

## به‌کارگیری الگوریتم‌های یادگیری ماشین، تصاویر لندست ۸ و سنتینل ۲ برای برآورد تراکم تاج‌پوشش جنگل‌های زاگرس

احمد عباسی‌وند<sup>۱</sup>، هرمز سهرابی<sup>۲\*</sup>، مزده میرکی<sup>۳</sup>

<sup>۱</sup> گروه علوم و مهندسی جنگل، دانشکده منابع طبیعی، دانشگاه تربیت مدرس  
abbasiwand@gmail.com

<sup>۲</sup> گروه علوم و مهندسی جنگل، دانشکده منابع طبیعی، دانشگاه تربیت مدرس  
hsohrabi@modares.ac.ir

<sup>۳</sup> گروه علوم و مهندسی جنگل، دانشکده منابع طبیعی، دانشگاه تربیت مدرس  
mojde.miraki@gmail.com

(دریافت: آذر ۱۴۰۳، تصویب: خرداد ۱۴۰۴)

### چکیده

تاج‌پوشش به‌عنوان یک متغیر اساسی و حیاتی در ارتباط با ارزیابی، پایش و مدیریت جنگل‌های زاگرس اهمیت بسیار زیادی دارد. به دلیل اینکه تاج‌پوشش جنگل می‌تواند تغییرات مختلفی را نشان دهد، مدیران جنگل و نهادهای مرتبط همواره به دنبال به‌روزرسانی دقیق نقشه‌ها و اطلاعات مربوط به این متغیر برای مدیریت بهتر جنگل‌ها هستند. استفاده از تصاویر ماهواره‌ای و مدل‌های یادگیری ماشین کمک می‌کند که درک بهتری از اکوسیستم‌های جنگلی کسب شود. این درک باعث می‌شود که بتوان راهکارهای بهتری برای حفظ طبیعت و جلوگیری از هدر رفت منابع طبیعی پیدا کرد. در این مطالعه، از داده‌های تصویری به دست آمده از ماهواره‌های سنتینل ۲ و لندست ۸ بهره برده شده و با استفاده از مدل‌های یادگیری ماشین، اطلاعات مربوط به تاج‌پوشش جنگل‌های زاگرس مدل‌سازی شد. مدل‌های یادگیری ماشین شامل پنج الگوریتم جنگل تصادفی (RF)، نزدیک‌ترین همسایه (KNN)، ماشین بردار پشتیبان رگرسیون (SVR)، رگرسیون اسپلاین تطبیقی چندمتغیره (MARS) و شبکه‌های عصبی مصنوعی (ANN) بود. برای ارزیابی مدل‌های استفاده شده، ۲۶۳۱ قطعه نمونه ۴۰۰ متری در ۲۷ منطقه جنگلی در زاگرس انتخاب و درصد تاج‌پوشش محاسبه شد. مدل‌سازی به تفکیک زاگرس شمالی، میانی، جنوبی و کل انجام و پارامترهای ارزیابی مدل برای مقایسه مدل‌ها و ماهواره‌ها محاسبه شد. نتایج نشان داد با استفاده از تصاویر لندست ۸، روش‌های MARS، RF و ANN به ترتیب با ضریب تبیین تعدیل شده ۶۳/۷، ۶۲/۷ و ۶۱/۷ و با استفاده از تصاویر سنتینل ۲ بهترین روش‌های یادگیری ماشین با ضریب تبیین تعدیل شده ۷۳/۷، ۷۲/۷ و ۷۱/۷ به ترتیب MARS، SVR و RF بود. در مقایسه نتایج استفاده از تصاویر لندست ۸ و سنتینل ۲ نیز بهترین نتایج سنتینل ۲ (۷۳/۷) بهتر از بهترین نتایج لندست ۸ (۶۳/۷) بود. مدل‌سازی تاج‌پوشش در کل زاگرس اما نشان داد از بین روش‌های مورد استفاده، الگوریتم جنگل تصادفی (۷۳/۷ درصد) نتایج بهتری نسبت به سایر روش‌ها دارد. همچنین نتایج به دست آمده نشان می‌دهد که استفاده از تصاویر سنتینل ۲ نسبت به تصاویر ماهواره لندست ۸ کارایی بیشتری در برآورد سطح تاج‌پوشش داشته و ضریب تبیین حدود ۷٪ بیشتری را نشان داده است.

**واژگان کلیدی:** پایش جنگل، شاخص‌های گیاهی، جنگل تصادفی، تاج‌پوشش

\* نویسنده رابط

## ۱- مقدمه

ناحیه رویشی زاگرس با وسعتی بالغ بر یک پنجم سطح کل کشور، در حدود یک سوم جمعیت کشور را در خود جای داده است و از دیرباز محل زندگی ساکنان و کوچ نشینان بوده و در نتیجه همیشه در معرض آسیب های فراوان بوده است که موجب از بین رفتن جنگل یا باعث سیر قهقرایی آن گردیده است [۱، ۲ و ۳]. همچنین، این جنگل ها با مشکلات دیگری چون افزایش بیماری و آفات، تغییر کاربری اراضی به کشاورزی، آتش سوزی، تغییر اقلیم، و مهم ترین آن عدم مدیریت صحیح دست و پنجه نرم می کنند [۴]. به دلیل اهمیت این جنگل ها تهیه و تنظیم یک برنامه منسجم و کامل مدیریتی ضروری است [۵]. با توجه به ساختار جنگل های زاگرس که اغلب شاخه زاد است و قادر به تولید چوب صنعتی نیست، سطح مقطع در ارتفاع برابر سینه یا حجم سرپا، شاخص های مناسبی از توده برای مطالعه و پژوهش نیستند. بنابراین باید از ویژگی های دیگری مانند تاج پوشش برای بررسی روند تحولات برای مدیریت صحیح کمک گرفت [۶ و ۷].

آمار برداری و استفاده از روش های میدانی برای تهیه نقشه های مربوط به تاج پوشش جنگل، بسیار پرهزینه بوده و انجام آن به صورت دوره ای، خیلی زمانبر است. بنابراین ابداع روشی برای خودکار نمودن فرایند تهیه نقشه از مناطق بزرگ جنگلی و کسب اطلاعات به هنگام برای انجام عملیات جنگلداری، که با دقتی معمول، هزینه مالی و زمانی کمتری داشته باشد، همواره مورد توجه بوده است [۸ و ۹]. فناوری سنجنش از دور امکان پایش علمی و مستند از میزان تغییرات مناطق جنگلی چه در سطح، چه در حجم و تراکم جنگل در اختیار قرار می دهد [۱۰ و ۱۱]. اخیراً پژوهشگران با استفاده از تصاویر ماهواره ای و به کمک روش های رگرسیونی چندگانه، شبکه های عصبی مصنوعی، درخت تصمیم و مدل های خطی تعمیم یافته به برآورد مشخصه های کمی توده های جنگلی از جمله میزان تاج پوشش جنگل پرداخته اند [۱۱].

