

ارزیابی اثر جو بر عملکرد روش‌های شبکه عصبی و درخت رگرسیون در بازیابی پارامتر گیاهی کسری از پوشش گیاهی

علی شمس‌الدینی^{۱*}، آفاق زیدانی^۲

^۱ دانشیار گروه سنجش از دور و GIS، دانشگاه تربیت مدرس
ali.shamsoddini@modares.ac.ir

^۲ کارشناسی ارشد سنجش از دور و GIS، دانشگاه تربیت مدرس
afagh.zeydani@gmail.com

(دریافت: اسفند ۱۴۰۲، تصویب: مرداد ۱۴۰۳)

چکیده

بازتابندگی سطحی ثبت شده توسط سنجنده‌ها به دلیل عبور از اتمسفر در معرض ذرات موجود در آن از جمله گازها و هواویزها قرار گرفته و مقدار آن تغییر می‌کند. این تغییرات در میزان بازتابندگی سطحی، استفاده‌های مختلف از این کمیت را نیز تحت تاثیر قرار دهد. تصحیح اتمسفری تصاویر با استفاده از روش‌های مختلف به دلیل تفاوت در الگوریتم‌های تصحیح و همچنین استفاده از مقادیر متفاوت پارامترهای اتمسفری از قبیل بخار آب، میدان دید و ضخامت نوری هواویزها، که اغلب از اندازه‌گیری زمینی در ایستگاه‌های واقع در محدوده تصویر، و یا از محصولات سایر سنجنده‌ها و یا بر اساس مطالعات مشابه و حدس کاربر استخراج می‌شوند، می‌تواند نتایج مختلفی را حاصل کند. هدف این تحقیق ارزیابی تاثیر متغیرهای تصحیح اتمسفری بر صحت بازیابی شاخص گیاهی کسری از پوشش گیاهی (FCOVER) از بازتابندگی سطح می‌باشد. منطقه مورد مطالعه بخشی از زمین‌های کشاورزی کارمان واقع در استان مانی‌توبا در کشور کانادا می‌باشد. نمونه‌های زمینی FCOVER از پروژه مانی‌توبا به همراه تصویر لندست-۸ برای بازیابی در تحقیق حاضر به کار رفته‌اند. پس از اعمال روش تصحیح تحلیل پرسرعت اتمسفری خط دید از مکعب‌های طیفی (FLAASH) بر روی تصویر لندست-۸ با تغییر مقادیر بخار آب و میدان دید، مدلسازی شاخص گیاهی FCOVER با استفاده از الگوریتم‌های رگرسیونی شبکه عصبی و درخت رگرسیون انجام شد و تاثیر عدم اطمینان مربوط به هر پارامتر اتمسفری ورودی به این مدل‌ها مورد ارزیابی قرار گرفت. بررسی نتایج حاصل از مدلسازی و آزمون تی نمونه‌های جفت شده نشان داد مقادیر مختلف پارامترهای بخار آب و میدان دید بر بازیابی پارامتر FCOVER تاثیرگذار بوده و خطایی بیش از ۵ درصد ایجاد می‌کند. همچنین نتایج بدست‌آمده از الگوریتم‌های شبکه عصبی و درخت رگرسیون عملکرد نسبتاً مشابه و مناسبی برای بازیابی FCOVER با وجود عدم اطمینان در پارامترهای ورودی مدل FLAASH از خود نشان داده‌اند، اگرچه الگوریتم شبکه عصبی به‌طور کلی دارای خطای میانگین مربعات کمتر (به عنوان مثال ۰.۲۰ در مقایسه با ۰.۲۲) و ضریب تعیین بالاتر (به عنوان مثال ۰.۵۵ در مقایسه با ۰.۳۸) می‌باشد.

واژگان کلیدی: تصحیح اتمسفری، بازتابندگی سطحی، بازیابی پارامتر

۱- مقدمه

اتمیسفر به عنوان عاملی تاثیرگذار بر روی تصاویر سنجش از دور مطرح می‌باشد، که به مخلوطی از گازها و ذرات مختلف که قشر نسبتاً نازکی در اطراف کره زمین به وجود آورده‌اند گفته می‌شود. بازتابندگی سطحی ثبت شده توسط سنجنده ماهواره‌ها به دلیل عبور از اتمیسفر تحت تاثیر اجزای آن از جمله گازها و هواویزها قرار گرفته و میزان انرژی رسیده به سنجنده پیش از ثبت شدن دچار تغییر می‌شود. بازتابندگی بالای اتمیسفر^۱ به عنوان تابعی از بازتابندگی پدیده‌ها و همچنین تحت تاثیر زاویه زنیث^۲، آزیموت^۳ و ویژگی‌های اتمیسفر ممکن است کاهش یا افزایش یابد، لذا تفسیر تصاویر ثبت شده توسط سنجنده‌ها به دلیل وجود ذرات اتمیسفر با چالش‌های مختلفی رو به رو است [۱]. اثرات اتمیسفر عمدتاً به دو شکل جذب و پخش خود را نشان می‌دهد [۲]. جذب اتمیسفری عموماً در محدوده مادون قرمز، با اثر گذاری مولکول‌های بخار آب، دی‌اکسید کربن و آزن مانع از انتقال انرژی می‌شود و یا مقدار انرژی رسیده به سنجنده را کاهش می‌دهد [۲]. متعاقباً مطالعات مختلف از جمله بازتابی پارامترهای بیوفیزیکی گیاهی، مبتنی بر استفاده از این تصاویر نیز تحت تاثیر این تغییرات قرار می‌گیرند. به دلیل اینکه اثرات اتمیسفر بر بازتابندگی سطحی غیرقابل چشم پوشی است لذا تلاش در راستای کاهش اثرات آن اقدامی ضروری می‌باشد، برای این منظور تصحیح اتمیسفری انجام می‌گیرد [۳]. این اقدام به هرگونه کاهش اثرات اتمیسفر که شامل مکانیزم‌های پخش و جذب انرژی تابشی توسط هواویزها و مولکول‌های گاز موجود در آن می‌باشد، گفته می‌شود [۳]. در مطالعاتی با هدف بازتابی پارامتر، آشکارسازی تغییرات و استفاده از تصاویر سری زمانی، اجرای تصحیح اتمیسفری الزامی است [۴]، [۵]. روش‌های تصحیح اتمیسفری در گروه‌های مختلفی از جمله: روش‌های تجربی، فیزیک-مبنا، کالیبراسیون نسبی، تصویر-مبنا و روش‌های انتقال تابش قرار می‌گیرند (ورموت و ورمولن^۴ ۱۹۹۹) [۶]. روش‌های مبتنی بر مدل‌های انتقال تابش که از جمله آن‌ها روش‌های

FLAASH^۵ و ATCOR^۶ هستند، از قدرتمندترین و دقیق‌ترین روش‌های تصحیح اتمیسفری به شمار می‌روند [۷]. اساس این روش‌ها شبیه‌سازی مسیر حرکت انرژی تابشی از منبع تا رسیدن به سنجنده می‌باشد و با استفاده از مدل سازی‌های تجربی ساخته می‌شوند. به منظور استفاده از بهینه‌ترین حالت، اطلاعات مربوط به ویژگی‌های نوری مورد نیاز اتمیسفر، باید در زمان برداشت سنجنده از منطقه مورد مطالعه تهیه شوند. روش‌های مبتنی بر انتقال تابش توسط کافمن و سندرا^۷ ۱۹۸۸ [۸] ورموت و همکاران ۱۹۹۶ [۴] کافمن و تانر^۸ ۱۹۹۶ [۹] عنوان شده و توسعه داده شده‌اند. در تحقیق حاضر نیز به دلیل مدلسازی نسبتاً دقیق‌تر از اتمیسفر نسبت به سایر روش‌ها، سرعت بالای محاسبات، مدت، و همچنین گنجاندن مقادیر آتروسول و بخار آب در محاسبات (که از تاثیرگذارترین پارامترها هستند) [۱۰] از روش تصحیح اتمیسفری FLAASH مبتنی بر انتقال تابش استفاده شده‌است.

