده‌ها در برآورد زیست توده به حساب می‌آید [۸، ۱۳]. در مقابل، داده‌های سنجش از دوری SAR^۳ در محدوده طول موج‌های مختلف ماکروویو، با قابلیت نفوذ در ابرها و لایه‌های مختلف جنگل، محدودیت داده‌های نوری را در برآورد زیست توده مرتفع می‌کنند [۸]. این قابلیت منحصر به فرد منجر به استفاده‌ی مرسوم از این داده‌ها در برآورد پارامترهای جنگل در مناطق با پوشش ابر بالا شده‌است [۱۴]. همچنین، تفسیر بازپراکنش امواج ماکروویو از سطح

^۱ Food and Agriculture Organization (FAO)

^۲ REDD (Reduce emission from deforestation and forest degradation)

^۳ Synthetic Aperture Radar

اشیاء به سمت سنجنده می‌تواند خصوصياتی منحصر به فرد از گیاهان مانند شکل هندسی، توپوگرافی، رطوبت و... را ارائه دهد، که در محدوده طیف الکترومغناطیس نوری به دلیل طول موج کوتاه‌تر امکان‌پذیر نیست [۱۴]. همچنین، امکان ارسال و دریافت موج در پلاریزاسیون‌های افقی و عمودی می‌تواند به برآورد صحیح ساختار زیست-توده کمک قابل توجهی کند [۱۵].

مقادیر بازپراکنش ماکروویو به مقدار زیست‌توده در یک مکان معین حساس است [۱۶]. طول موج‌های بلندتر مانند باند L و P قدرت بیشتری برای نفوذ در تاج پوشش گیاهی جنگل دارند و اطلاعات بیشتری را در مورد ساختار عمودی جنگل در برابر طول موج‌های کوتاه‌تر مانند باند C و X اخذ می‌نمایند [۱۷، ۱۸]. با در دسترس بودن داده‌های ماهواره‌ای رایگان مانند Sentinel-1 که توسط آژانس فضایی اروپا (ESA) در سال ۲۰۱۴ پرتاب شد، فرصتی مناسب برای برآورد زیست‌توده در باند C فراهم شده‌است [۱۹].

براساس نقاط ضعف و مزایای سنجنده‌های نوری و راداری، اخیراً تلاش شده‌است که اطلاعات تکمیلی این دو منبع داده در برنامه‌های پوشش زمین با هم ترکیب شوند [۲۰]. تحقیقات نشان داده‌است با ترکیب اطلاعات سنجنده‌های مختلف، نتایج امیدوار کننده‌تری در برآورد میزان زیست‌توده جنگل حاصل خواهد شد [۲۱]. به عنوان مثال، Attarchi و همکارش (۲۰۱۴)، برای برآورد زیست‌توده‌ی جنگل‌های هیرکانی در منطقه لوه از تصویر چندطیفی Landsat ETM+ و تصویر راداری ALOS PALSAR، در باند L استفاده کردند. سپس ۱۱ مدل مختلف رگرسیون خطی چندگانه را با استفاده از ترکیبات مختلف باندهای تصحیح شده طیفی و راداری و ویژگی‌های حاصل از آن‌ها را ارزیابی نمودند. استفاده از باندهای طیفی و ویژگی‌های راداری نتایج حاصل از برآورد زیست-توده را به میزان قابل توجهی بهبود می‌بخشد [۲۲].

Huang و همکاران (۲۰۱۶) برای برآورد زیست‌توده پارک ملی Xixi در چین از تصاویر نوری سنجنده‌های (Landsat TM، Terra ASTER و HJ-1-B) و تصاویر راداری سنجنده‌های (ERS-2، Envisat ASAR) استفاده کردند، که براساس نتایج ترکیب ویژگی‌های تصاویر سنجنده‌های ASTER و ERS-2 دارای ضریب همبستگی بالایی می‌باشند. با این حال، عدم همزمانی داده‌های

سنجش‌ازدوری از ضعف‌های این تحقیق به شمار می‌آید [۲۳]. Pham و همکاران (۲۰۱۸)، برای برآورد زیست‌توده پوشش گیاهی حرا در منطقه‌ی ساحلی فونگ در ویتنام از ترکیب داده‌های ALOS-2 PALSAR و Sentinel-2A استفاده کردند [۲۴]. Narissara Nuthammachot و همکاران (۲۰۲۰) تصاویر سنجنده‌های Sentinel-1 و Sentinel-2 را به تنهایی و به صورت ترکیبی برای برآورد میزان زیست‌توده جنگلی در منطقه‌ی جنگلی در اندونزی مورد بررسی نمودند. که نتایج حاصل از ترکیب دو تصویر پیش‌بینی زیست‌توده را به میزان قابل توجهی بهبود بخشید [۱۹]. Negar Tavasoli و همکاران (۲۰۲۱) پتانسیل استفاده از ترکیب دو داده‌ی راداری ALOS PALSAR و Sentinel-1 را با استفاده از داده نوری Sentinel-2 به تنهایی برای برآورد زیست‌توده مقایسه کردند. ویژگی‌های استخراجی از تصاویر راداری شامل تجزیه و تحلیل پلاریمتریک و ویژگی‌های بافت و ضرایب بازپراکنش است. از تصویر نوری هم ویژگی‌های شاخص پوشش گیاهی، بافت و PCA استخراج شده‌است. R^2 حاصل از دو تصویر راداری برتری بالاتری به نسب تصویر نوری نشان می‌دهد [۲۵].

مروری بر تحقیقات فوق نشان‌دهنده‌ی آن است که ویژگی‌های استفاده‌شده در برآورد زیست‌توده از تنوع زیادی برخوردارند و استفاده کورکورانه از حجم زیادی از ویژگی‌ها بدون توجه به کارایی آن‌ها ممکن است دقت برآورد را کاهش دهد. از این رو لازم است که متناسب با منطقه‌ی مورد مطالعه ویژگی‌های مناسب از تصاویر ماهواره‌ای استخراج شوند و در برآورد زیست‌توده مورد استفاده قرار گیرند. در این راستا، می‌توان از روش سعی و خطا مبتنی بر دانش قبلی از منطقه‌ی مورد مطالعه در زمینه‌ی انتخاب ویژگی‌های بهینه در زمینه تخمین زیست‌توده استفاده نمود. با این حال، بکارگیری این روش مستلزم صرف هزینه‌ی زمانی و محاسباتی بالا است. در جهت رفع این مشکل و تخمین دقیق‌تر زیست‌توده، استفاده از الگوریتم‌های فراابتکاری در انتخاب ویژگی‌های بهینه‌ی مستخرج از تصاویر ماهواره‌ای به عنوان یک جایگزین مناسب مطرح می‌شود. به عنوان مثال، Latifi و همکاران (۲۰۱۹)، از الگوریتم ژنتیک به منظور انتخاب ویژگی بهینه‌ی مستخرج از تصاویر سنجنده Sentinel-1، Seninel-2 و ALOS-2 جهت برآورد ذخیره رو به رشد

^۱ (GSV) جنگل‌های هیرکانی شمال ایران استفاده کردند [۲۶]. Chiarito و همکاران (۲۰۲۱) برای بازیابی زیست‌توده‌ی علفزار در مناطق آلپ از الگوریتم ژنتیک به منظور انتخاب باندهای فراطیفی با بیشترین محتوای اطلاعاتی استفاده کردند و از ترکیب باندهای انتخابی و اطلاعات راداری زیست‌توده را بازیابی کردند [۲۷].