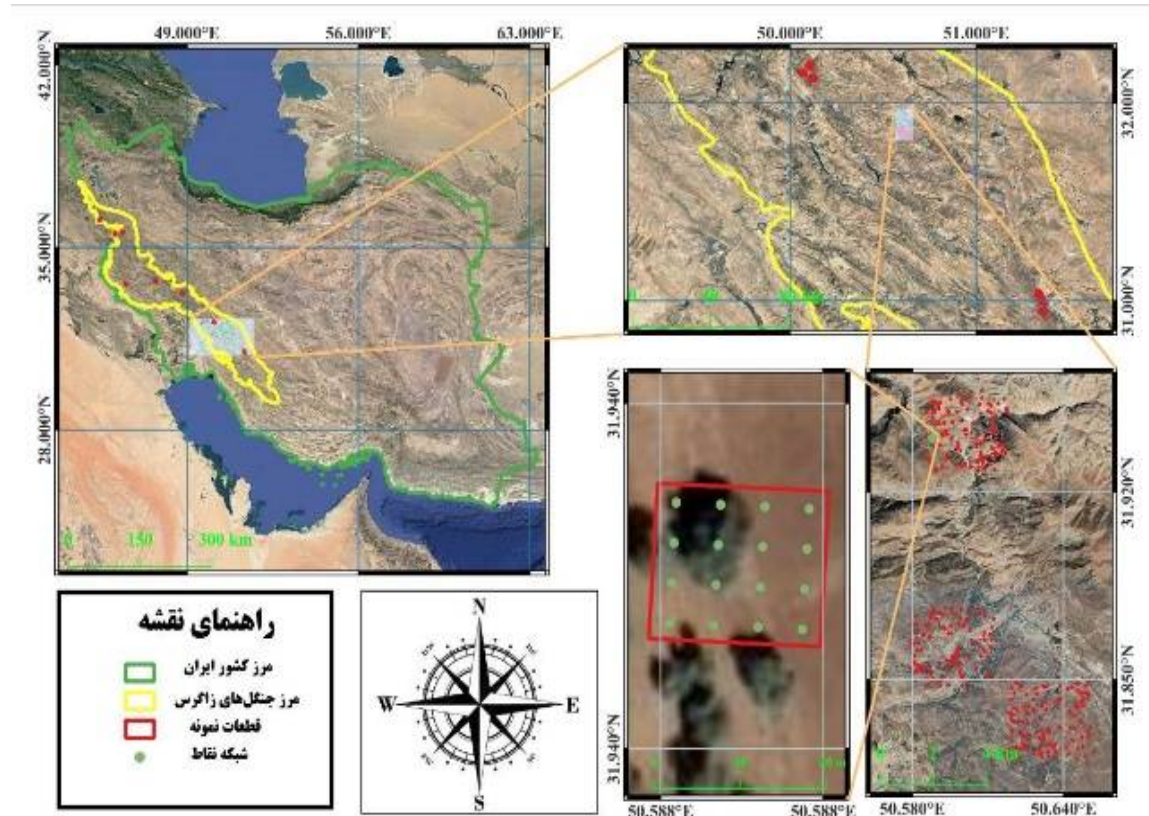
از جمله تحقیقات انجام گرفته در این خصوص می توان به [۱۲] اشاره نمود که به مقایسه الگوریتم های ماشین بردار پشتیبان و جنگل تصادفی برای تهیه نقشه تاج پوشش با استفاده از تصاویر ماهواره های سنتینل ۲ و لندست ۸ در سه منطقه مختلف کاتالونیا، لهستان و رومانی پرداختند. نتایج نشان داد که تصاویر ماهواره ای سنتینل ۲ نسبت به داده های

لندست ۸ نسبت به داده های سنتینل ۲ و الگوریتم ماشین بردار پشتیبان با پایه شعاعی نسبت به جنگل تصادفی با صحت بیشتر عمل کرد. بررسی [۱۳] در تهیه نقشه جنگل حرا واقع در سواحل شرقی هند با استفاده از الگوریتم جنگل تصادفی و داده های AVIRIS-NG و سنتینل ۲ نشان داد خروجی حاصل از باند قرمز تصاویر سنتینل ۲ نتایج بهتری را ارائه داد. علاوه بر این، نتایج نشان داد مدل های پیشرفته مانند جنگل تصادفی، متغیرهای پیش بینی کننده را به خوبی کنترل و طبقه بندی بهینه را امکان پذیر می کند.

در تحقیق با استفاده از سنجنش از دور و زمین آمار بصورت مطالعه موردی بر روی جنگل های باغان مریوان برآورد تاج پوشش جنگل صورت گرفت [۱۱]. به این صورت که ۸۹ قطعه ۰/۱ هکتاری را در منطقه مورد مطالعه پیاده و تاج پوشش درختان و موقعیت قطعات نمونه برداشت را برداشت کردند. در روش سنجنش از دور از تصاویر سنجنده TM ماهواره لندست و مدل رگرسیونی خطی چندگانه استفاده شد. بدین ترتیب پس از پردازش تصاویر، ارزش های متناظر قطعات نمونه از باندهای اصلی و باندهای حاصل از شاخص های گیاهی و تجزیه مؤلفه های اصلی، استخراج شد. در روش زمین آمار از مدل نمایی برازش داده شده بر نیم تغییرنا به روش کریجینگ معمولی استفاده شد. نتایج این تحقیق نشان داد که زمین آمار می تواند ابزاری کارآمد برای تهیه نقشه میزان تاج پوشش جنگل در نواحی رویشی مشابه (رویشگاه زاگرس) باشد.

امکان تهیه نقشه های تنوع و تراکم تاج پوشش جنگل های زاگرس با استفاده از تصاویر سنجنده ETM+ به صورت مطالعه موردی در جنگل های قلاجه استان کرمانشاه بررسی شد [۱۴]. نتایج حاصل از رگرسیونی نشان داد که ترکیب خطی مورد بررسی به عنوان متغیرهای مستقل در مقایسه با دیگر باندها و ترکیبات به کار گرفته شده بهتر می تواند تنوع گونه ای درختان و درختچه ها را برآورد کند ( $R^2_{adj} = 0/327$ ). نتایج به دست آمده نشان دهنده قابلیت به نسبت کم داده های ETM+ در تهیه نقشه تراکم تاج پوشش و برآورد تنوع گونه ای درختی و درختچه ای در منطقه مورد بررسی است.