بازتابندگی سطحی که مناسبترین کمیت در خصوص مطالعات مختلف در نظر گرفته می‌شود می‌تواند تحت تاثیر روش‌های تصحیح و پارامترهای مختلف اتمیسفر قرار گرفته و بالتبع استفاده‌های مختلف از این کمیت همچون بازتابی پارامترهای گیاهی را نیز دچار تغییر کند. یکی از مهمترین پارامترهای گیاهی، شاخص کسر پوشش گیاهی (FCOVER^۹) می‌باشد. FCOVER به مساحتی از سطح زمین که توسط برآمدگی تاج گیاه پوشیده شده‌است، اطلاق می‌گردد و مقادیر آن بین ۰ و ۱ می‌باشد. این شاخص یک کمیت ساختاری گیاه است و بیانگر تقسیم‌بندی سهمی از خاک و پوشش گیاهی در انتشار انرژی و دما مابین اتمیسفر و خاک می‌باشد. بنابراین به منظور توصیف فرآیندهای سطح زمین و طرح‌های پارامترسازی سطح مورد استفاده قرار می‌گیرد [۱۱]. محاسبه دقیق متغیرهای بیوفیزیکی گیاهان در مطالعات مختلف اهمیت بسیار زیادی داشته و اقدامی ضروری در کاربردهایی در حوزه کشاورزی و اکولوژیکی از جمله: بررسی صحت و سلامت گیاهان [۱۲]، نظارت بر

۵ Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes

۶ Atmospheric and Topographic correction

۷ Sendra

۸ Tanré

۹ Fractional vegetation cover

۱ Top of atmosphere (TOA)

۲ Zenith angle

۳ Azimuth angle

۴ Vermeulen

ویژگی محصولات [۱۳] و توسعه دادن پیش‌بینی مقادیر محصول و همچنین کاهش مقدار مصرف کود [۱۴] می‌باشد. مهم‌ترین کاربردهای جنگل‌داری و بوم‌شناسی در مقیاس‌های مختلف نیازمند برآورد دقیق شاخص FCOVER هستند [۱۵]. همچنین، استفاده از شاخص FCOVER روشی مناسب برای ارزیابی شدت آتش‌سوزی می‌باشد [۱۶]. با توجه به اهمیت دقت محاسبه شاخص‌های گیاهی و اهمیت شاخص FCOVER لذا در این تحقیق به بررسی اثرات اتمسفر بر بازیابی این پارامتر پرداخته می‌شود. بازیابی پارامترهای گیاهی با استفاده از سنجنده‌های چندطیفی مرئی در دهه‌های اخیر در مطالعات مختلف درحال استفاده می‌باشد [۱۷]، [۱۳]. الگوریتم‌های بسیاری برای بازیابی FCOVER از داده‌های سنجنش از دوری ماهواره‌ای توسعه یافته [۱۸] و چندین محصول جهانی FCOVER از داده‌های به دست آمده توسط ماهواره AVHRR^{۱۰} تولید شده‌اند [۱۹]. روش‌های بازیابی پارامتر با استفاده از تصاویر مرئی، در سه گروه روش‌های تجربی-آماری، فیزیک-پایه و ترکیبی قرار می‌گیرند [۱۷]، [۲۰]. رویکرد نخست به دلیل سادگی و سرعت بالای محاسباتی بیشتر از سایر رویکردها در مطالعات گوناگون مورد استفاده قرار می‌گیرد. روش‌های تجربی-آماری به دو دسته روش‌های پارامتریک و ناپارامتریک تقسیم می‌شوند. روش‌های پارامتریک رگرسیونی رابطه مشخصی بین پارامترهای بیوفیزیکی و شاخص‌های گیاهی تعریف می‌نمایند، درحالی که روش‌های ناپارامتریک رگرسیونی مدل‌هایی را مبتنی بر مجموعه داده‌های آموزشی تعریف می‌کنند [۲۱]. مدل‌های پارامتریک دارای نقاط ضعف مهمی هستند، که قاعدتاً منجر به پیش‌بینی ضعیف داده‌های آزمایشی می‌شود [۲۲]. درمقابل، روش‌های رگرسیونی ناپارامتریک و غیرخطی که شامل الگوریتم‌های یادگیری ماشین^{۱۱} می‌شوند، به شکل موثرتری ظاهر شده‌اند و می‌توانند از تمامی اطلاعات طیفی استفاده کرده و رابطه بین داده‌های ورودی و خروجی را مستقیماً از داده‌های آموزشی یاد بگیرند. روش‌های یادگیری ماشین به‌عنوان ابزاری قدرتمند در بازیابی متغیرهای بیوفیزیکی ظاهر شده‌اند [۲۳]. ازجمله آن‌ها می‌توان به شبکه‌های عصبی^{۱۲} [۲۴]، [۲۵]، ماشین بردار

پشتیان^{۱۳} [۲۶]، فرآیند گاوسی^{۱۴} [۲۷] و درخت رگرسیون^{۱۵} اشاره نمود.

در تحقیق حاضر از دو روش شبکه عصبی و درخت رگرسیون به جهت مدل‌سازی استفاده شده‌است. این دو الگوریتم، به عنوان روش‌هایی اثبات‌شده و متداول برای مدیریت روابط پیچیده و غیرخطی بین متغیرهای ورودی و خروجی هستند. تمرکز بر این روش‌ها این امکان را می‌دهد تا قابل اعتماد بودن این الگوریتم‌های شناخته‌شده در رابطه با بازیابی FCOVER بررسی شود. این دو الگوریتم همچنین در مدیریت پارامترهای ورودی بسیار کارآمد بوده و حتی در شرایط داده‌های ناقص یا غیرقطعی عملکرد قابل‌قبولی ارائه می‌دهند. انتخاب این دو الگوریتم همچنین بر پایه تحقیقات قبلی استوار است که اثربخشی آن‌ها در سنجنش از دور و بازیابی شاخص‌های گیاهی را نشان داده‌اند، و نتایج مطالعه را با سایر تحقیقات قابل مقایسه می‌سازد.