اگرچه استفاده از الگوریتم‌های فراابتکاری در این تحقیق‌ها منجر به انتخاب ویژگی‌های مناسب‌تر برای تخمین زیست‌توده شد، اما در آن‌ها تنوع گونه‌های جنگل در مناطق مورد مطالعه در نظر گرفته نشده‌است. به عبارت دیگر ممکن است ویژگی‌های بهینه برای گونه‌های مختلف یکسان نباشد و انتخاب یکدسته ویژگی بهینه برای کل منطقه‌ی مورد مطالعه منجر به حصول بهترین دقت کلی شود نه دقت منطقه‌ای. در راستای رفع این محدودیت، در این تحقیق از الگوریتم ژنتیک برای انتخاب ویژگی‌های بهینه‌ی مستخرج از تصاویر Sentinel 1& 2 به منظور برآورد زیست‌توده در چهار گونه‌ی مختلف در یک منطقه مطالعاتی استفاده می‌شود. از سوی دیگر، در اکثر تحقیقات پیشین عدم همزمانی بین برداشت داده‌های زمینی و تصاویر سنجش‌ازدوری مشاهده می‌شود که می‌تواند نتایج را به صورت بالقوه تحت تاثیر قرار دهد. در راستای غلبه بر این محدودیت، داده‌های زمینی با استفاده از ابزار دقیق نقشه‌برداری از سطح منطقه جمع‌آوری شده‌است و از داده‌های سنجش‌ازدوری همزمان با این داده‌ها در برآورد زیست‌توده استفاده شده‌است. همچنین، در اکثر تحقیقات استفاده از الگوریتم‌های یادگیری ماشین پیشرفته به خصوص الگوریتم ماشین بردار پشتیبان را به عنوان هسته مدلسازی مد نظر قرار می‌دهند. برخی از مطالعات پیشین نشان دادند که رویکرد های SVM به کاهش مجموعه داده‌ها حساس هستند که ممکن است در پاره‌ای از مواقع صرفاً منجر به نتایج بهتر نشوند [۲۸]. لذا، در این مطالعه روش رگرسیون خطی چند متغیره و رگرسیون بردار پشتیبان به عنوان هسته‌های مدلسازی در برآورد زیست‌توده با یکدیگر مقایسه می‌شوند.

۲- مواد و روش‌ها

۲-۱- منطقه‌ی مورد مطالعه

جنگل‌های هیرکانی خزر کمربندی سبز از جنگل‌های معتدل می‌باشند، که در دامنه‌ی شمالی رشته کوه البرز و در امتداد مرزهای جنوبی دریای خزر از استان گلستان تا استان گیلان کشیده شده‌اند [۲۹]. بخش‌هایی از این جنگل‌ها اخیراً در فهرست میراث طبیعی جهانی یونسکو ثبت شده‌اند؛ بنابراین، نگهداری و حفظ آن‌ها از اهمیت بالایی در سطح منطقه‌ای و جهانی برخوردار است [۳۰]. منطقه‌ی مورد مطالعه‌ی این تحقیق مناطق جنگلی نور (شکل ۱)، واقع در استان مازندران می‌باشد. این جنگل‌ها از درختان پهن‌برگ تشکیل یافته و از سایر جنگل‌های ایران متمایز هستند و بین طول جغرافیایی “۵۸° ۰۰’ ۵۲° و عرض جغرافیایی “۵۷° ۲۷’ ۳۶° قرار دارد و ارتفاع منطقه در محدوده ۲۰- تا ۵۰ متر از سطح دریا قرار دارد. در این تحقیق، جنگل مورد مطالعه در چهار کلاس اصلی مورد بررسی قرار گرفت که شامل (۱) پوشش گیاهی مخلوط^۲، (۲) جنگل طبیعی^۳، (۳) جنگل تخریب شده^۴، (۴) ذخایر جنگلی^۵ می‌باشد.

۲-۲- توصیف داده‌ها

۲-۲-۱- داده‌های زمینی

مقادیر زیست‌توده‌ی زمینی برای منطقه‌ی مورد مطالعه در فاصله زمانی ماه‌های اکتبر، نوامبر و دسامبر سال ۲۰۱۷ اندازه‌گیری و برآورد شده‌است. ۸۸ پلات با استفاده از سامانه موقعیت‌یاب جهانی تفاضلی (DGPS) اندازه‌گیری و ثبت شد که کلاس اول (۲۰ پلات)، کلاس دوم (۲۰ پلات)، کلاس سوم (۱۹ پلات) و کلاس چهارم (۲۹ پلات) را شامل می‌شوند. در هر پلات به ترتیب نوع گونه و قطر برابر سینه (DBH)^۶ برای همه گونه‌هایی که DBH آن‌ها بزرگتر از ۷۵ سانتی‌متر بود، برداشت شده‌است. برای محاسبه‌ی میزان زیست‌توده گونه‌ها، به ترتیب برای گونه‌های بلوط بلندمازو و درخت مرمرز از معادله آلومتری قطر-مبنا و گونه خاص [۳۱]. همچنین، برای سایر گونه‌ها از معادله‌ی آلومتری عمومی استفاده شده است [۳۲].

^۲ Mixed plantations

^۳ Natural forest

^۴ Degraded forest

^۵ Forest reserve


^۶ Diameter at breast height

^۱ Growing Stock Volume

۲-۲-۲- تصاویر سنجش از دوری

• تصویر نوری

در این تحقیق از تصویر نوری مربوط به سنجنده Sentinel-2 به تاریخ ۱۹ دسامبر سال ۲۰۱۷ با ۱۳ باند طیفی و تفکیک مکانی ۱۰، ۲۰ و ۶۰ متر استفاده شده است. تصویر نوری ماهواره Sentinel-2 در سطح



شکل ۱- منطقه‌ی مورد مطالعه تحقیق

کیفیت رادیومتریکی تصویر (حذف تداخل ها و کاهش لکه های نویزی) تصویر مورد نظر چند منظر^۲ می شود. پس از آن، با استفاده از عملگر اسپکل^۳ برای از بین بردن نویز اسپکل و عملگر تصحیح زمینی^۴ به منظور نزدیک بودن نمایش هندسی تصویر با واقعیت زمینی بر روی تصویر انجام می شود.

۲-۳- روش تحقیق

مطابق شکل ۲، روش پیشنهادی انجام این تحقیق از سه مرحله اصلی تشکیل شده است که شامل مراحل زیر است:

(۱) با استفاده از داده های زمینی مقدار زیست توده با استفاده از معادلات آلومتریک برآورد می شود و

• تصویر راداری

در این پژوهش همانگونه که پیش از این اشاره شد، از تصویر راداری سنجنده Sentinel-1 به تاریخ ۲۱ دسامبر سال ۲۰۱۷ در حالت های پلاریزاسیون VH و VV در باند C برای برآورد زیست توده استفاده شده است. تصویر راداری ماهواره Sentinel-1 در حالت نواری IW و با فرمت SLC^۱ که هیچ پردازشی بر روی تصویر انجام نگرفته است دریافت شد. از آنجایی که منطقه ی مورد مطالعه در نواری IW1 و در دو Burst ابتدایی این تصویر قرار دارد، از عملگر Split نرم افزار SNAP به منظور تهیه یک محصول جداگانه از این ناحیه استفاده می شود. در ابتدا پردازش کالیبراسیون به منظور تبدیل ارزش پیکسل خام تصویر به مقدار باز پخش زمینی آن پیکسل انجام می پذیرد. سپس، پردازش Deburst برای از بین بردن خطوط سیاه تصویر و یکپارچگی آن انجام می پذیرد. سپس، به منظور افزایش


^۲ Multilook

^۳ Speckle

^۴ Terrain Correction

^۱ Single look complex

^{22}CI ، $^{22}BI2$ ، ^{24}BI و آب ($^{25}NDWI2$ ، $^{26}NDWI$ ، $^{27}NDT1$ ، $^{28}NDPI$ ، $^{29}MNDWI$) تصویر نوری سنجنده Sentinel-2 و ترکیبات ریاضی آن ها به عنوان ورودی های نوری استفاده شد [۳۳، ۳۴].