بر اساس منابع مورد بررسی، تحقیقات صورت گرفته برای برآورد تاج پوشش جنگل های زاگرس بصورت عمومی محدود به مناطق کوچک بوده است. همچنین در اکثر موارد برای تعیین درصد تاج پوشش، از تصاویر یک ماهواره استفاده شده است که امکان مقایسه و انتخاب ماهواره بهتر برای مدل سازی



شکل ۱- موقعیت منطقه مورد مطالعه، توزیع مناطق رویش گاه‌های انتخاب شده، و یک نمونه اندازه‌گیری تاج پوشش

از این محدوده‌ها سه رویشگاه جنگلی شامل تاج‌پوشش انبوه، نیمه انبوه و پراکنده انتخاب گردید. در مجموع ۲۷ محدوده مورد مطالعه انتخاب و نقاط تصادفی برای محاسبه تاج‌پوشش ترسیم شد. در هر یک از رویشگاه‌های مورد بررسی تعداد ۷۰ تا ۱۰۰ نقطه تصادفی با در نظر گرفتن مساحت منطقه طراحی گردید. در هر یک از این نقاط تصادفی یک قطعه نمونه مربعی شکل با مساحت ۴۰۰ متر مربع (۲۰×۲۰ متر) انتخاب و سپس در هر قطعه نمونه شبکه نقطه چین ۴×۴ نقطه پیاده شد. برای محاسبه درصد تاج‌پوشش، تعداد نقاط واقع شده بر روی تاج درختان در نرم‌افزار Google Earth Pro مشخص شد و به کل نقاط تقسیم گردید. در مجموع تعداد ۲۶۳۱ قطعه نمونه بررسی و درصد تاج‌پوشش به دست آمد (شکل ۱).

## ۲-۲- داده‌های ماهواره‌ای

تصاویر ماهواره‌های لندست ۸ (سنجنده‌های OLI و TIRS) و سنتینل ۲ از تاریخ ۱۴۰۱/۰۵/۰۵ تا ۱۴۰۲/۰۶/۰۵ برای اهداف این تحقیق دانلود شد. پردازش تصاویر نیز شامل

تاج‌پوشش جنگل‌های زاگرس را محدود نموده است. از طرف دیگر نیز بیشتر تحقیقات برای مدل‌سازی از روش‌های رگرسیون خطی چندگانه استفاده نموده‌اند. بر اساس خلاءهای ذکر شده تحقیق حاضر طراحی گردید تا برای مناطقی با توزیع مناسب در سراسر زاگرس، تاج‌پوشش جنگل با استفاده از روش‌های مختلف یادگیری ماشین و تصاویر ماهواره‌های لندست و سنتینل برآورد گردد تا ضمن امکان‌سنجی برآورد تاج‌پوشش در جنگل‌های زاگرس، روش یادگیری ماشین و تصاویر مناسب‌تر برای این هدف معرفی گردد.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه پژوهش و تعیین درصد تاج‌پوشش

منطقه رویشی زاگرس در سلسله جبال زاگرس به طول تقریبی ۱۳۰۰ کیلومتر و عرض متوسط ۲۰۰ کیلومتر و با مساحت حدود ۵ میلیون هکتار می‌باشد که ۱۱ استان کشور را تحت پوشش قرار می‌دهد [۱۵]. برای اندازه‌گیری درصد تاج‌پوشش، ۳ منطقه مختلف در زاگرس (شمالی، میانی و جنوبی) انتخاب شد و در هر کدام سه محدوده و در هر یک

عملیات‌های مختلف نظیر نسبت‌گیری و محاسبه شاخص‌های گیاهی است [۱۷ و ۱۶]. پردازش تصاویر در نرم‌افزار Arc Map نسخه ۱۰/۸ صورت گرفت. ارزش‌های طیفی معادل قطعه‌نمونه‌ها از باندهای اصلی و شاخص‌های گیاهی شامل AVI<sup>۱</sup>، SI<sup>۲</sup>، BI<sup>۳</sup>، NDVI<sup>۴</sup>، GNDVI<sup>۵</sup>، EVI<sup>۶</sup>، SAVI<sup>۷</sup> و GCI<sup>۸</sup> استخراج و به‌عنوان متغیر مستقل در انواع مدل‌ها استفاده شد.

## ۲-۳- جنگل تصادفی

روش جنگل تصادفی رگرسیونی<sup>۹</sup> یک تکنیک یادگیری ماشین است که از ترکیب چندین درخت تصمیم رگرسیونی برای پیش‌بینی مقادیر پیوسته استفاده می‌کند. در این روش، مجموعه‌ای از درخت‌های تصمیم به‌طور تصادفی بر روی نمونه‌های مختلف از داده‌های آموزشی و ویژگی‌های تصادفی ساخته می‌شوند. سپس، برای پیش‌بینی مقدار خروجی یک نمونه جدید، تمام درخت‌های ساخته‌شده مقدار خروجی خود را ارائه می‌دهند و میانگین این مقادیر به‌عنوان پیش‌بینی نهایی در نظر گرفته می‌شود. این روش نسبت به یک درخت تصمیم واحد پایدارتر است، از بیش‌برازش<sup>۱۰</sup> جلوگیری می‌کند و دقت بیشتری دارد، به‌ویژه در مسائل پیچیده که روابط غیرخطی بین ویژگی‌ها و متغیر هدف وجود دارد. دقت این روش وابسته به توان درختان به‌صورت مجزا و نیز میزان همبستگی بین آن‌ها می‌باشد. به بیان دیگر هر چه این درختان قابلیت تصمیم‌گیری بهتری داشته و میزان همبستگی میان درخت‌ها کمتر باشد، دقت نهایی بهتر می‌شود [۱۸].

## ۲-۴- نزدیک‌ترین همسایه

روش چندمین نزدیک‌ترین همسایه<sup>۱۱</sup> یک الگوریتم یادگیری ماشین غیرپارامتری و مبتنی بر نمونه<sup>۱۲</sup> است که برای طبقه‌بندی و رگرسیون استفاده می‌شود. در این روش، برای پیش‌بینی مقدار یک نمونه جدید، فاصله آن با تمام

نمونه‌های موجود در مجموعه داده محاسبه شده (معمولاً با استفاده از فاصله اقلیدسی)، سپس K نمونه نزدیک‌تر انتخاب می‌شوند. در طبقه‌بندی، برچسب کلاس غالب بین این K همسایه به‌عنوان خروجی در نظر گرفته می‌شود، و در رگرسیون، میانگین مقادیر این همسایه‌ها به‌عنوان مقدار پیش‌بینی شده استفاده می‌شود. این روش ساده اما کارآمد است و برای داده‌هایی با ساختار غیرخطی مفید است، اما در داده‌های بزرگ ممکن است محاسبات سنگین شود و به انتخاب مناسب مقدار K حساس باشد [۱۹ و ۲۰].