اجرای تصحیح اتمسفری بر روی تصاویر ماهواره‌ای، بازتابندگی سطحی را دچار تغییراتی می‌کند. علاوه بر این استفاده از پارامترهای اتمسفری از قبیل بخارآب، ضخامت نوری هواویزها و میدان دید، میزان آزن و دی اکسید کربن که از منابع مختلف زمینی در ایستگاه‌های واقع در محدوده تصویر و همچنین استفاده از محصولات سایر سنجنده‌ها و یا با استفاده از حدس کاربر استخراج می‌شوند، می‌تواند نتایج مختلفی را حاصل کند [۲]. از دیگر سوی، حتی میزان تغییرات اندک بازتابندگی سطحی می‌تواند باعث عدم اطمینان در بازیابی پارامتر شود. علیرغم اهمیت این موضوع، تاکنون مطالعه جامعی که به بررسی اثرات پارامترهای اتمسفری و عدم اطمینان آن‌ها در بازیابی پارامترهای گیاهی و سایر کاربردهای سنجنش از دوری بپردازد، انجام نشده‌است. تحقیق حاضر با هدف پوشش دادن این چالش، تاثیر تغییرات پارامترهای اتمسفری بر دقت بازیابی FCOVER را با استفاده از الگوریتم‌های شبکه عصبی و درخت رگرسیون بررسی می‌کند. به این منظور، تصحیح اتمسفری که یک مرحله پیش پردازشی بوده و اجرای آن در خصوص کاربردهای بازیابی پارامتر از اقدامات ضروری، پیش از بازیابی می‌باشد [۲۸] با تغییر پارامترهای بخارآب و میدان دید انجام گرفته‌است.

^{۱۳} Support Vector Machine (svm)

^{۱۴} Gaussian Processes (GP)

^{۱۵} Regression Tree

^{۱۰} Advanced Very High-Resolution Radiometer

^{۱۱} Machine Learning Regression Algorithms (MLRA)

^{۱۲} Neural Network (NN)

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

منطقه کشاورزی کارمان^{۱۶} واقع در استان مانیتوبا^{۱۷} در کشور کانادا به دلیل وجود داده‌های زمینی از شاخص FCOVER، به عنوان منطقه مورد مطالعه انتخاب شده است. عرض جغرافیایی منطقه ۳۰° ۵۴' ۹۸" غربی و طول جغرافیایی آن ۲۲° ۴۵' ۴۹" شمالی می‌باشد. به طور کلی استان مانیتوبا دارای پوشش گیاهی گسترده و متنوع بوده که منطقه کشاورزی کارمان نیز بخشی از این پوشش‌های گیاهی را در خود جای داده است. محصولات کشاورزی در استان مانیتوبا متمرکز بر کشت سویا می‌باشد با اینحال ذرت و گندم نیز در این منطقه کشت داده می‌شود [۲۹]. در کمپین مانیتوبا ۲۰۱۶ پارامترهای شاخص سطح برگ^{۱۸} و کسر پوشش گیاهی از گیاهان مختلف شامل ذرت، گندم، سویا، یونجه، جو دوسر، کانولا و لوبیای سیاه نمونه برداری شده است. شکل ۱ منطقه مورد مطالعه را نشان می‌دهد.

۲-۲- داده‌های مورد استفاده

داده‌های مورد استفاده در تحقیق حاضر شامل دو تصویر لندست-۸ در تاریخ‌های ۲۷/۰۶/۲۰۱۶ و ۱۸/۰۷/۲۰۱۶ (جدول ۱ مشخصات این ماهواره را نشان می‌دهد) و همچنین داده‌های زمینی FCOVER از پروژه مانیتوبا^{۱۹} می‌باشد. این پروژه توسط محققین سازمان هوانوردی و فضانوردی امریکا^{۲۰} با هدف بررسی رطوبت فعال و غیر فعال خاک انجام شده است. این پروژه در سال ۲۰۱۶ در منطقه کشاورزی کارمان، استان مانیتوبا، کانادا صورت گرفته است [۲۹]. از این منطقه در مجموع ۷۰۰ نمونه زمینی LAI و FCOVER با استفاده از عکسبرداری دیجیتال نیمکره‌ای جمع‌آوری شده است. عکسبرداری از ۵۰ مزرعه کشاورزی انجام شده که هر کدام دارای ۱۶ مکان نمونه برداری بوده‌اند. در مجموع از سه نقطه نمونه برداری در هر مزرعه عکسبرداری شد. در طول کمپین، مکان‌ها با استفاده از

واحد‌های GPS Garmin شناسایی شدند. دقت هر واحد GPS تقریباً ۳ متر بوده است [۲۹].

برای گرفتن هر عکس یک دوربین با عدسی چشم ماهی حداقل ۵۰ سانتی متر، بالا یا پایین تاج پوشش قرار داده شد. برای عکسبرداری از بالای تاج پوشش دوربین روی یک پایه نصب شده است. تصاویر از زیر تاج پوشش نیز برای محصولات ذرت در ماه جولای گرفته شده است. در همه موارد، دوربین‌ها رو به خورشید قرار می‌گرفتند تا سایه را به حداقل برسانند. عکسبرداری در امتداد هر ترانسکت به فاصله تقریباً ۵ متری از یکدیگر انجام شد. به منظور افزایش کیفیت نمونه‌های برداشت شده از نرم‌افزار ViewNX-2 (Nikon) استفاده شده است. سپس تصاویر جهت پردازش‌های بعدی به نرم افزار CanEye وارد شدند. پارامترهای CanEye که شامل تعداد خطوط، تعداد ستون‌ها، تاریخ ژوئیه‌سی^{۲۱} و عرض جغرافیایی می‌باشد، برای عکس‌ها پیکربندی شدند. داده‌های غیرعادی و مشکل دار حذف شده و در ادامه، عکس‌ها به دقت در پوشش گیاهی و خاک طبقه بندی شدند. در نهایت با استفاده از CanEye میانگین LAI و FCOVER را برای هر مکان نمونه‌برداری از تمام عکس‌های قابل استفاده در هر سایت محاسبه گردید. گیاهان نمونه برداری شامل ذرت، گندم، سویا، یونجه، جو دوسر، کانولا و لوبیای سیاه می‌باشند. نمونه‌های FCOVER به همراه تصویر لندست-۸ برای بازیابی در تحقیق حاضر به کار رفته‌اند.

جدول ۱. مشخصات ماهواره لندست-۸	
ارتفاع سکو	۷۰۵ کیلومتر
پهنای نوار (Swath)	۱۸۵ کیلومتر
قدرت تفکیک مکانی	۳۰ متر ۱۵ متر ۱۰۰ متر
تعداد باند طیفی	۸ باند مرئی و مادون قرمز ۱ باند پانکروماتیک ۲ باند حرارتی
قدرت تفکیک طیفی	۴۳۳-۱۳۹۰ نانومتر ۱۰۶۰۰-۱۲۵۰۰ نانومتر (محدوده حرارتی)
زمان گردش به دور زمین	خورشید آهنگ، ۹۹ دقیقه


۱۶ Carman
۱۷ Manitoba
۱۸ Leaf Area Index
۱۹ SMAPVEX16 Manitoba
۲۰ The National Aeronautics and Space Administration

و درخت رگرسیون از نرم‌افزار متلب نسخه ۲۰۲۲^{۲۳} استفاده گردید. به منظور اجرای الگوریتم درخت رگرسیون تعداد بهینه برای پارامترهای تاثیر گذار همچون تعداد برگ و انتخاب متغیرهای تصادفی هر گره^{۲۴} به صورت تجربی انتخاب شدند. از ۱ تا ۱۰ برگ مورد آزمون قرار گرفته و با توجه به ریشه میانگین مربعات خطای کمتر، در نهایت تعداد بهینه برگ ۳ برای مدلسازی مورد استفاده قرار گرفت. تعداد متغیرهای تصادفی نیز ۷ در نظر گرفته شد. همچنین به منظور اجرای الگوریتم شبکه عصبی پارامترهای تاثیرگذار از جمله تعداد لایه‌های متصل شده^{۲۵} و اندازه آن‌ها، تابع فعال سازی و تعداد تکرار آن و تنظیم کننده‌ها به صورت تجربی مورد آزمون قرار گرفته و با توجه به میانگین مربعات خطای کمتر، مقادیر نهایی برای تعداد لایه‌ها ۳، ساین هرکدام ۱۰ و تابع فعال سازی سیگموئید^{۲۶} با دوره تکرار ۵۰ انتخاب شد.