• استخراج ویژگی از تصویر راداری

برای استخراج ویژگی از تصویر راداری، از ماتریس پراکنش تعدادی متغیر استخراج می شود که دارای همبستگی با مقدار زیست توده هستند. از آنجایی که ویژگی های نسبت بین المانی $^{30} \frac{[VV]^2/[VH]^2}$ ،

پیش پردازش های مورد نیاز بر روی تصویر نوری و راداری انجام می شود. ویژگی های حاصل از ماتریس پراکنش و نسبت های اجزای ماتریس پراکنش و ویژگی های حاصل از تجزیه H/α از تصویر راداری و ویژگی های پوشش گیاهی، خاک و آب از تصویر نوری استخراج می شوند.

۲) مدلسازی رگرسیون خطی چند متغیره یکبار تنها با ویژگی های نوری و یکبار دیگر با ویژگی های راداری و نهایتاً با ترکیب این دو ویژگی انجام می گیرد تا توانایی هر یک از این ترکیب ها در برآورد زیست توده مورد بررسی قرار گیرد. بدین منظور، مدل رگرسیون خطی چند متغیره با مدل رگرسیون بردار پشتیبان مقایسه می شود و مدل ریاضی مناسب تر حاصل از این مقایسه وارد رقابت ژنتیک می شود. ۳) در نهایت متناسب با هر یک از کلاس ها، بهترین ترکیب باندی انتخاب شده توسط الگوریتم ژنتیک در برآورد زیست توده از آن کلاس به کار می رود و نقشه برآورد زیست توده از منطقه ی مورد مطالعه تهیه می شود.

۲-۳-۱- استخراج ویژگی ها

• استخراج ویژگی از تصویر نوری

در این تحقیق، جهت برآورد زیست توده از منطقه ی مورد مطالعه، از ۳۰ ویژگی به علاوه باندهای طیفی تصویر شامل: پوشش گیاهی ($^{1}WDVI$ ، $^{2}SAVI$ ، $^{3}TNDVI$ ، $^{4}PSSRa$ ، ^{5}PVI ، $^{6}RIEP$ ، ^{7}RVI ، $^{8}S2REP$ ، $^{9}SAVI$ ، $^{10}MSAVI2$ ، $^{11}MTCI$ ، $^{12}NDI45$ ، $^{13}NDVI$ ، $^{14}IPVI$ ، $^{15}IRECI$ ، $^{16}MCARI$ ، $^{17}MSAVI$ ، $^{18}GNDVI$ ، $^{19}GEMI$ ، ^{20}DVI ، $^{21}ARVI$)، خاک (^{22}RI)

- ^۱ Weighted Difference Vegetation Index
- ^۲ Transformed Soil Adjusted Vegetation Index
- ^۳ Transformed Normalized Difference Vegetation Index
- ^۴ Soil Adjusted Vegetation Index
- ^۵ Sentinel2 Red-Edge Position Index
- ^۶ Ratio Vegetation Index
- ^۷ Red-Edge Inflection Point Index
- ^۸ Pigment Specific Simple Ratio
- ^۹ Normalized Difference Vegetation Index
- ^{۱۰} Normalized Difference Index
- ^{۱۱} Meris Terrestrial Chlorophyll Index
- ^{۱۲} Second Modified Soil Adjusted Vegetation Index
- ^{۱۳} Modified Soil Adjusted Vegetation Index
- ^{۱۴} Modified Chlorophyll Absorption Ratio Index
- ^{۱۵} Inverted Red-Edge chlorophyll Index
- ^{۱۶} Infrared Percentage Vegetation Index
- ^{۱۷} Green Normalized Difference Vegetation Index
- ^{۱۸} Global Environment Monitoring Index
- ^{۱۹} Difference Vegetation Index
- ^{۲۰} Atmospherically Resistant Vegetation Index
- ^{۲۱} Redness Index

- ^{۲۲} Colour Index
- ^{۲۳} Brightness Index
- ^{۲۴} Second Brightness Index
- ^{۲۵} Normalized Difference Water Index
- ^{۲۶} Second Normalized Difference Water Index
- ^{۲۷} Normalized Difference Turbidity Index
- ^{۲۸} Normalized Difference Pond Index
- ^{۲۹} Modified Normalized Difference Water Index
- ^{۳۰} Division

عنوان متغیر وابسته و باندهای طیفی و ویژگی‌های حاصل از تصویر نوری و ویژگی‌های حاصل از تصویر راداری متغیر مستقل در نظر گرفته می‌شوند. پیش‌بینی براساس متغیرهای مستقل بر روی متغیر وابسته انجام می‌شود.

• رگرسیون بردار پشتیبان

رگرسیون SVR به عنوان یک تکنیک یادگیری نظارت شده معرفی شده است [۳۶]. براساس به حداقل رساندن ریسک ساختاری، SVR مسائل غیر خطی را با ابعاد بالا و نمونه‌های کمی حل می‌کند و در مقایسه با روش‌های دیگر، SVR همگرایی سریع‌تری نشان می‌دهد. به دلیل توانایی آن در تشخیص همبستگی بین داده‌های ورودی و خروجی، مشکلات تخمین تابع چند بعدی را به طور موثرتری حل می‌کند. برای مجموعه‌ای از نقاط آموزشی $\{(X_1, Y_1), (X_2, Y_2), \dots, (X_i, Y_i)\}$ که در آن $X_i \in R$ مقادیر ورودی هستند، $Y_i \in R$ مقادیر خروجی مرتبط X_i هستند و n برابر با تعداد نقاط داده، می‌توان همبستگی مقادیر ورودی و خروجی را با توجه به یک تابع خطی $[f(X)]$ تعریف کرد:

$$f(X_i) = W^T \phi(X_i) + b \quad (2)$$

که در آن $W \in R^n$ و $b \in R^n$ ضرایب قابل تنظیم هستند که به ترتیب بردارهای وزن و بایاس را نشان می‌دهند، تابع غیر خطی $\phi(X)$ برای نگاشت X_i به فضای ویژگی با ابعاد بالا اعمال می‌شود. براساس حداقل‌سازی ریسک ساختاری، W و b به صورت زیر محاسبه می‌شوند [۳۷]:

$$\text{Minimize: } \left[\frac{1}{2} \|W\|^2 + C \sum_{i=1}^n \xi_i + \xi_i^* \right] \quad (3)$$

With the constrains:

$$\begin{cases} Y_i - (W^T \phi(X_i) + b_i) \leq \varepsilon + \xi_i \\ (W^T \phi(X_i) + b_i) - Y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \quad i = 1, 2, \dots, n \end{cases} \quad (4)$$

که در آن $\frac{1}{2} \|W\|^2$ فاکتور منظم‌سازی، C تابع هزینه و ξ_i, ξ_i^* متغیرهای سستی غیر منفی و $\varepsilon > 0$ یک تابع از دست دادن غیر حساس می‌باشد [۳۷، ۳۸].

۲-۳-۳- انتخاب ویژگی

الگوریتم ژنتیک (GA) یکی از رایج‌ترین الگوریتم‌های تکاملی می‌باشد. این روش راه حل‌های بالقوه را برای

$(|VV|^2 + |VH|^2)$ ^۱، $(|VV|^2 - |VH|^2)$ ^۲ و $(|VV| * |VH|)$ ^۳ مستخرج از ماتریس پراکنش بیانگر برخی پارامترهای بیوفیزیکی خاص نظیر زیست‌توده جنگل است، در این مطالعه از آن‌ها نیز در کنار قطبیت‌های اصلی تصویر Sentinel 1 استفاده شد. همچنین، در کنار ویژگی‌های ذکرشده، از سه ویژگی $\text{Alpha} = \alpha$ و $\text{Entropy} = H$ و $\text{Anisotropy} = A$ حاصل از تجزیه ماتریس پراکنش به روش H/α [۳۵] استفاده شد.