## ۲-۵- ماشین بردار پشتیبان رگرسیون

ماشین بردار پشتیبان رگرسیون<sup>۱۳</sup> یک روش یادگیری ماشین مبتنی بر ماشین بردار پشتیبان است که برای پیش‌بینی مقادیر عددی در مسائل رگرسیون استفاده می‌شود. در این روش، مدل تلاش می‌کند یک تابع تصمیم‌گیری را بیابد که مقادیر پیش‌بینی‌شده در یک محدوده خاص<sup>۱۴</sup> از مقادیر واقعی قرار بگیرند، به‌گونه‌ای که نمونه‌های خارج از این محدوده کمترین انحراف ممکن را داشته باشند. SVR با استفاده از هسته‌های<sup>۱۵</sup> مختلف مانند هسته خطی، چندجمله‌ای، گاوسی<sup>۱۶</sup> می‌تواند روابط غیرخطی را نیز مدل‌سازی کند [۲۱]. این روش نسبت به نویز مقاوم است، از بیش‌برازش جلوگیری می‌کند و برای مجموعه داده‌های کوچک یا با ابعاد بالا عملکرد خوبی دارد، اما تنظیم پارامترهای آن (C، ε و نوع هسته) نقش مهمی در دقت آن ایفا می‌کند.

## ۲-۶- رگرسیون اسپلاین تطبیقی چندمتغیره

رگرسیون اسپلاین تطبیقی چندمتغیره<sup>۱۷</sup> یک روش رگرسیونی غیرخطی و انعطاف‌پذیر است که برای مدل‌سازی روابط پیچیده بین متغیرهای مستقل و وابسته استفاده می‌شود. این روش با تقسیم دامنه متغیرهای ورودی به

۱۰ Overfitting  
 ۱۱ K-Nearest Neighbors  
 ۱۲ Instance-based  
 ۱۳ Support Vector Regression  
 ۱۴ ε-tube  
 ۱۵ Kernel Trick  
 ۱۶ RBF  
 ۱۷ Multivariate Adaptive Regression Splines

۱ Advanced Vegetation Index  
 ۲ Shadow Index  
 ۳ Bare Soil Index  
 ۴ Normalized Difference Vegetation Index  
 ۵ Green Normalized Difference Vegetation  
 ۶ Enhanced Vegetation Index  
 ۷ Soil-adjusted vegetation index  
 ۸ Green Chlorophyll Vegetation Index  
 ۹ Random Forest Regression

قطعات<sup>۱</sup> و استفاده از توابع پایه‌ای اسپلاین<sup>۲</sup> ساختاری شبیه به درخت تصمیم ایجاد می‌کند؛ اما به روشی نرم‌تر و پیوسته‌تر. برخلاف مدل‌های خطی سنتی، MARS می‌تواند تعاملات بین متغیرها را به طور خودکار شناسایی کند و روابط غیرخطی را مدل‌سازی کند. این روش برای مجموعه داده‌های بزرگ و مسائلی که پیش‌فرض‌های رگرسیون خطی کلاسیک را نقض می‌کنند مناسب است و به دلیل مکانیزم انتخاب ویژگی داخلی، به طور خودکار ویژگی‌های غیرمؤثر را حذف می‌کند [۲۲]. یکی از ویژگی‌های مهم مدل MARS این است که رابطه عملکردی بین متغیرهای وابسته و مستقل را با مجموعه‌ای از ضرایب تعریف کرده به طوری که تأثیر آن‌ها را به طور جداگانه محاسبه می‌کند [۲۳].

## ۲-۷- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی<sup>۳</sup> یک مدل محاسباتی الهام‌گرفته از ساختار و عملکرد مغز انسان است که برای یادگیری الگوها، طبقه‌بندی، رگرسیون و سایر وظایف یادگیری ماشین استفاده می‌شود. این شبکه از لایه‌های متصل به هم از نورون‌ها (گره‌ها) تشکیل شده است، شامل یک لایه ورودی (دریافت داده‌ها)، لایه‌های پنهان (پردازش و استخراج ویژگی‌ها) و لایه خروجی (ارائه نتیجه). هر نورون با وزن‌های خاصی به نورون‌های لایه بعد متصل است و از تابع فعال‌سازی (مانند سیگموئید، ReLU یا تانژانت هایپربولیک (برای ایجاد خروجی غیرخطی)) استفاده می‌کند. شبکه‌های عصبی با استفاده از روش‌هایی مانند پس‌انتشار خطا<sup>۴</sup> و بهینه‌سازی گرادیان کاهشی آموزش داده می‌شوند. این روش قدرت بالایی در یادگیری روابط پیچیده دارد اما نیازمند داده زیاد، قدرت محاسباتی بالا و تنظیم بهینه ابرپارامترها است [۲۴].

## ۲-۸- بررسی اعتبار مدل‌ها

برای مقایسه کمی برآوردهای مقادیر مختلف تاج‌پوشش در مناطق مختلف، مستخرج از مدل‌های یادگیری ماشین هر دو ماهواره با مقدار اندازه‌گیری شده تاج‌پوشش، معیارهای زیر محاسبه شد [۱۷ و ۲۰].

$$R^2 = \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (1)$$

$$\bar{R}_{adj}^2 = 1 - (1 - R^2) \left[ \frac{n-1}{n-(k+1)} \right] \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (3)$$

$$RMSE\% = \frac{(RMS)}{\bar{y}} \times 100 \quad (4)$$

## ۳- نتایج

### ۳-۱- مقایسه مدل‌های یادگیری ماشین در مناطق مختلف جنگل‌های زاگرس

توصیف آماری اندازه‌گیری سطح تاج‌پوشش در جدول ۱ در مناطق مورد مطالعه در رویشگاه‌های جنگلی زاگرس شمالی، زاگرس میانی و زاگرس جنوبی نشان داده شده است. در مجموع در زاگرس شمالی، میانی و جنوبی به ترتیب ۸۱۴، ۹۱۱ و ۹۰۶ قطعه نمونه اندازه‌گیری گردید. بیشینه تاج‌پوشش در این سه محدوده به ترتیب ۹۷، ۸۰ و ۹۱ درصد و کمینه آن صفر بود.

جدول ۱- توصیف آماری تاج‌پوشش در مناطق مورد مطالعه

مناطق مطالعاتی	تعداد	میانگین	حداقل	حداکثر	انحراف معیار
Northern Zagros	۸۱۴	۴۷.۰	۰.۰	۹۷.۷	۲۲.۰
Middle Zagros	۹۱۱	۳۷.۷	۰.۰	۸۰.۷	۱۹.۳
Southern Zagros	۹۰۶	۳۸.۳	۰.۰	۹۱.۰	۲۱.۰

۳ Artificial Neural Network  
۴ Backpropagation

۱ Piecewise Segments  
۲ Spline Basis Functions

انتخاب می‌شوند. با بررسی مدل‌سازی‌ها مبتنی بر تصاویر سنتینل ۲ ملاحظه می‌گردد که بهترین روش‌های یادگیری ماشین با ضریب تبیین تعدیل شده ۷۳/۷، ۷۲/۷ و ۷۱/۷ به ترتیب MARS، SVR و RF بوده است. در مقایسه نتایج استفاده از تصاویر لندست ۸ و سنتینل ۲ نیز بهترین نتایج سنتینل ۲ (۷۳/۷) بهتر از بهترین نتایج لندست ۸ (۶۳/۷) بود.