در ادامه آزمون تی دو نمونه ی جفت شده جهت بررسی تاثیر پارامترهای مختلف اتمسفری، بررسی تفاوت تصویر تصحیح شده و تصحیح نشده و همچنین به منظور بررسی تفاوت عملکرد الگوریتم‌های یادگیری ماشین مورد استفاده، در سطح ۵ درصد به کار گرفته شد. روند انجام این تحقیق در شکل ۲ به صورت نمودار جریان نشان داده شده‌است.

۲-۳-۱- تصحیح اتمسفری

در این مطالعه از الگوریتم تصحیح اتمسفری FLAASH^{۲۷} استفاده شد. این روش که بر مبنای مدل‌های انتقال تابش خورشیدی است، یک بسته نرم افزاری مبتنی بر روش مادترن^{۲۸} می‌باشد و با همکاری محققان علوم طیفی^{۲۹} و آزمایشگاه تحقیقاتی نیروی هوایی امریکا^{۳۰} و Hanscom AFB^{۳۱} به منظور خوانش و پوشش دادن داده‌های مادون قرمز، مرئی، داده‌های چندطیفی و آبرطیفی عموماً در فرمت تصویر توسعه داده شده‌است [۳۰].



شکل ۱. تصویر منطقه مورد مطالعه: منطقه کشاورزی کارمان استان مانیتوبا، کانادا

۲-۳-۲- روش تحقیق

در این تحقیق از دو روش شبکه عصبی و درخت رگرسیون به منظور مدلسازی شاخص FCOVER، با استفاده از تصویر لندست-۸ استفاده شد. باندهای مرئی تصویر لندست-۸ با قدرت تفکیک مکانی ۳۰ متر به کار رفتند. به منظور انجام تصحیح اتمسفری از روش FLAASH استفاده شده‌است. مقادیر مختلف بخار آب و میدان دید جایگذاری شده و سپس تصحیح اتمسفری مکرراً اجرا و نتایج حاصله به منظور انجام بازیابی FCOVER ذخیره شد. مقادیر مختلف بخار آب و میدان دید بر اساس انحراف معیار مقادیر سالانه پارامترهای ذکر شده از منطقه مورد نظر تولید شدند. به این صورت که مقدار بخار آب و میدان دید در تاریخ برداشت تصویر از وبسایت هواشناسی جهانی^{۳۲} برداشت شده و از عدد انحراف معیار بیشینه و کمینه در بازه زمانی یکساله کسر گردیده و سپس برای هر پارامتر ۷ مقدار مختلف به این ترتیب بدست آمد. در تحقیق حاضر به جهت اجرای الگوریتم‌های شبکه عصبی رگرسیونی

۲۳ MATLAB_R2022a

۲۴ Surrogate decision splits

۲۵ Fully connected layers

۲۶ Sigmoid Activation

۲۷ Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes

۲۸ Moderate spectral resolution transmittance-Moderate resolution atmospheric Transmission


۲۹ Spectral sciences inc (SSI)

۳۰ Air Force Research Laboratory (AFRL)

۳۱ Hanscom Air Force Base

۳۲ <https://www.visualcrossing.com/>

این روش با اهداف عمده‌ای از جمله توصیف نسبتاً دقیق از سطح و ویژگی‌های اتمسفری (مانند آلبيدو، ارتفاع نسبی، مقدار بخار آب و آئروسول، دما و ویژگی‌های اپتیکی ابرها)، حداقل کردن زمان محاسبات و همچنین تعامل و کاربر پسند بودن آن به منظور تصویرسازی براساس جداول جست و جویی^{۳۲} که مبتنی بر مادترن ۴ هستند، انجام شده‌است [۳۰].



شکل ۲. نمودار جریان‌ی تحقیق

محاسبات FLAASH بر پایه یک فرمول استاندارد می‌باشد. بازتابندگی طیفی در سنجنده (L) را محاسبه کرده و سپس این محاسبات را با توجه به طیف خورشیدی، به سطوح صاف، لامبرتی و شبه لامبرتی تعمیم می‌دهد. فرمول (۱) رابطه مورد استفاده در این روش را نشان می‌دهد:

$$L = \left(\frac{A\rho}{1-\rho_e S} \right) + \left(\frac{B\rho_e}{1-\rho_e S} \right) + L_a \quad (1)$$

در رابطه (۱) ρ و ρ_e به ترتیب بیانگر بازتاب پیکسل از سطح و میانگین بازتاب سطح از پیکسل و پیکسل‌های مجاور می‌باشد. همچنین S نشان دهنده آلبيدوی کروی اتمسفر، L_a نشان دهنده رادیانس بازپخش شده توسط اتمسفر و A و

B ضرایبی هستند که به شرایط اتمسفری و هندسی وابسته بوده اما وابستگی به سطح ندارند. بخش اول رابطه (۱) نشان دهنده رادیانسی است که مستقیم از سطح به سنجنده می‌رسد، درحالی‌که بخش دوم رابطه، رادیانسی را نشان می‌دهد که در اتمسفر پخش شده و سپس به سمت سنجنده حرکت می‌کند. تمایز بین ρ و ρ_e در به حساب آوردن اثر همسایگی پیکسل‌های مجاور است که به دلیل پخش اتمسفر اتفاق می‌افتد. این الگوریتم اثر همسایگی را در محاسبات خود دخیل کرده و آن را تصحیح می‌کند. مقادیر A ، B ، S و L_a از محاسبات مبتنی بر مادترن ۴ حاصل شده و درکنار اندازه‌های زوایای زنیث و آزیموت خورشید و ماهواره و همچنین میانگین ارتفاع سطح، یک مدل اتمسفری مشخص با درنظر گرفتن نوع هواویز در محدوده مرئی می‌سازد [۳۱].

۲-۳-۲- پیاده‌سازی الگوریتم‌های مدل‌سازی

۲-۳-۳-۱- شبکه عصبی

شبکه عصبی یکی از رایج‌ترین روش‌های ناپارامتریک غیر خطی است که به طور متداول در مسائل رگرسیونی و طبقه‌بندی مورد استفاده قرار می‌گیرد [۲۰]. متغیرهای ورودی برای آن می‌توانند کمی و غیر کمی باشند ولیکن به منظور اجرای شبکه عصبی رگرسیونی متغیر وابسته ی عددی مورد نیاز است.