۲-۳-۲- مدل‌سازی زیست‌توده جنگلی

در این تحقیق، برای برآورد زیست‌توده از روش مدل‌سازی رگرسیون خطی چند متغیره استفاده شده است و در راستای ارزیابی کیفیت رگرسیون خطی چند متغیره از رگرسیون بردار پشتیبان جهت مقایسه (این مقایسه براساس مقدار خطای RMSE می‌باشد) بدون آنکه در الگوریتم ژنتیک آورده شود، استفاده شده است. به منظور برآورد زیست‌توده، مدل‌سازی با سه ترکیب مختلف از داده‌ها شامل (۱) ویژگی‌های استخراج شده از تصویر نوری (۳۰) ویژگی به علاوه باندهای طیفی تصویر، (۲) ویژگی‌های استخراج شده از تصویر راداری (۹) ویژگی و (۳) ترکیب ویژگی‌های استخراج شده از تصویر نوری و راداری انجام شد. در نهایت، انتخاب بهترین مدل‌ها از مجموعه مدل‌های رگرسیون خطی چندمتغیره و رگرسیون بردار پشتیبان، براساس آماره‌های خطای RMSE، ضریب تعیین و ضریب تعیین تعدیل شده بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده انجام شد.

• رگرسیون خطی چند متغیره

در تحلیل رگرسیونی، نیاز به درک مناسب در مقوله تئوری و عملی مساله دارد. در حالت کلی، متغیر پاسخ ممکن است به k متغیر رگرسیون $X_1, X_2, X_3, \dots, X_k$ مربوط شود، که در این حالت رگرسیون ساده به رگرسیون چندمتغیره تبدیل می‌شود که می‌تواند طبق رابطه زیر تعریف گردد:

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon \quad (1)$$

به طوریکه ε اشاره به خطای مدل رگرسیونی دارد، x و y به ترتیب بیانگر متغیرهای مستقل و وابسته و $\beta_0 \dots \beta_k$ بیانگر بردار پارامترها می‌باشند. در این تحقیق زیست‌توده به

^۱ Plus

^۲ Negative

^۳ Multi

۳- نتایج

۳-۱- مدل‌سازی با ویژگی‌های نوری

تمامی داده‌ها به صورت تصادفی، به دو دسته داده آموزشی (۶۰ درصد داده‌ها) و داده تست (۴۰ درصد داده‌ها) تقسیم‌بندی می‌شوند. همانطور که قبلاً بیان شد، در این تحقیق به منظور برآورد زیست توده، مدل‌سازی با سه ترکیب مختلف از داده‌ها انجام می‌شود. جدول ۱) ضریب تعیین و ضریب تعیین تعدیل‌شده و خطای RMSE ویژگی‌های نوری را با استفاده از رگرسیون خطی چند متغیره و رگرسیون بردار پشتیبان در چهار کلاس پوشش گیاهی نشان می‌دهد. مطابق با جدول ۱، بهترین مقدار برآورد زیست توده با استفاده از مدل‌سازی رگرسیون خطی چند متغیره در کلاس چهارم پوشش گیاهی با ضریب تعیین ۰/۸۰ و خطای RMSE ۹/۱۲ تن بر هکتار می‌باشد. بهترین مقدار برآورد زیست توده با رگرسیون بردار پشتیبان در کلاس سوم پوشش گیاهی با ضریب تعیین ۰/۵۶ و خطای RMSE ۱۹/۲۵ تن بر هکتار می‌باشد. شاخص‌های پوشش گیاهی $^{۴}NDVI$ ، $^{۵}TNDVI$ و ^{۶}RVI در هر چهار کلاس پوشش گیاهی، شاخص‌هایی تأثیر گذار برای برآورد زیست توده با دقتی بالا بودند. شکل ۳ نمودارهای پراکنندگی در چهار کلاس پوشش گیاهی با ویژگی‌های نوری را با عنوان Model 1 نشان می‌دهد.

۳-۲- مدل‌سازی با ویژگی‌های راداری

ضریب تعیین و ضریب تعیین تعدیل‌شده و خطای RMSE ویژگی‌های راداری با استفاده از رگرسیون خطی چند متغیره و رگرسیون بردار پشتیبان در چهار کلاس پوشش گیاهی در جدول ۲ آورده شده‌است. مطابق با جدول ۲ و مشاهده‌ی مقادیر آماره‌های ضریب تعیین، ضریب تعیین تعدیل‌شده و خطای RMSE عملکرد ضعیف ترکیب داده‌های راداری را در برابر ترکیب داده‌های نوری نشان می‌دهد.

بهینه‌سازی مشکلات در زمان مناسب به ویژه زمانی که فضای جستجو بسیار گسترده باشد پیدا می‌کند [۳۹]. این الگوریتم تولید مثل، ترکیب^۱ و جهش‌های^۲ ژنتیکی را که در طی انتخاب طبیعی و فرآیندهای ژنتیکی رخ می‌دهد، شبیه‌سازی می‌کند. که مجموعه‌ای از راه حل‌های کاندید را در هر مرحله حفظ می‌کند و افراد بهتری را از نظر جمعیت براساس معیارهای خاص انتخاب می‌کند. سپس، از طریق انتخاب، ترکیب و تغییر، نسل جدیدی را از جمعیت‌های کاندید ایجاد می‌کند. این روند را تا زمانی که شرط همگرایی خاصی برآورده شود تکرار می‌کند. الگوریتم ژنتیک شامل یک مکانیزم کد گذاری، تابع تناسب^۳ است که عملکرد تابع تناسب جهت جستجو را هدایت می‌کند [۴۰]. ویژگی ممکن است به صورت فردی برای برآورد زیست توده مناسب نباشد و نمی‌توان به بهینه بودن ترکیب ویژگی‌های انتخاب‌شده اطمینان داشت که در کیفیت نتیجه‌ی نهایی می‌تواند تأثیر گذار باشد. به عبارتی دیگر، ترکیب ویژگی‌ها تا یک حدی دقت را بهبود می‌دهد. از این رو، در این تحقیق از بهینه‌سازی الگوریتم ژنتیک استفاده شده‌است. تابع تناسبی که در این تحقیق برای انتخاب ترکیب باندی بهینه از بین ویژگی‌های نوری و رادار در نظر گرفته شده‌است، مطابق با رابطه زیر محاسبه می‌گردد:

$$\text{Fitness Function} = \frac{1}{\text{RMSE}} \quad (۵)$$

$$\text{RMSE} = \sqrt{\sum_{i=1}^n (y_i^{\text{obs}} - y_i^{\text{pred}})^2 / n} \quad (۶)$$





رابطه (۶) نمایانگر خطای RMSE می‌باشد، که در آن y^{obs} مقادیر زمینی زیست توده و y^{pred} مقادیر سنجش از دوری است. در الگوریتم ژنتیک، طراحی مناسب عملکرد تابع تناسب می‌تواند زمان بهینه‌سازی را کاهش داده و کارایی بهینه‌سازی را بهبود بخشد. عملکرد تابع تناسب نیروی محرکه‌ی فرآیند الگوریتم ژنتیک است و باید مطابق با الزامات حل مسئله خود طراحی شود.