نتایج مدل‌سازی با استفاده از روش‌های مختلف یادگیری ماشین برای زاگرس شمالی، میانی و جنوبی با استفاده از پارامترهای ارزیابی مدل در جدول ۲ آمده است. نتایج نشان می‌دهد با استفاده از تصاویر لندست ۸، روش‌های MARS، RF و ANN به ترتیب با ضریب تبیین تعدیل شده ۶۳/۷، ۶۲/۷ و ۶۱/۷ به عنوان مناسب‌ترین مدل‌ها که مطابق با روند RMSE و RMSE% نیز هست

جدول ۲- ارزیابی مدل‌های یادگیری ماشین برای برآورد تاج پوشش در جنگل‌های زاگرس

مدل	مناطق مطالعاتی	لندست-۸			سنتینل-۲		
		RMSE	R <sup>2</sup> adj	RMSE/%	RMSE	R <sup>2</sup> adj	RMSE/%
RF	Northern Zagros	۱۵.۰	۶۲.۷	۲۹.۰	۱۲.۳	۷۲.۷	۲۵.۰
	Middle Zagros	۱۷.۳	۳۲.۳	۴۴.۳	۱۳.۳	۵۹.۷	۳۴.۰
	Southern Zagros	۱۵.۷	۵۴.۰	۳۷.۰	۱۳.۷	۵۹.۷	۳۰.۰
KNN	Northern Zagros	۱۵.۷	۵۹.۷	۳۰.۳	۱۳.۳	۶۹.۳	۲۶.۰
	Middle Zagros	۱۸.۳	۲۸.۰	۴۷.۰	۱۳.۷	۵۵.۷	۳۵.۷
	Southern Zagros	۱۵.۷	۵۰.۷	۳۸.۷	۱۵.۳	۵۳.۰	۳۶.۷
SVR	Northern Zagros	۱۸.۰	۴۹.۷	۳۹.۷	۱۴.۰	۷۱.۷	۲۷.۷
	Middle Zagros	۱۷.۷	۳۵.۷	۴۰.۳	۱۷.۳	۶۱.۳	۳۲.۳
	Southern Zagros	۱۸.۳	۳۸.۷	۴۳.۰	۱۵.۳	۶۱.۷	۳۸.۳
MARS	Northern Zagros	۱۴.۳	۶۳.۷	۲۸.۷	۱۲.۳	۷۳.۷	۲۴.۳
	Middle Zagros	۱۶.۰	۴۱.۳	۴۰.۷	۱۲.۳	۶۴.۰	۳۲.۳
	Southern Zagros	۱۵.۰	۵۵.۳	۳۶.۷	۱۴.۳	۵۹.۰	۳۳.۷
ANN	Northern Zagros	۳۲.۳	۶۱.۷	۶۳.۷	۶۰.۳	۶۹.۰	۶۲.۷
	Middle Zagros	۲۷.۰	۳۸.۷	۶۷.۰	۵۰.۰	۶۳.۷	۵۷.۰
	Southern Zagros	۳۱.۰	۵۰.۳	۷۴.۷	۵۸.۷	۶۲.۰	۶۹.۳

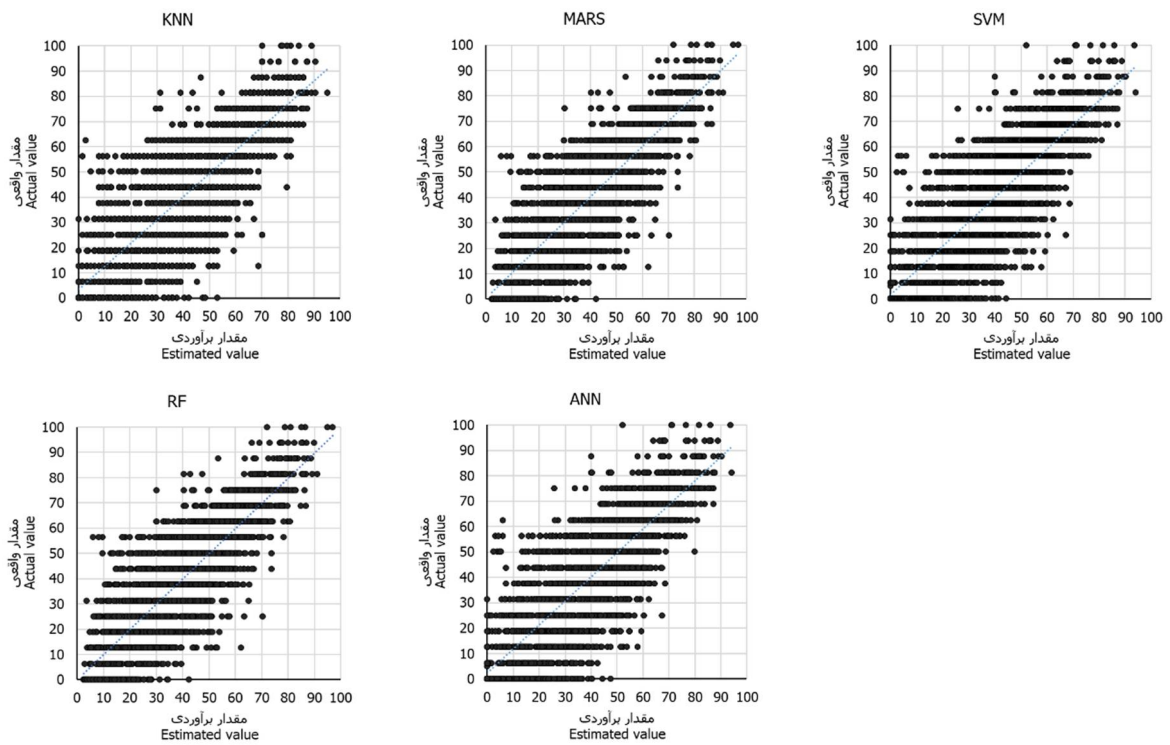
نتایج برآورد تاج پوشش با استفاده از تصاویر سنتینل ۲ بهتر از تصاویر لندست ۸ بود.