شبکه‌های عصبی مصنوعی از یک لایه ورودی، یک یا چند لایه ی پنهان و یک لایه خروجی تشکیل شده‌است [۳۲]. هر لایه از n تعداد نرون تشکیل شده و دارای یک تابع فعال‌سازی مرتبط با هر یک از نرون‌ها می‌باشد. وجود تابع فعال‌سازی در هر لایه، توانایی یادگیری روابط پیچیده بین متغیرها و تابع هدف را ایجاد می‌کند. همچنین تنظیم‌کننده‌ها^{۳۳} وظیفه جلوگیری از برازش بیش از حد^{۳۴} داده را بر عهده دارند. به طور کلی شبکه عصبی مصنوعی از دو فاز انتشار رو به جلو^{۳۵} و انتشار رو به عقب^{۳۶} تشکیل شده‌است. رویکرد نخست فرآیند وزن‌دهی به لایه‌ها و رویکرد دوم به فرآیند به‌روزرسانی وزن‌ها در مدل اطلاق می‌شود [۳۳]. آموزش یک شبکه عصبی مستلزم انتخاب

^{۳۳} Regularizer

^{۳۴} overfitting

^{۳۵} Forward Propagation

^{۳۶} Backward Propagation

^{۳۲} Look-up tables

یک ساختار، مقداردهی اولیه وزن‌ها، شکل غیرخطی بودن، نرخ یادگیری و پارامترهای منظم‌سازی برای جلوگیری از برازش بیش از حد به داده‌ها می‌باشد. شبکه‌های عصبی به طور گسترده در بازیابی پارامترهای بیوفیزیکی مورد استفاده قرار گرفته‌اند [۳۴]، [۳۵]، [۳۶].

۲-۲-۳-۲- درخت رگرسیون

طبقه‌بندی و رگرسیون از طریق ساختار درختی که از روش‌های محاسباتی ناپارامتریکی محسوب می‌شوند در طول دهه‌های اخیر محبوبیت زیادی پیدا کرده‌اند. درخت رگرسیون اساساً یک درخت تصمیم‌گیری است که به منظور پیش‌بینی خروجی‌های با مقادیر پیوسته به جای خروجی‌های گسسته مورد استفاده قرار می‌گیرد [۳۷] و همانند سایر الگوریتم‌های یادگیری ماشین به منظور تولید مقادیر پیش‌بینی، مشاهدات را به عنوان داده‌های ورودی در نظر گرفته و آن‌ها را به متغیر هدف تبدیل می‌کند. این الگوریتم پارامترهای ورودی را نصف می‌کند تا بخش بندی‌های باینری ایجاد کند. هر بخش ایجاد شده، گره نامیده شده و گره‌های پایانی، گره برگ نامیده می‌شوند [۳۸]. در داخل هر گره، درخت رگرسیون مقداری را به عنوان میانگین تخمین می‌زند. این فرآیند مقدار میانگین مربعات خطا ($MSE^{(y)}$) را بین مقدار پیش‌بینی شده و اندازه‌گیری شده به حداقل می‌رساند. روش تقسیم گره تا زمانی که MSE مورد نظر برای درخت به دست آید، به صورت بازگشتی تکرار می‌شود. این ویژگی‌ها، درخت رگرسیون را به یکی از پرکاربردترین روش‌های یادگیری تبدیل می‌کند که در حال حاضر مورد استفاده قرار می‌گیرند [۳۹]. درخت رگرسیون همچنین می‌تواند تخمین‌هایی با بایاس^{۳۸} پایین ایجاد کند اما این عمل می‌تواند مستعد واریانس بالا باشد که واریانس بالا نشان‌دهنده برازش بیش از حد داده می‌باشد [۴۰]، [۴۱]، [۲۳]. داده‌ها در الگوریتم درخت تصمیم‌گیری به طور کلی به صورت زیر می‌باشد:

$$(x, Y) = (x_1, x_2, x_3, \dots, x_k, Y) \quad (2)$$

Y متغیر هدف و x یک بردار چند بعدی است که شامل مقدار ویژگی‌های $x_1, x_2, x_3, \dots, x_k$ است.

از مجموع مربعات اختلافات^{۳۹} به منظور هرس درختان استفاده می‌شود. با تنظیم طبقه‌بندی از طریق حداقل کردن ناخالصی اندازه‌گیری شده توسط شاخص جینی^{۴۰} (معیاری از پراکندگی آماری) جهت گسترش درخت استفاده می‌شود. برای درخت رگرسیون، معیار خطا-پیچیدگی از فرمول (۳) محاسبه می‌شود:

$$R\alpha(T) = R(T) + \alpha|T| \quad (3)$$

$R(T)$ مجموع مربعات اختلافات مقادیر داده‌های آموزشی و مقادیر پیش‌بینی شده، $|T|$ تعداد گره‌های نهایی و α ضریبی است که در اندازه‌گیری برای هر گره پایانی مشارکت دارد [۳۷].

۲-۳-۳- ارزیابی روش‌ها

دریافت نتایج خطا به صورت یک مقدار عددی بسیار مهم است. در غیر این صورت ارزیابی عملکرد الگوریتم مورد استفاده دشوار خواهد بود. به همین دلیل به منظور یافتن دقت مدل‌سازی FCOVER توسط شاخص‌های آماری میانگین مربعات خطا^{۴۱} و ضریب تعیین^{۴۲} مورد ارزیابی قرار گرفت. فرمول‌های RMSE و R^2 در ادامه بیان شده‌است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (4)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{x}_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (5)$$

در فرمول‌های (۴) و (۵)، علامت‌های $\hat{x}_i$ و $\bar{x}$ به ترتیب بیانگر مقدار FCOVER برداشت‌شده، میانگین مقادیر FCOVER برداشت‌شده و مقدار FCOVER حاصل از مدل‌سازی می‌باشند.

همچنین، به منظور ارزیابی عملکرد مدل و نتایج حاصله، داده‌ها به سه مجموعه داده‌های آموزشی، آزمایشی و اعتبارسنجی تقسیم شدند. به طور معمول مجموعه

^{۳۹} sum of squared or absolute differences

^{۴۰} Gini Coefficient

^{۴۱} Mean Square Error

^{۴۲} R Squared

^{۳۷} Mean Square Error

^{۳۸} Bias

آموزشی شامل ۷۰٪ از داده‌ها و مجموعه آزمایشی و مجموعه اعتبارسنجی هر کدام ۱۵٪ در نظر گرفته می‌شوند. بر این اساس برای داده‌های آموزشی ۳۵۸ نمونه، تعداد داده‌های آزمایشی ۷۷ نمونه و مجموعه اعتبارسنجی ۷۷ نمونه از کل داده‌ها بدست آمده‌است. داده‌های اعتبارسنجی به منظور بهینه سازی پارامترهای روش‌های یادگیری ماشین مورد استفاده قرار گرفتند. داده‌های آزمایشی نیز به منظور تعیین صحت عملکرد مدل‌هایی مورد استفاده قرار گرفتند که با استفاده از داده‌های آموزشی بدست آمدند.

۳- نتایج

در این بخش، نتایج الگوریتم‌های مدلسازی به کار رفته در تحقیق حاضر و همچنین عملکرد هر یک از روش‌ها در دامنه‌های متفاوت پارامتر بخارآب و میدان دید بررسی شده‌است.