^۴ Normalized Difference Vegetation Index
^۵ Transformed Soil Adjusted Vegetation Index
^۶ Ratio Vegetation Index

^۱ Crossover
^۲ Mutation
^۳ Fitness function

جدول ۱- ضریب تعیین و ضریب تعیین تعدیل شده و خطای RMSE ویژگی های نوری با استفاده از رگرسیون خطی چند متغیره و رگرسیون بردار پشتیبان در چهار کلاس پوشش گیاهی

روش	نوع جنگل	ویژگی	R^2 (%)	Adjusted R^2 (%)	RMSE (Ton/ha)
رگرسیون خطی چند متغیره	کلاس اول	TNDVI, RVI, PSSra, NDVI, NDPI	۰/۶۶	۰/۶۰	۲۱/۳۵
	کلاس دوم	WDVI, TNDVI, RVI, ARVI, IPVI	۰/۷۹	۰/۷۸	۱۷/۱۰
	کلاس سوم	SAVI, RVI, NDVI, MCARI, GNDVI	۰/۴۲	۰/۲۰	۷/۹۶
	کلاس چهارم	TNDVI, PSSra, IRECI, NDVI, IPVI	۰/۸۰	۰/۸۰	۹/۱۲
رگرسیون بردار پشتیبان	کلاس اول	TNDVI, RVI, PSSra, NDVI, NDPI	۰/۵۱	۰/۴۴	۲۰/۷۸۶
	کلاس دوم	WDVI, TNDVI, RVI, ARVI, IPVI	۰/۷۳	۰/۷۰	۵۶/۴۴
	کلاس سوم	SAVI, RVI, NDVI, MCARI, GNDVI	۰/۵۶	۰/۵۵	۱۹/۲۵
	کلاس چهارم	TNDVI, PSSra, IRECI, NDVI, IPVI	۰/۳۷	۰/۳۸	۲۲/۱۳




شکل ۳- نمودارهای پراکندگی در چهار کلاس پوشش گیاهی با ویژگی های نوری تحت عنوان (Model 1) می باشد. (ترتیب نمودارها: کلاس اول (الف)، کلاس دوم (ب)، کلاس سوم (ج) و کلاس چهارم (د))

جدول ۲- ضریب تعیین و ضریب تعیین تعدیل شده و خطای RMSE ویژگی های راداری با استفاده از رگرسیون خطی چند متغیره و رگرسیون بردار پشتیبان در چهار کلاس پوشش گیاهی

روش	نوع جنگل	ویژگی	R^2 (%)	Adjusted R^2 (%)	RMSE (Ton/ha)
رگرسیون خطی چند متغیره	کلاس اول	Negative, Division, Anistropy, Sigma VH, Plus	۰/۴۱	۰/۲۵	۳۰/۴۴
	کلاس دوم	Division, Multi, Sigma VH, Negative, Anistropy	۰/۵۱	۰/۳۳	۲۰/۰۱
	کلاس سوم	Sigma VH, Plus, Multi, Negative, Division	۰/۳۶	۰/۳۶	۸/۰۱۲
	کلاس چهارم	Sigma VH, Plus, Negative, Multi, Alpha	۰/۳۲	۰/۳۱	۱۴/۲۱
رگرسیون بردار پشتیبان	کلاس اول	Negative, Division, Anistropy, Sigma VH, Plus	۰/۲۳	۰/۲۳	۱۵۴/۰۶
	کلاس دوم	Division, Multi, Sigma VH, Negative, Anistropy	۰/۳۴	۰/۳۲	۹۰/۰۵
	کلاس سوم	Sigma VH, Plus, Multi, Negative, Division	۰/۴۵	۰/۴۵	۲۰/۰۱
	کلاس چهارم	Sigma VH, Plus, Negative, Multi, Alpha	۰/۴۸	۰/۴۵	۱۹/۲۰

بهترین مقدار برآورد زیست توده با ترکیب ویژگی‌های راداری و با استفاده از مدلسازی رگرسیون خطی چند متغیره مربوط به کلاس دوم پوشش گیاهی با ضریب تعیین 0.51 و خطای RMSE 20.01 تن بر هکتار است. همچنین، بهترین مقدار برآورد زیست توده با استفاده از رگرسیون بردار پشتیبان مربوط به کلاس چهارم پوشش گیاهی با ضریب تعیین 0.48 و خطای RMSE 19.20 تن

بر هکتار می‌باشد. از بین ویژگی‌های راداری Sigma VH و نسبت‌های المانی (Division، Plus، Multi، Negative) ویژگی‌هایی تاثیر گذار برای برآورد زیست توده در چهار کلاس پوشش گیاهی با دقتی بالا بودند. شکل ۴ نمودارهای پراکندگی در چهار کلاس پوشش گیاهی با ویژگی‌های راداری را با عنوان Model 2 نشان می‌دهد.



شکل ۴- نمودارهای پراکندگی در چهار کلاس پوشش گیاهی با ویژگی‌های راداری تحت عنوان (Model 2) می‌باشد. (ترتیب نمودارها کلاس اول (الف)، کلاس دوم (ب)، کلاس سوم (ج) و کلاس چهارم (د))

۳-۳- مدلسازی با ترکیب ویژگی‌های نوری و راداری

اکنون مدلسازی با ترکیب دو ویژگی نوری و راداری برای برآورد زیست توده انجام می‌شود. به این منظور، دو نوع ترکیب برای ویژگی‌های راداری و نوری در نظر گرفته شده‌است؛ این دو ترکیب شامل (۱) ترکیب چهار ویژگی نوری و یک ویژگی راداری، (۲) ترکیب چهار ویژگی راداری و یک ویژگی نوری می‌باشد. جدول ۳ ضریب تعیین و ضریب تعیین تعدیل شده و خطای RMSE ترکیب ویژگی‌های رادار و نوری را با رگرسیون خطی چند متغیره نشان می‌دهد.

مطابق با جدول ۳ بهترین مقدار برآورد زیست توده با استفاده از رگرسیون خطی چند متغیره مربوط به کلاس دوم پوشش گیاهی با ضریب تعیین 0.85 و خطای RMSE 16.35 تن بر هکتار می‌باشد. هنگامی که از چهار ویژگی

نوری و یک ویژگی راداری برای ترکیب استفاده شده‌است، مقادیر ضریب تعیین، ضریب تعیین تعدیل شده و خطای RMSE بهتر از زمانی است که از چهار ویژگی راداری در ترکیب استفاده شده‌است. پس می‌توان نتیجه گرفت، هر چه تعداد ویژگی‌های طیفی بیش‌تر باشد دقت برآورد زیست توده بهتر می‌شود. شکل ۵ نمودارهای پراکندگی در چهار کلاس پوشش گیاهی با ترکیب ویژگی‌های نوری و راداری با عنوان Model 3 نشان می‌دهد.





ضریب تعیین و ضریب تعیین تعدیل شده و خطای RMSE ترکیب ویژگی‌های رادار و نوری با استفاده از رگرسیون بردار پشتیبان در جدول ۴ ارائه شده‌است. مطابق با جدول ۴، بهترین مقدار برآورد زیست توده مربوط به کلاس چهارم پوشش گیاهی با ضریب تعیین 0.72 و خطای RMSE 14.94 تن بر هکتار می‌باشد.