### ۳-۲- مقایسه مدل‌های یادگیری ماشین در کل زاگرس

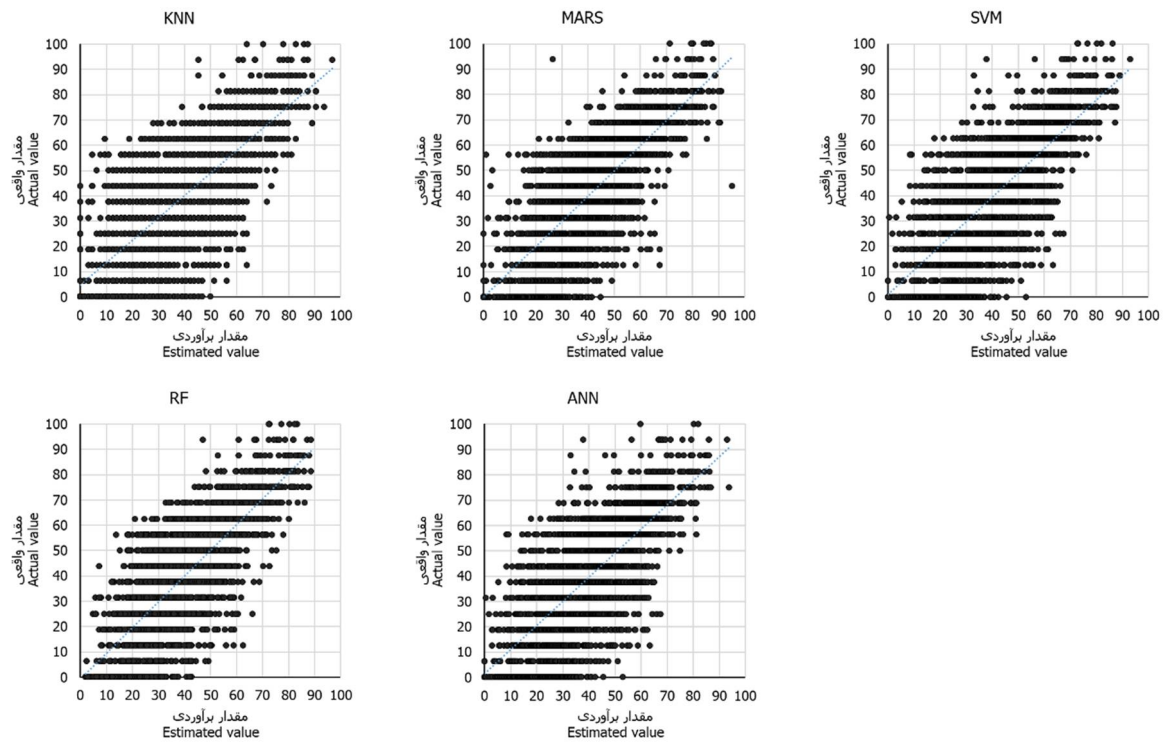
پس از ارزیابی و مقایسه نتایج مدل‌ها و داده‌های هر دو ماهواره به تفکیک مناطق مختلف، مدل‌سازی برای کل مناطق مورد مطالعه در جنگل‌های زاگرس مورد بررسی قرار گرفت. نتیجه مدل‌سازی بر اساس ۵ روش جنگل تصادفی، ماشین بردار پشتیبان، اسپلاین تطبیقی چندگانه، شبکه عصبی مصنوعی و نزدیک‌ترین همسایه بر اساس داده‌های حاصل از تصاویر ماهواره لندست ۸ و سنتینل ۲ در جدول ۳ و ابر نقاط مقادیر برآورد شده در مقابل مقادیر واقعی در شکل‌های ۲ و ۳ نشان داده شده است. نتایج نشان داد برای تصاویر لندست، مدل RF و MARS با اختلاف جزئی بهترین عملکرد را داشتند. اما RF بهترین مدل برای زمانی بود که از تصاویر سنتینل ۲ برای مدل‌سازی استفاده شد. در مجموع

جدول ۳- ارزیابی مدل‌های یادگیری ماشین برای برآورد تاج-پوشش در جنگل‌های زاگرس

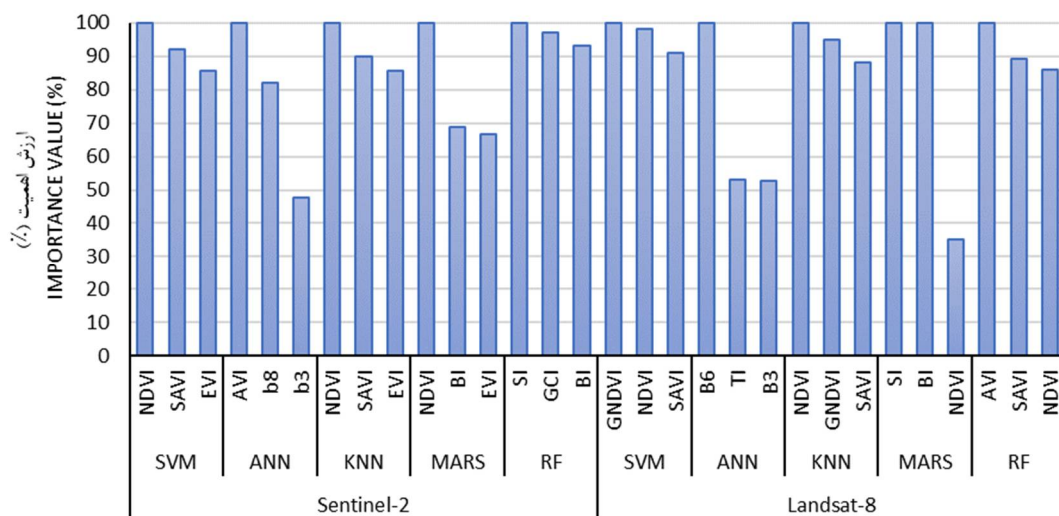
نام مدل	لندست-۸			سنتینل-۲		
	RMSE	R <sup>2</sup> adj	RMSE/%	RMSE	R <sup>2</sup> adj	RMSE/%
RF	۱۵.۰	۶۰.۰	۲۹.۰	۱۲.۰	۷۰.۰	۲۵.۰
KNN	۱۷.۰	۵۵.۰	۳۷.۰	۱۵.۰	۶۵.۰	۳۳.۰
SVR	۱۶.۰	۵۷.۰	۳۵.۰	۱۳.۰	۶۶.۰	۳۲.۰
MARS	۱۴.۰	۶۱.۰	۲۸.۰	۱۲.۰	۶۵.۰	۲۸.۰
ANN	۳۰.۰	۵۶.۰	۷۴.۰	۵۴.۰	۶۵.۰	۶۷.۰



شکل ۲- برآورد سطح تاج‌پوشش با استفاده از روش‌های KNN, ANN, RF, MARS و SVR بر اساس داده‌های سنتینل ۲



شکل ۳- برآورد سطح تاج‌پوشش با استفاده از روش‌های KNN, ANN, RF, MARS و SVR بر اساس داده‌های لندست ۸



شکل ۴- ارزش اهمیت سه مهمترین متغیر استفاده شده در روش‌های مدل‌سازی برآورد سطح تاج‌پوشش

تاجی جنگل را به طور موثر تحلیل کرده و تفسیر کنند. با استفاده از این الگوریتم‌ها، امکان ایجاد مدل‌های پیش‌بینی‌کننده‌ای وجود دارد که می‌توانند تاج‌پوشش را در وسعت‌های بزرگ با دقت بالا برآورد کنند.