جدول ۲. نتایج حاصل از مدلسازی FCOVER مستخرج شده از تصحیح اتمسفری FLAASH برای مقادیر بخارآب

مقدار بخارآب (میلی بار)	روش مدلسازی	میانگین مربعات خطا	ضریب تعیین
۰.۲۷	درخت رگرسیون	۰.۲۰۴۴	۰.۵۵
	شبکه عصبی	۰.۲۰۶۶	۰.۵۳
۰.۳۹	درخت رگرسیون	۰.۲۴۷۱	۰.۳
	شبکه عصبی	۰.۲۱۵۷	۰.۴۴
۰.۵۱	درخت رگرسیون	۰.۲۲۷۲	۰.۳۷
	شبکه عصبی	۰.۲۳۱۶	۰.۳۵
۰.۶۳	درخت رگرسیون	۰.۲۱۷۳	۰.۴۴
	شبکه عصبی	۰.۲۲۱۴	۰.۴
۰.۷۵	درخت رگرسیون	۰.۲۳۴۶	۰.۳۶
	شبکه عصبی	۰.۲۱۶۱	۰.۴۵
۰.۸۷	درخت رگرسیون	۰.۲۷۱	۰.۰۸
	شبکه عصبی	۰.۲۳۱۹	۰.۳۴
۰.۹۹	درخت رگرسیون	۰.۳۲۷۸	۰.۰۲
	شبکه عصبی	۰.۲۶۸۷	۰.۱۳
تصویر	درخت رگرسیون	۰.۲۷۲۸	۰.۰۹
تصحیح نشده	شبکه عصبی	۰.۲۳۳	۰.۳

ابتدا نتایج حاصل از مدلسازی پارامتر FCOVER از تصاویر تصحیح شده و تصحیح نشده توسط مدل‌های

رگرسیونی شبکه عصبی و درخت رگرسیون ارائه می‌شود. سپس به منظور مقایسه عملکرد الگوریتم‌های مدلسازی و همچنین مقایسه تاثیر هر پارامتر اتمسفری از نظر آماری نتایج آزمون تی دو نمونه مستقل مورد بررسی قرار می‌گیرد. جدول (۲) نتایج حاصل از دو روش شبکه عصبی و درخت رگرسیون را در دامنه تغییرات بخارآب نشان می‌دهد. اگرچه که در نگاه نخست هر دو الگوریتم عملکردینزدیک بهم و مناسب در بازیابی FCOVER داشته‌اند با این حال، الگوریتم شبکه عصبی عموماً میزان خطای کمتری را نشان می‌دهد. مشاهده می‌شود که به طور کلی با افزایش بخارآب مقدار RMSE نیز روند افزایشی دارد. همچنین مقادیر مربوط به تصویر تصحیح نشده نشان می‌دهد میزان خطای RMSE تصویر تصحیح نشده از RMSE تصاویر تصحیح شده بیشتر است. ولیکن مقدار خطای ناشی از تصویر تصحیح نشده درمقایسه با تصاویر دارای مقادیر بالای بخارآب که به حالت اشباع نزدیک است، کمتر و یا برابر می‌باشد.

جدول (۳) نتایج حاصل از دو روش شبکه عصبی و درخت رگرسیون را در دامنه تغییرات میدان دید نشان می‌دهد. طبق نتایج این جدول تغییرات هم‌روندی با افزایش یا کاهش میدان دید در مقدار RMSE دیده نمی‌شود. در مواردی افزایش جزئی RMSE با افزایش میدان دید نشان داده شده و در مواردی عکس این حالت صادق است. همچنین مقدار RMSE در تصویر تصحیح نشده نسبت به تصاویر تصحیح شده بیشتر می‌باشد.

جدول ۳. نتایج حاصل از مدلسازی FCOVER مستخرج شده از تصحیح اتمسفری FLAASH برای مقادیر میدان دید

مقدار میدان دید (کیلومتر)	روش مدلسازی	میانگین مربعات خطا	ضریب تعیین
۸	درخت رگرسیون	۰.۲۲۶	۰.۳۷
	شبکه عصبی	۰.۲۱۳۱	۰.۴۷
۱۶	درخت رگرسیون	۰.۲۲۴۴	۰.۳۸
	شبکه عصبی	۰.۲۱۴۷	۰.۴۶
۲۴	درخت رگرسیون	۰.۲۲۴۴	۰.۳۸
	شبکه عصبی	۰.۲۱۹۴	۰.۴۲
۳۲	درخت رگرسیون	۰.۲۲۴۴	۰.۳۸
	شبکه عصبی	۰.۲۰۸۶	۰.۵۵
تصویر	درخت رگرسیون	۰.۲۷۲۸	۰.۰۹
تصحیح نشده	شبکه عصبی	۰.۲۳۳	۰.۳

جدول (۴) نتایج حاصل از آزمون تی دو نمونه جفت شده در دامنه تغییرات بخارآب را نشان می‌دهد. با توجه به نتایج آماری، تغییرات مقدار بخارآب موجود در اتمسفر تا کمتر از ۰.۴۰ درصد در بازیابی FCOVER تاثیری نداشته و تفاوتی ایجاد نمی‌کند، ولیکن مقادیر بیشتر از عدد ذکر شده شروع اثر گذاری بخارآب در بازیابی پارامتر را نشان می‌دهد. در نتیجه از نظر آماری، تغییرات بخارآب در بازیابی FCOVER عاملی تاثیر گذار بوده و مقادیر بالای بخارآب می‌تواند در بازیابی FCOVER ایجاد خطا کرده و مقدار عدم اطمینان را افزایش دهد.

جدول ۴. نتایج حاصل از آزمون تی دو نمونه جفت شده در بررسی تاثیر بخارآب در بازیابی FCOVER از تصاویر تصحیح شده در مقایسه

با تصویر تصحیح نشده		
تصویر تصحیح شده نسبت به تصویر تصحیح نشده	روش مدلسازی	Sig.
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۹۶
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۹۱
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۱۴
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۸۲
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۰
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۱۹
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۵
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۰۲
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۱
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۰۴
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۰
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۰۰
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۰
تصحیح با مقدار بخارآب نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۰۰

در جدول (۵) مشاهده می‌شود در هر دو الگوریتم مورد استفاده، تغییرات میدان دید از نظر آماری تفاوت معنی داری را نشان می‌دهد. می‌توان اینگونه بیان نمود که عموماً تغییرات مقدار میدان دید در بازیابی FCOVER تاثیرگذار می‌باشد. اگرچه در میدان دید ۲۴ کیلومتر عدم معنی داری نشان داده شده است، ولی به صورت کلی این نتایج مبین این موضوع می‌باشد که مقادیر مختلف میدان دید به صورت

مشخص بر خطای مربوط به بازیابی این پارامتر تاثیرگذار می‌باشد اگرچه این رابطه خطی نیست.

جدول ۵. نتایج حاصل از آزمون تی دو نمونه جفت شده در بررسی تاثیر میدان دید در بازیابی FCOVER از تصاویر تصحیح شده در مقایسه با تصویر تصحیح نشده

تصویر تصحیح شده نسبت به تصویر تصحیح نشده	روش مدلسازی	Sig.
تصحیح با مقدار میدان دید ۸ نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۰
تصحیح با مقدار میدان دید ۱۶ نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۰۱
تصحیح با مقدار میدان دید ۲۴ نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۱
تصحیح با مقدار میدان دید ۲۴ نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۰۱
تصحیح با مقدار میدان دید ۳۲ نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۱
تصحیح با مقدار میدان دید ۳۲ نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۲۳
تصحیح با مقدار میدان دید ۳۲ نسبت به تصویر تصحیح نشده	درخت رگرسیون	۰.۰۱
تصحیح با مقدار میدان دید ۳۲ نسبت به تصویر تصحیح نشده	شبکه عصبی	۰.۰۰

جدول (۶) نشان می‌دهد از نظر آماری تفاوت معنی داری بین تصویر تصحیح شده و تصویر تصحیح نشده وجود دارد، که این مسئله نشان دهنده ضرورت انجام تصحیح اتمسفری پیش از انجام بازیابی این پارامتر می‌باشد.