جدول ۳- ضریب تعیین و ضریب تعیین تعدیل شده و خطای RMSE ترکیب ویژگی های رادار و نوری با استفاده از رگرسیون خطی چند متغیره

نوع جنگل	ویژگی	$R^2(\%)$	Adjusted $R^2(\%)$	RMSE (Ton/ha)
کلاس اول	NDPI, RVI, PSSra, NDVI, Division	۰/۷۰	۰/۶۲	۱۹/۸۹
	Sigma VH, Plus, Negative, Division, NDPI	۰/۷۴	۰/۶۸	۱۹/۴۵
کلاس دوم	TNDVI, RVI, ARVI, IPVI, Negative	۰/۸۵	۰/۸۱	۱۶/۳۵
	Negative, Sigma VH, Multi, Division, RV	۰/۸۱	۰/۷۴	۱۶/۹۸
کلاس سوم	NDVI, RVI, MCARI, GNDVI, Plus	۰/۶۶	۰/۵۲	۷/۳۲
	Plus, Multi, Sigma VH, Negative, NDVI	۰/۶۵	۰/۵۵	۷/۰۳
کلاس چهارم	NDVI, PSSra, IPVI, TNDVI, Sigma VH	۰/۷۷	۰/۷۴	۸/۲۵
	Sigma VH, Plus, Negative, Alpha, NDVI	۰/۷۶	۰/۷۲	۸/۹۵

جدول ۴- ضریب تعیین و ضریب تعیین تعدیل شده و خطای RMSE ترکیب ویژگی های رادار و نوری با استفاده از رگرسیون بردار پشتیبان

نوع جنگل	ویژگی	$R^2(\%)$	Adjusted $R^2(\%)$	RMSE (Ton/ha)
کلاس اول	NDPI, RVI, PSSra, NDVI, Division	۰/۵۰	۰/۵۰	۲۱/۰۱
	Sigma VH, Plus, Negative, Division, NDPI	۰/۲۰	۰/۱۹	۲۹/۴۹
کلاس دوم	TNDVI, RVI, ARVI, IPVI, Negative	۰/۶۷	۰/۶۷	۶۲/۲۵
	Negative, Sigma VH, Multi, Division, RV	۰/۶۵	۰/۶۴	۶۴/۴۱
کلاس سوم	NDVI, RVI, MCARI, GNDVI, Plus	۰/۴۷	۰/۴۵	۱۵/۳۲
	Plus, Multi, Sigma VH, Negative, NDVI	۰/۴۸	۰/۴۸	۱۵/۱۹
کلاس چهارم	NDVI, PSSra, IPVI, TNDVI, Sigma VH	۰/۷۲	۰/۷۲	۱۴/۹۴
	Sigma VH, Plus, Negative, Alpha, NDVI	۰/۶۶	۰/۶۶	۱۶/۲۸



شکل ۵- نمودارهای پراکندگی در چهار کلاس پوشش گیاهی با ترکیب ویژگی های نوری و راداری تحت عنوان (Model 3) می باشد. (ترتیب نمودارها: کلاس اول (الف)، کلاس دوم (ب)، کلاس سوم (ج) و کلاس چهارم (د))

۳-۴- انتخاب بهترین ترکیب باندی با الگوریتم ژنتیک

از الگوریتم ژنتیک برای انتخاب بهترین ترکیب باندی از بین تمام ویژگی‌های نوری و راداری استفاده می‌شود، به این منظور، ابتدا پارامترهای مربوط به استفاده از الگوریتم ژنتیک از قبیل جمعیت اولیه، ترکیب، جهش که تنظیم شدند، در جدول ۵ آورده می‌شوند.


جدول ۵- پارامترهای الگوریتم ژنتیک

پارامتر	مقادیر
جمعیت	۱۰۰
نرخ ترکیب	۰/۲
نرخ جهش	۰/۲۵
تعداد نسل	۱۰۰۰


بر اساس تابع تناسبی که در نظر گرفته شده‌است، یک نمودار دقت و تکرار برنامه نشان می‌دهد، این مقدار هرچه بالاتر باشد شایستگی بالاتری دارد. در نتیجه، تعدادی از بهترین ویژگی‌ها نشان داده می‌شود، و مقدار RMSE (Ton/ha) پایین‌تر و مناسب‌تری براساس تمام ویژگی‌ها نه

تنها بعضی از ویژگی‌ها بدست می‌آید. نتیجه همگرایی حاصل از الگوریتم ژنتیک با تکرار ۱۰۰۰ نسل مربوط به چهار کلاس پوشش گیاهی در شکل ۶ تایید می‌شود.


این تحقیق به ازای چهار کلاس پوشش گیاهی ترکیب باندی‌های مختلفی نشان می‌دهد. جدول ۶ ضریب تعیین و ضریب تعیین تعدیل‌شده و خطای RMSE به کمک الگوریتم ژنتیک در چهار کلاس تحقیق را نشان می‌دهد. مطابق با جدول (۶) میزان دقت برآورد زیست‌توده در کلاس دوم پوشش گیاهی با ضریب تعیین ۰/۸۷ و خطای RMSE ۲۳/۶۸ تن بر هکتار به نسبت بقیه‌ی کلاس‌های پوشش گیاهی بالا می‌باشد. همچنین، مشاهده می‌شود ویژگی‌های طیفی حاصل از Sentinel-2 شامل NIR، لبه قرمز و SWIR و شاخص‌های پوشش گیاهی و ویژگی‌های راداری حاصل از Sentinel-1 شامل Sigma VH و ویژگی‌های حاصل از تجزیه H/a از جمله ویژگی‌های تاثیر گذار در برآورد زیست‌توده است. در نهایت، نقشه‌ی برآورد زیست‌توده بوسیله نرم‌افزار QGIS از منطقه تحقیق تهیه می‌شود. شکل ۷ نقشه‌ی برآورد زیست‌توده را از منطقه تحقیق نشان می‌دهد.




(ب)



(الف)



(د)




(ج)

شکل ۶- نتیجه‌ی همگرایی الگوریتم ژنتیک با تکرار ۱۰۰۰ نسل برای چهار کلاس پوشش گیاهی: (الف) کلاس اول، (ب) کلاس دوم، (ج) کلاس سوم و (د) کلاس چهارم

جدول ۶- ضریب تعیین و ضریب تعیین تعدیل شده و خطای RMSE بهترین ترکیب باندی به کمک الگوریتم ژنتیک در چهار کلاس تحقیق

نوع جنگل	ویژگی	R ² (%)	Adjusted R ² (%)	RMSE (Ton/ha)
کلاس اول	B4, B5, B8a, B11, TNDVI, RVI, MTCI, MSAVI2, MSAVI, IPVI, DVI, NDVI, Plus, Multi, Entropy, Alpha	۰/۷۸	۰/۷۵	۱۶/۹۷
کلاس دوم	B4, B5, B8a, NDVI, MTCI, GNDVI, GEMI, NDPI, Sigma VH, Plus, Division, Anisotropy, Alpha	۰/۸۷	۰/۸۷	۲۳/۶۸
کلاس سوم	B4, B8a, B12, TSAVI, NDVI, RVI, PVI, PSSRA, GNDVI, Sigma VH, Anisotropy	۰/۶۸	۰/۶۸	۱۹/۲۳
کلاس چهارم	B4, B5, B11, B12, RVI, PSSRA, NDVI, MSAVI2, GEMI, RI, Sigma VH, Plus, Multi, Entropy	۰/۷۹	۰/۷۷	۱۳/۰۹



شکل ۷- نقشه‌ی برآورد زیست‌توده

۴- بحث و بررسی

(۲۰۱۴) انجام شد، استفاده از تصویرهای راداری سنجنده پالسر در کنار تصویرهای نوری سنجنده +ETM، مقدار ضریب تعیین و خطای RMSE بهبود بخشید [۲۲]. مقایسه‌ی ارزیابی کیفیت رگرسیون خطی چند متغیره با رگرسیون بردار پشتیبان و نتایج حاصل از جداول ۱، ۲، ۳ و ۴ مقدار بالای خطای RMSE را به هنگام استفاده از رگرسیون بردار پشتیبان نشان می‌دهد. در این رابطه، نتایج تحقیق Baloloy و همکاران (۲۰۱۸)، نشان داد مدل رگرسیون خطی چند متغیره با استفاده از تصویر نوری Sentinel-2 مقدار خطای RMSE پایین‌تری را نشان می‌دهد [۱۲].