در مطالعه حاضر نتایج عملکرد پنج الگوریتم یادگیری ماشین شامل جنگل تصادفی، نزدیک‌ترین همسایه، طبقه‌بندی‌کننده ماشین بردار پشتیبان، خطوط رگرسیون تطبیقی چند متغیره و شبکه عصبی مصنوعی برای کمی کردن تاج‌پوشش جنگل‌های زاگرس مورد بررسی قرار گرفت و تصاویر سنتینل ۲ نسبت به تصاویر ماهواره لندست ۸ کارایی بهتری در برآورد تاج‌پوشش نشان داد. همچنین در میان روش‌های مورد استفاده، RF نتایج بهتری را نسبت به سایر روش‌ها برای برآورد تاج‌پوشش با استفاده از تصاویر سنتینل ۲ و لندست ۸ نشان داد.

تصاویر سنتینل ۲ و لندست ۸ اطلاعات ارزشمندی درباره بازتاب طیفی پوشش تاجی جنگل ارائه می‌دهند که می‌توان به‌عنوان متغیرهای ورودی برای الگوریتم‌های یادگیری ماشین استفاده کرد. این الگوریتم‌ها سپس می‌توانند روابط بین بازتاب طیفی و اندازه‌گیری‌های تاج‌پوشش را یاد بگیرند و اجازه می‌دهند که برای مناطقی که داده‌های تاج‌پوشش در دسترس نیست، پیش‌بینی‌های دقیق انجام دهند. علاوه بر این، استفاده از الگوریتم‌های یادگیری ماشین می‌تواند به غلبه بر برخی از محدودیت‌ها و چالش‌های مرتبط با برآورد تاج‌پوشش در جنگل‌های زاگرس کمک کند. در مطالعه مقایسه‌ای [۲۵]، قوت‌های تصویربرداری سنتینل ۲ در تحلیل

در شکل ۴ متغیرهای مهم مستخرج از تصاویر ماهواره‌های سنتینل ۲ و لندست ۸ به تفکیک الگوریتم‌های مختلف یادگیری ماشین نمایش داده شده است. در مجموع چنان‌که ملاحظه می‌گردد شاخص‌های پوشش گیاهی بیشتر از باندهای خام در ایجاد مدل‌های یادگیری موثر بوده‌اند. اگرچه فهرست شاخص‌های مورد استفاده در هر مدل برای هر ماهواره و روش متنوع است و امکان نتیجه‌گیری در خصوص تعیین مهمترین شاخص‌ها به سهولت میسر نیست، اما در ماهواره لندست ۸ ملاحظه می‌گردد شاخص NDVI همواره جزو متغیرهای مهم در مدل‌سازی بوده است.

#### ۴- بحث

جنگل‌های زاگرس منبع طبیعی مهمی هستند که مزایای محیط زیستی و اقتصادی-اجتماعی فراوانی را فراهم می‌آورند. برآورد تاج‌پوشش این جنگل‌ها برای مدیریت و تلاش‌های حفاظتی موثر ضروری است [۱]. روش‌های سنتی برآورد پوشش تاجی، مانند برآوردهای میدانی، زمان‌بر و پرهزینه است. بنابراین، استفاده از الگوریتم‌های یادگیری ماشینی در ترکیب با داده‌های سنجنش از دور، مانند تصاویر سنتینل ۲ و لندست ۸، رویکرد امیدوارکننده‌ای را برای برآورد دقیق پوشش تاجی جنگل‌های زاگرس ارائه می‌دهد. الگوریتم‌های یادگیری ماشین، مانند جنگل تصادفی و ماشین‌های بردار پشتیبان می‌توانند بر اساس داده‌های سنجنش از دور آموزش ببینند تا الگوهای پیچیده پوشش

نمونه برداری خوشه‌ای، روش شبکه عصبی مصنوعی و تصاویر سنتینل ۲ کارایی مناسبی در برآورد مشخصه‌های مورد بررسی داشت. البته در تحقیق حاضر RF نتایج بهتری نسبت به روش شبکه عصبی مصنوعی نشان داد. همچنین در پژوهشی دیگر توسط [۱۸] برای مقایسه الگوریتم‌های یادگیری ماشین در طبقه‌بندی مکانی گونه‌های درختی پهن‌برگ با مقایسه عملکرد الگوریتم‌های ناپارامتری ماشین‌پرداز پشتیبان، جنگل تصادفی و شبکه عصبی مصنوعی و الگوریتم پارامتری تحلیل تشخیص خطی در طبقه‌بندی درختان، به این نتیجه دست یافتند که الگوریتم تحلیل ممیزی خطی صحت کلی بیشتری داشت.

دقیق پوشش گیاهی برجسته شده است. مطالعه ما این یافته‌ها را با نشان دادن نحوه استفاده از این قوت‌ها، از طریق یادگیری ماشینی برای فراهم کردن برآوردهای دقیق‌تر و قابل اعتمادتر تاج‌پوشش تکمیل می‌کند.

در راستای نتایج پژوهش حاضر، [۱۹] با هدف بررسی قابلیت باندهای اصلی و شاخص‌های مبتنی بر تصاویر ماهواره سنتینل ۲ در برآورد مشخصه‌های کمی جنگل‌های زاگرس، مدل‌سازی با استفاده از روش‌های جنگل تصادفی، ماشین‌پرداز پشتیبان، نزدیکترین همسایه و شبکه عصبی مصنوعی را انجام دادند که نتایج حاصل از اعتبارسنجی به‌دست آمده نشان داد استفاده از طرح‌های مختلف