جدول (۷) تفاوت بین دو الگوریتم مورد استفاده در پژوهش حاضر در خصوص بازیابی FCOVER را نشان می‌دهد، که بر طبق آن از نظر آماری تفاوت چندانی بین عملکرد دو روش درخت رگرسیون و شبکه عصبی وجود ندارد. ولیکن با مقایسه مقادیر میانگین خطای مربعات حاصل از دو روش، شبکه عصبی با اختلاف جزئی، عموماً مقدار خطای کمتری را نتیجه می‌دهد.

جدول ۶. نتایج حاصل از آزمون تی دو نمونه جفت شده جهت بررسی عملکرد روش تصحیح اتمسفری FLAASH بر روی تصویر لندست-۸

تصحیح اتمسفری FLAASH	
تصویر تصحیح نشده	۰.۰۰

جدول ۷. نتایج حاصل از آزمون تی دو نمونه جفت شده جهت بررسی عملکرد روش‌های مدلسازی FCOVER مستخرج شده از روش

FLAASH از تصویر لندست-۸	
درخت رگرسیون	شبکه عصبی
درخت رگرسیون	-
شبکه عصبی	۰.۴۰
درخت رگرسیون	-
شبکه عصبی	۰.۴۰

۴- بحث

اتمسفر و پارامترهای مختلف اتمسفری بر بازایی شاخص‌های گیاهی تاثیرگذار می‌باشند. با اینحال، تاکنون مطالعه جامعی در خصوص بررسی مقایسه میزان تاثیرات هر کدام از پارامترهای اتمسفری صورت نگرفته‌است. در این تحقیق با توجه به نتایج ارائه شده در خصوص بررسی تاثیر پارامترهای اتمسفری بر بازایی FCOVER مشاهده شد که تاثیر هر پارامتر اتمسفری می‌تواند متفاوت باشد و این تفاوت را می‌توان ناشی از دلایل مختلفی دانست.

الگوریتم‌های یادگیری ماشین رگرسیونی در زمینه بازایی پارامترهای گیاهی از روش‌های کارآمد ناپارامتریک در رویکرد آماری به شمار می‌روند. الگوریتم‌های درخت رگرسیون و شبکه عصبی از تغییرات مقادیر بخار آب تاثیر پذیرفته‌اند. به‌طور کلی می‌توان بیان نمود مقادیر بالای بخار آب به شکلی محسوس بر کیفیت بازایی FCOVER تاثیرگذار می‌باشد. در مطالعات دیگری نیز نشان داده شده‌است که تفاوت مقادیر مختلف بخار آب بر شاخص‌های گیاهی مختلف تاثیرگذار می‌باشد [۴۲]، [۴۳].

گائو^{۴۳} و همکاران (۲۰۰۶) در تحقیقی که به بررسی بازتابش روزانه از لندست صورت گرفته بیان می‌کنند که شبکه عصبی نسبت به خطاهای ایجاد شده در تصحیح اتمسفری حساسیت بیشتری نسبت به سایر الگوریتم‌ها دارد. نتایج آن‌ها در واقع از نتایج حاصل شده در این تحقیق در خصوص حساسیت بیشتر شبکه عصبی نسبت به درخت رگرسیون پشتیبانی می‌کند [۴۴]. در پژوهشی توسط مارتینز-فرر^{۴۴} و همکاران (۲۰۲۲) که به منظور بازایی شاخص گیاهی FCOVER با دقت بالا و مدیریت داده‌ها انجام شد، از شبکه عصبی به منظور مدلسازی استفاده گردید نتایج نشان می‌دهد که این روش قادر به تولید نقشه‌های پیش‌بینی دقیق و قابل اطمینان می‌باشد [۴۵].

بررسی تاثیر میدان دید در بازایی FCOVER نشان داد که از نظر آماری تغییرات مقادیر میدان دید نیز بر کیفیت بازایی این پارامتر بیوفیزیکی تاثیرگذار می‌باشد. اگرچه که فانگ و همکاران (۲۰۱۹) نشان دادند که شاخص‌های گیاهی مختلف نسبت به تغییرات میدان دید و هواویزها واکنش‌های

متفاوتی دارند [۴۶]. برای این رخداد می‌توان دلایل مختلفی را برشمرد. میدان دید به مه و هواویز بستگی دارد و همچنین هواویزها می‌توانند نور را پراکنده یا جذب کنند. هواویزهای پخش کننده مانند غبار، امواج الکترومغناطیسی بیشتری به سمت سنجنده منعکس می‌کنند که این عامل میدان دید را افزایش می‌دهد اما درعین حال باعث ایجاد تصاویر با کیفیت پایین می‌شود. در نتیجه رابطه بین میدان دید و صحت بازایی ممکن است غیر خطی باشد، درواقع سطح دید متوسط بهینه‌ای وجود دارد که مقادیر بسیار کم یا بسیار زیاد می‌توانند صحت را کاهش دهند [۴۷]، [۴۸]. همچنین مناطق مختلف که دارای ترکیب‌های متفاوتی از هواویزها می‌باشند، می‌توانند به شکل متفاوتی با پارامتر اتمسفری میدان دید تعامل داشته باشند. پراکندگی بیشتر، در مقابل جذب ذرات معلق در هوا می‌تواند اثرات معکوس داشته باشد [۴۷]، [۴۹]، [۵۰]. ممکن است محدوده مقادیر میدان دید در برخی موارد از یک آستانه دقت عبور کرده باشد اما در موارد دیگر اینگونه نباشد. میدان دید بالا در برخی موارد می‌تواند سایر اثرات جوی مانند پراکندگی ریلی یا جذب ازن را اغراق آمیز کند [۴۷]، [۵۱]. مقادیر بسیار زیاد [۵۲] یا بسیار کم [۵۳] میدان دید باعث کاهش صحت بازایی پارامتر می‌گردد [۵۴]. مناطق مختلف بر اساس منابع آلودگی و گرد و غبار، ترکیب متفاوتی از هواویزهای جذب و پخش کننده را دارند [۴۹]، [۵۵]. همچنین محدوده کوچک مقادیر هواویز، تاثیرات بسیار اندکی بر محاسبات LAI و fAPAR در مزارع دارد [۲۱]، [۵۶]. این نتایج نشان می‌دهد که تاثیرگذاری میدان دید و هواویزها دارای حد آستانه‌ای می‌باشد که برای بررسی آن باید به عوامل مختلفی توجه نمود. با توجه به شرایط، میدان دید و مقدار هواویزها می‌توانند به افزایش صحت کمک کرده و همچنین باعث کاهش آن شوند. به‌طور کلی، روابط پیچیده انتقال تابش بین میدان دید، هواویزها، شرایط روشنایی، و خواص سطحی می‌توانند منجر به اثرات مختلط یا مشروطی بر صحت بازایی شوند. بنابراین ویژگی‌های داده‌ها، روش‌های پردازش، منطقه مورد مطالعه و معیارهای صحت می‌توانند نوع و میزان تاثیر پارامترهای اتمسفری بر بازایی را توضیح دهند.