در رابطه با استفاده از الگوریتم ژنتیک به منظور بهبود دقت برآورد زیست‌توده نیز نتایج تحقیق Negar Tavasoli و همکار (۲۰۲۱)، نشان داد که در صورت استفاده از ترکیب دو تصویر راداری PALSAR و Sentinel-1 و بکارگیری الگوریتم ژنتیک با مدلسازی رگرسیون RF،

با توجه به نتایج، بهترین مدل برای برآورد زیست‌توده با استفاده از تصاویر راداری و نوری با بیشترین مقدار ضریب تعیین و کمترین مقدار خطای RMSE هنگامی بود که از ترکیب ویژگی‌های این دو تصویر برای برآورد زیست‌توده در چهار کلاس پوشش گیاهی استفاده شده بود. در این رابطه، تحقیقات انجام‌شده در جنگل با استفاده از ترکیب ویژگی‌های دو تصویر راداری و نوری از جمله نتایج تحقیق Narissara Nuthammachot و همکاران (۲۰۲۰)، نشان داد در صورت استفاده از تصویر راداری سنجنده Sentinel-1 در کنار تصویر نوری Sentinel-2، مقدار ضریب تعیین و خطای RMSE برآورد از ۰/۷۷ و ۲۴/۱۹ تن بر هکتار به ۰/۷۹ و ۲۲/۹۸ تن بر هکتار بهبود خواهد یافت که با نتایج پژوهش پیش رو همخوانی دارد [۱۹]. در تحقیقی دیگر که توسط Attarchi و Gloaguen

مقدار ضریب تعیین را به نسبت زمانی که تنها از ویژگی‌های نوری برای برآورد زیست توده استفاده شده بود بهبود می‌دهد [۲۵]. در تحقیق دیگری که توسط Latifi و همکاران (۲۰۱۹) انجام شد، از الگوریتم ژنتیک و ترکیب تصاویر راداری و نوری برای تخمین ذخیره در حال رشد (یکی از ویژگی‌های مهم بیوفیزیکی جنگل است که رابطه نزدیکی با زیست توده دارد) استفاده شد. استفاده از الگوریتم ژنتیک در این تحقیق نشان داد که، مقدار ضریب تعیین و خطای RMSE در پنج هسته رگرسیون بردار پشتیبان بهبود یافته است [۲۶].

۵- نتیجه‌گیری

در این پژوهش از ترکیب ویژگی‌های حاصل از تصاویر نوری و راداری و همچنین استفاده از الگوریتم فراابتکاری ژنتیک به منظور بهبود دقت تخمین زیست توده در منطقه جنگلی نور در شمال ایران در چهار کلاس اصلی که شامل (۱) پوشش گیاهی مخلوط، (۲) جنگل طبیعی، (۳) جنگل تخریب شده، (۴) ذخایر جنگلی می‌باشند استفاده شد. در راستای ارزیابی کیفیت رگرسیون خطی چند متغیره از

رگرسیون بردار پشتیبان براساس مقدار RMSE به منظور مقایسه استفاده شد. همچنین، ارزیابی نتایج حاصل از اعمال رگرسیون خطی چند متغیره با کمترین مقدار خطای RMSE نشان داد که استفاده از ویژگی‌های انتخاب شده مبتنی بر الگوریتم ژنتیک در این مدل، منجر به افزایش دقت ضریب تعیین R^2 به میزان ۰/۷۸، ۰/۸۷، ۰/۶۸ و ۰/۷۹ به ترتیب در کلاس‌های اول تا چهارم پوشش گیاهی شده‌است. در پایان، به منظور تکمیل و دستیابی به نتایج بهتر پیشنهاد می‌گردد که تحقیقات آتی از روش تداخل سنجی تصاویر راداری به منظور برآورد زیست توده استفاده کنند. همچنین، پیشنهاد می‌گردد که به منظور پایش روند تغییرات زیست توده از آنالیز سری زمانی بهره گرفته شود. همچنین، در تحقیقات آتی می‌توان عملکرد دیگر الگوریتم‌های فراابتکاری را با الگوریتم ژنتیک مقایسه نمود. ضمناً، می‌توان از سایر روش‌های یادگیری ترکیبی و طبقه‌بندی مانند روش جنگل تصادفی و آنالیز حساسیت بر روی منطقه مورد مطالعه یا سایر مناطق مشابه استفاده نمود.

مراجع

- [1] FAO, "FAO, "Global Forest Resources. Assessment 2010," FAO, "Global Forest Resources. Assessment 2010," no. Food and Agriculture Organization of the United Nations, 2010., 2010. .
- [2] M. Main-Knorn, G. G. Moisen, S. P. Healey, W. S. Keeton, E. A. Freeman, and P. Hostert, "Evaluating the remote sensing and inventory-based estimation of biomass in the western carpathians," *Remote Sens.*, vol. 3, no. 7, pp. 1427–1446, 2011, doi: 10.3390/rs3071427.
- [3] D. Lu, "Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon," *Int. J. Remote Sens.*, vol. 26, no. 12, pp. 2509–2525, 2005, doi: 10.1080/01431160500142145.
- [4] G. M. Foody, D. S. Boyd, and M. E. J. Cutler, "Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions," *Remote Sens. Environ.*, vol. 85, no. 4, pp. 463–474, 2003, doi: 10.1016/S0034-4257(03)00039-7.
- [5] L. Theodor, E. Næsset, T. Gobakken, T. G. Gregoire, G. Ståhl, and S. Holm, "Remote Sensing of Environment A simulation approach for accuracy assessment of two-phase post-stratified estimation in large-area LiDAR biomass surveys," *Remote Sens. Environ.*, vol. 133, pp. 210–224, 2013, doi: 10.1016/j.rse.2013.02.002.
- [6] C. Wu and K. Wang, "Comparison of machine-learning methods for above-ground biomass estimation based on Landsat imagery," vol. 10, no. 3, 2016, doi: 10.1117/1.JRS.10.035010.
- [7] L. Chen, C. Ren, B. Zhang, Z. Wang, and Y. Xi, "Estimation of forest above-ground biomass by geographically weighted regression and machine learning with sentinel imagery," *Forests*, vol. 9, no. 10, pp. 1–20, 2018, doi: 10.3390/f9100582.
- [8] I. Indirabai, M. V. Harindranathan Nair, J. R. Nair, and R. R. Nidamanuri, "Optical Remote Sensing for Biophysical Characterisation in Forests: A Review," *Int. J. Appl. Eng. Res.*, vol. 14, no. 2, p. 344, 2019, doi: 10.37622/ijaer/14.2.2019.344-354.
- [9] L. Kumar and O. Mutanga, "Remote sensing of above-ground biomass," *Remote Sens.*, vol. 9, no. 9, pp. 1–8, 2017, doi: 10.3390/rs9090935.