## مراجع

- [۱] A. Safari and H. Sohrabi, "Effect of climate change and local management on aboveground carbon dynamics (1987–2015) in Zagros oak forests using Landsat time-series imagery," *Appl. Geogr.*, vol. 110, no. July, p. 102048, 2019, doi: 10.1016/j.apgeog.2019.102048.
- [۲] F. Pordel, A. Ebrahimi, and Z. Azizi, "Canopy cover or remotely sensed vegetation index, explanatory variables of above-ground biomass in an arid rangeland, Iran," *J. Arid Land*, vol. 10, no. 5, pp. 767–780, Oct. 2018, doi: 10.1007/s40333-018-0017-y.
- [۳] Z. Azizi, A. Najafi, and H. Sohrabi, "Forest Canopy Density Estimating , Using Satellite Images," in *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, Beijing, China, 2008, p. 4. doi: 10.13140/2.1.2953.6967.
- [۴] A. Ildoromi, F. Ghasemi, and N. Bahmani, "Investigation of the Role of Socio-Economic Factors on the Degradation of Zagros Forests (Kakareza Lorestan)," *Iran. J. For. Range Prot. Res.*, vol. 13, no. 2, pp. 140–149, 2016, doi: 10.22092/ijfpr.2016.106021.
- [۵] H. Beygiheidarlou and et al., "Forest Cover Density Mapping of Zagros Forests Using Landsat-9 Imagery and Hemispherical Photographs," *For. Res. Dev.*, vol. 9, no. 1, pp. 47–65, 2023, doi: 10.30466/jfrd.2023.54591.1661.
- [۶] A. Anand, S. K. Singh, and S. Kanga, "Estimating the Change in Forest Cover Density and Predicting NDVI for West Singhbhum Using Linear Regression," *Int. J. Environ. Rehabil. Conserv.*, vol. 9, pp. 193–203, 2018.
- [۷] S. Vafaei et al., "Improving accuracy estimation of Forest Aboveground Biomass based on incorporation of ALOS-2 PALSAR-2 and Sentinel-2A imagery and machine learning: A case study of the Hyrcanian forest area (Iran)," *Remote Sens.*, vol. 10, no. 2, 2018, doi: 10.3390/rs10020172.
- [۸] T. N. Phan, V. Kuch, and L. W. Lehnert, "Land Cover Classification Using Google Earth Engine and Random Forest Classifier: The Role of Image Composition," *Remote Sens.*, vol. 12, no. 15, p. 2411, 2020.
- [۹] H. Panahi, Z. Azizi, H. Kiadaliri, S. A. Almodaresi, and H. Aghamohamadi, "Bare soil detecting algorithms in western iran woodlands using remote sensing," *Smart Agric. Technol.*, vol. 7, no. March, pp. 1–9, 2024, doi: 10.1016/j.atech.2024.100429.
- [۱۰] M. Taefi Feijani, S. Azadnejad, and M. Moradi, "Improvement of the Forest Canopy Density Model Based on the Addition of the FCC Index and the Average Kernel Implementation," *Sp. Sci. Technol.*, vol. 14, no. 2, pp. 27–36, 2021, doi: 10.22034/jsst.2021.1191.
- [۱۱] S. Vafaei and et al., "Estimation of Forest Canopy Using Remote Sensing and Geostatistics (Case Study: Marivan Baghan Forests)," *J. Environ. Sci. Technol.*, vol. 24, no. 1, pp. 71–82, 2022, doi: 10.30495/jest.2018.20376.294.
- [۱۲] A. Dabija and et al., "Comparison of Support Vector Machines and Random Forests for Corine Land Cover Mapping," *Remote Sens.*, vol. 13, p. 777, 2021, doi: 10.3390/rs13040777.
- [۱۳] R. K. M. Malhi et al., "Synergistic evaluation of Sentinel 1 and 2 for biomass estimation in a tropical forest of India,"

- Adv. Sp. Res.*, vol. 69, no. 4, pp. 1752–1767, Feb. 2022, doi: 10.1016/j.asr.2021.03.035.
- [۱۴] R. A. Parma and S. Shataey, “Capability Study on Mapping the Diversity and Canopy Cover Density in Zagros Forests Using ETM+ Images (Case Study: Ghalajeh Forests, Kirmanshah Province),” *Iran. J. For.*, vol. 2, no. 3, pp. 231–242, 2010.
- [۱۵] M. Ghanbari Motlagh and et al., “Investigating Spatiotemporal Changes in Greenness of Zagros Oak Forests in Response to Drought,” *J. Renew. Nat. Resour. Res.*, vol. 13, no. 2, pp. 131–143, 2023, doi: 10.30495/jmr.2023.71340.10281.
- [۱۶] H. Naghavi, “Application of Quickbird Satellite Images in Estimating the Canopy Level of Zagros Forests (Case Study: Gol Khorramabad Castle Area),” Sari University of Agricultural Sciences and Natural Resources, 2014.
- [۱۷] A. Safari and H. Sohrabi, “Ability of Landsat-8 OLI derived texture metrics in estimating aboveground carbon stocks of coppice Oak Forests,” *Int. Arch. Photogramm. Remote Sens. & Spat. Inf. Sci.*, vol. 41, 2016.
- [۱۸] M. Miraki, H. Sohrabi, P. Fatehi, and M. Kneubuehler, “Comparison of Machine Learning Algorithms for Broad Leaf Species Classification Using UAV-RGB Images,” *J. Geomatics Sci. Technol.*, vol. 10, no. 2, pp. 1–10, 2020.
- [۱۹] N. Nazariani and A. Fallah, “Investigation of the Effect of Main and Artificial Bands of Sentinel-2 Satellite Images on Estimation of Quantitative Characteristics of Zagros Forests,” *Sci. Q. Geogr. Data*, vol. 31, no. 124, pp. 103–118, 2023, doi: 10.22131/sepehr.2023.553505.2875.
- [۲۰] A. Safari and H. Sohrabi, “The effect of digital preprocessing and modeling method on an estimation of aboveground carbon stock of Zagros forests using Landsat 8 imagery,” *RS GIS Nat. Resour.*, vol. 9, no. 4, pp. 73–89, 2019.
- [۲۱] S. Arekhi and M. Adibnejad, “Efficiency Assessment of the Support Vector Machines for Land Use Classification Using Landsat ETM+ Data (Case Study: Ilam Dam Catchment),” *Iran. J. Range Desert Res.*, vol. 18, no. 3, pp. 420–440, 2011, doi: 10.22092/ijrdr.2011.102175.
- [۲۲] R. M. Adnan, Z. Liang, and S. Heddham, “Least Square Support Vector Machine and Multivariate Adaptive Regression Splines for Streamflow Prediction in Mountainous Basin Using Hydro-Meteorological Data as Inputs,” *J. Hydrol.*, vol. 124, p. 371, 2019, doi: 10.1016/J.JHYDROL.2019.124371.
- [۲۳] N. Busto Serrano, A. Suárez Sánchez, and F. Sánchez Lasheras, “Identification of Gender Differences in the Factors Influencing Shoulders, Neck, and Upper Limb MSD by Means of Multivariate Adaptive Regression Splines (MARS),” *Appl. Ergon.*, vol. 82, p. 102981, 2020, doi: 10.1016/j.apergo.2019.102981.
- [۲۴] C. Witharana and H. J. Lynch, “An Object-Based Image Analysis Approach for Detecting Penguin Guano in Very High Spatial Resolution Satellite Images,” *Remote Sens.*, vol. 8, no. 5, p. 375, 2016.
- [۲۵] X. Huang and et al., “Comparative Study on Remote Sensing Methods for Forest Height Mapping in Complex Mountainous Environments,” *Remote Sens.*, vol. 15, p. 2275, 2023, doi: 10.3390/rs15092275.