- [10] L. Kumar, P. Sinha, S. Taylor, and A. F. Alqurashi, "Review of the use of remote sensing for biomass estimation to support renewable energy generation," *J. Appl. Remote Sens.*, vol. 9, no. 1, p. 097696, 2015, doi: 10.1117/1.jrs.9.097696.
- [11] N. Clerici, K. Rubiano, A. Abd-Elrahman, J. M. P. Hoestettler, and F. J. Escobedo, "Estimating aboveground biomass and carbon stocks in periurban Andean secondary forests using very high resolution imagery," *Forests*, vol. 7, no. 7, 2016, doi: 10.3390/f7070138.
- [12] A. Balidoy Baloloy et al., "ESTIMATION of MANGROVE FOREST ABOVEGROUND BIOMASS USING MULTISPECTRAL BANDS, VEGETATION INDICES and BIOPHYSICAL VARIABLES DERIVED from OPTICAL SATELLITE IMAGERIES: RAPIDEYE, PLANETSCOPE and SENTINEL-2," *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 4, no. 3, pp. 29–36, 2018, doi: 10.5194/isprs-annals-IV-3-29-2018.
- [13] G. Zhang et al., "Estimation of forest aboveground biomass in california using canopy height and leaf area index estimated from satellite data," *Remote Sens. Environ.*, vol. 151, pp. 44–56, 2014, doi: 10.1016/j.rse.2014.01.025.
- [14] S. Sinha, C. Jeganathan, L. K. Sharma, and M. S. Nathawat, "A review of radar remote sensing for biomass estimation," *Int. J. Environ. Sci. Technol.*, vol. 12, no. 5, pp. 1779–1792, 2015, doi: 10.1007/s13762-015-0750-0.
- [15] G. Patenaude, R. Milne, and T. P. Dawson, "Synthesis of remote sensing approaches for forest carbon estimation: reporting to the Kyoto Protocol," *Environ. Sci. Policy*, vol. 8, no. 2, pp. 161–178, 2005, doi: 10.1016/j.envsci.2004.12.010.
- [16] A. B. Debastiani, C. R. Sanquetta, A. P. D. Corte, F. E. Rex, and N. S. Pinto, "Evaluating SAR-optical sensor fusion for aboveground biomass estimation in a Brazilian tropical forest," *Ann. For. Res.*, vol. 62, no. 1, pp. 109–122, 2019, doi: 10.15287/afr.2018.1267.
- [17] S. S. Saatchi and M. Moghaddam, "Estimation of crown and stem water content and biomass of boreal forest using polarimetric SAR imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 38, no. 2 I, pp. 697–709, 2000, doi: 10.1109/36.841999.
- [18] G. Sun, K. J. Ranson, and V. I. Kharuk, "Radiometric slope correction for forest biomass estimation from SAR data in the Western Sayani Mountains, Siberia," *Remote Sens. Environ.*, vol. 79, no. 2–3, pp. 279–287, 2002, doi: 10.1016/S0034-4257(01)00279-6.
- [19] N. Nuthammachot, A. Askar, D. Stratoulis, and P. Wicaksono, "Combined use of Sentinel-1 and Sentinel-2 data for improving above-ground biomass estimation," *Geocarto Int.*, vol. 0, no. 0, pp. 1–11, 2020, doi: 10.1080/10106049.2020.1726507.
- [20] K. Van Tricht, A. Gobin, S. Gilliams, and I. Piccard, "Synergistic use of radar sentinel-1 and optical sentinel-2 imagery for crop mapping: A case study for Belgium," *Remote Sens.*, vol. 10, no. 10, pp. 1–22, 2018, doi: 10.3390/rs10101642.
- [21] N. Ghasemi, M. R. Sahebi, and A. Mohammadzadeh, "Biomass estimation of a temperate deciduous forest using wavelet analysis," *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 2, pp. 765–776, 2013, doi: 10.1109/TGRS.2012.2205260.
- [22] S. Attarchi and R. Gloaguen, "Improving the estimation of above ground biomass using dual polarimetric PALSAR and ETM+ data in the Hyrcanian mountain forest (Iran)," *Remote Sens.*, vol. 6, no. 5, pp. 3693–3715, 2014, doi: 10.3390/rs6053693.
- [23] C. Huang, X. Ye, C. Deng, Z. Zhang, and Z. Wan, "Mapping above-ground biomass by integrating optical and SAR imagery: A case study of Xixi National Wetland Park, China," *Remote Sens.*, vol. 8, no. 8, 2016, doi: 10.3390/rs8080647.
- [24] T. D. Pham, K. Yoshino, N. N. Le, and D. T. Bui, "Estimating aboveground biomass of a mangrove plantation on the Northern coast of Vietnam using machine learning techniques with an integration of ALOS-2 PALSAR-2 and Sentinel-2A data," *Int. J. Remote Sens.*, vol. 39, no. 22, pp. 7761–7788, 2018, doi: 10.1080/01431161.2018.1471544.
- [25] N. Tavasoli and H. Arefi, "Comparison of Capability of SAR and Optical Data in Mapping Forest above Ground Biomass Based on Machine Learning," *Environ. Sci. Proc.*, vol. 5, no. 1, p. 13, 2020, doi: 10.3390/iecg2020-07916.
- [26] M. S. Ataee, Y. Maghsoudi, H. Latifi, and F. Fadaie, "Improving estimation accuracy of growing stock by multi-frequency SAR and multi-spectral data over Iran's heterogeneously-structured broadleaf Hyrcanian forests," *Forests*, vol. 10, no. 8, pp. 1–18, 2019, doi: 10.3390/f10080641.
- [27] E. Chiarito et al., "Biomass retrieval based on genetic algorithm feature selection and support vector regression in Alpine grassland using ground-based hyperspectral and Sentinel-1 SAR data," *Eur. J. Remote Sens.*, vol. 54, no. 1, pp. 209–225, 2021, doi: 10.1080/22797254.2021.1901063.

- [28] M. Pal and G. M. Foody, "Feature selection for classification of hyperspectral data by SVM," *IEEE Trans. Geosci. Remote Sens.*, vol. 48, no. 5, pp. 2297–2307, 2010, doi: 10.1109/TGRS.2009.2039484.
- [29] M. Tohidifar, M. Moser, B. Zehzad, and T. Ghadirian, "Biodiversity of the Hyrcanian Forests. A synthesis report," *UNDP/GEF/FRWO Casp. Hyrcanian For. Proj.*, no. October, p. 41p, 2016, doi: 10.13140/RG.2.2.31436.00649.
- [30] H. F.-U. W. H. Centre., "Hyrcanian Forests - UNESCO World Heritage Centre," <https://whc.unesco.org/en/list/1584>, 2021. .
- [31] and C. A. C. U. Shahrokhzadeh, H. Sohrabi, ""Aboveground biomass and leaf area equations for three common tree species of Hyrcanian temperate forests in northern Iran," *Botany*, 2015, doi: 10.1139/cjb-2015-0078.
- [32] D. Zianis and M. Mencuccini, "On simplifying allometric analyses of forest biomass," *For. Ecol. Manage.*, vol. 187, no. 2–3, pp. 311–332, 2004, doi: 10.1016/j.foreco.2003.07.007.
- [33] F. F. Muhsoni, A. B. Sambah, M. Mahmudi, and D. G. R. Wiadnya, "Comparison of different vegetation indices for assessing mangrove density using sentinel-2 imagery," *Int. J. GEOMATE*, vol. 14, no. 45, pp. 42–51, 2018, doi: 10.21660/2018.45.7177.
- [34] M. Barzegar, H. Ebadi, and A. Kiani, "Comparison of different vegetation indices for very high-resolution images, specific case UltraCam-D imagery," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 40, no. 1W5, pp. 97–104, 2015, doi: 10.5194/isprsarchives-XL-1-W5-97-2015.
- [35] P. E. Lee Jong-Sen, *Polarimetric radar imaging: from basics to applications*. Boca Raton: CRC Press, 2009.
- [36] V. Vapnik, *The Nature of Statistical Learning Theory*. Springer, New York., 1995.
- [37] V. Vapnik, *Statistical Learning Theory 1*. Wiley, New York. p. 624., 1998.
- [38] A. L. Balogun et al., "Spatial prediction of landslide susceptibility in western Serbia using hybrid support vector regression (SVR) with GWO, BAT and COA algorithms," *Geosci. Front.*, vol. 12, no. 3, 2021, doi: 10.1016/j.gsf.2020.10.009.
- [39] J. H. Goldberg, D. E.; Holland, "Genetic Algorithms and Machine LearningNo Title," 1988, doi: <https://doi.org/10.1023/A:1022602019183>.
- [40] X. Y. and M. Gen, "Introduction to evolutionary algorithms," London ; New York Springer, 2010.