از نظر آماری بین تصاویر تصحیح شده لندست-۸ با استفاده از روش تصحیح FLAASH و تصویر تصحیح نشده تفاوت معنی داری وجود دارد. این تفاوت در خصوص بازایی FCOVER نیز اثرات خود را نشان می‌دهد. با توجه

۴۳ Gao

۴۴ Martínez-Ferrer

به اطلاعات بخش‌های پیشین در تحقیق حاضر، تاثیرات تصویر تصحیح نشده نسبت به تصاویر تصحیح شده به طور کامل نشان داده شد، حتی اگر به لحاظ آماری درموردی بازیابی پارامتر تاثیرات قابل توجهی از تغییرات اتمسفر نشان ندهد، همانطور که توسط تن^{۴۵} و همکاران ۲۰۱۳ تایید شده است (که مقادیر بخار آب و هواویز در روش‌های تصحیح اتمسفری پیشرفته تاثیرات اندکی بجای می‌گذارند) [۵۷]، ولیکن با توجه به نتایج حاصل از RMSE نشان داده شد که اجرای تصحیح اتمسفری کیفیت تصویر را افزایش داده و اثر نویز را حذف می‌کند، حتی اگر پارامترها به‌طور جداگانه تأثیرات عمده‌ای را نشان ندهند. RMSE کمتر نشان می‌دهد که مقادیر بازیابی شده از تصاویر تصحیح شده در مقایسه با بازیابی‌های حاصل از تصویر اصلاح نشده به اندازه گیری‌های حقیقی زمینی نزدیک‌تر هستند. این امر ارزش تصحیح اتمسفری را به عنوان یک مرحله پیش پردازشی هنگام بازیابی پارامترهای پوشش گیاهی از داده‌های ماهواره‌ای برجسته می‌کند.

مشکلات چالش‌برانگیزی در انتخاب الگوریتم‌های یادگیری ماشین به جهت بازیابی پارامترهای گیاهی و همچنین تصمیم‌گیری در مورد تعداد بهینه برای اندازه داده‌های آموزشی و باندهای طیفی وجود دارد. برای به دست‌آوردن نتایج رضایت‌بخش از الگوریتم‌های یادگیری ماشین به تجربه نیاز است و ممکن است آزمایش‌هایی با تعداد زیادی مجموعه مورد نیاز باشد که معمولاً در دسترس نیستند. بر این اساس، لازم است مقایسه مدل‌های مختلف یادگیری ماشین به‌روزتر برای پشتیبانی از برنامه‌ها و مطالعات سنجش از دور انجام شود [۵۸]. به دلیل پیچیدگی‌های مدل کردن رابطه بازتابش-بازیابی پارامتر با تغییرات اتمسفر، استفاده از روش‌های غیرخطی در مقایسه با روش‌های خطی [۵۹] و همچنین غیرخطی رگرسیون-پایه مزایای بیشتری دارند [۶۰].

الگوریتم درخت رگرسیون نسبت به داده‌های ورودی حساسیت بیشتر و همچنین میزان خطای نسبتاً بیشتری را نشان داد. این الگوریتم سریع بوده و برای آموزش دادن آسانتر می‌باشد ولیکن در رابطه با شاخص‌های گیاهی و در مقایسه با دیگر روش‌ها صحت نسبتاً پایینی دارد [۶۱].

۴۵ Tan

مائو و همکاران (۲۰۱۹) نشان دادند که عملکرد مناسب الگوریتم شبکه عصبی در کنار الگوریتم فرآیند رگرسیون گاوسی در بازیابی شاخص گیاهی مناسب است، اگرچه که سرعت آموزش شبکه عصبی کندتر از سایر روش‌ها می‌باشد [۵۸].

همچنین در خصوص استفاده از تصاویر ماهواره‌ای به جهت مطالعات شاخص‌های گیاهی، انتخاب باند اهمیت زیادی دارد [۶۲]. به منظور بازیابی FCOVER اغلب باندهای مادون قرمز نزدیک و باند قرمز مورد استفاده قرار می‌گیرند [۶۳]. ورست و همکاران (۲۰۱۹) نشان دادند که باندهای لبه قرمز نسبت به تغییرات بخار آب مقاوم هستند [۲۰]. البته همانطور که ذکر شد عملکرد هرکدام به انتخاب شاخص گیاهی نیز بستگی دارد. همچنین بر طبق مطالعات ورست و همکاران (۲۰۱۵)، به منظور بازیابی FCOVER، استفاده از تنها دو باند به نتایج بهتر منجر نمی‌شود [۱۷]، [۶۴]. این نتایج در تحقیق کایرا و همکاران (۲۰۱۶) نیز نشان داده شد [۶۵]. لذا استفاده از تنها دو باند در بازیابی پارامترهای گیاهی توصیه نمی‌شود. همچنین در پایان لازم به ذکر است که به طور کلی عوامل مربوط به مشخصات ماهواره‌ها و ژئومتری تصویربرداری، الگوریتم‌های تصحیح و الگوریتم‌های مدلسازی می‌تواند منجر به تفاوت‌هایی در روند تصحیح و درنهایت تأثیر آن بر بازیابی FCOVER گردد و به همین خاطر تغییر در هر یک از این عوامل در تحقیقات آتی می‌تواند منجر به اخذ نتایجی متفاوت گردد.

۵- نتیجه‌گیری

همانطور که پیش‌تر ذکر شد، در این تحقیق از دو الگوریتم یادگیری درخت رگرسیون و شبکه عصبی استفاده شد و تاثیرات دو پارامتر بخار آب و میدان دید در بازیابی FCOVER مورد بررسی قرار گرفت. بر طبق تحلیل‌های آماری انجام شده، نتایج حاصله به شرح زیر می‌باشند: از نظر آماری مشاهده شد عموماً تغییرات مقدار بخار آب و میدان دید در بازیابی FCOVER تاثیرگذار می‌باشد. به طور کلی می‌توان بیان نمود مقادیر بالای بخار آب به شکلی محسوس بر کیفیت بازیابی FCOVER تاثیرگذار می‌باشد. همچنین بررسی تأثیر میدان دید در بازیابی FCOVER نشان داد که از نظر آماری تغییرات مقادیر میدان دید نیز بر کیفیت بازیابی این پارامتر بیوفیزیکی تأثیر گذار می‌باشد.

درخت رگرسین سریع بوده و برای آموزش دادن آسانتر می‌باشد ولیکن در رابطه با شاخص‌های گیاهی و در مقایسه با دیگر روش‌ها صحت نسبتاً پایینی دارد. در مقابل الگوریتم شبکه عصبی صحت بالاتری داشته اما سرعت آموزش داده‌ها با این روش کمتر بوده و برای داده‌های به تعداد بسیار بالا زمانبر می‌باشد.

همچنین مشاهده شد از نظر آماری بین تصاویر تصحیح‌شده با استفاده از روش اتمسفری FLAASH و تصویر تصحیح نشده برای تصویر لندست-۸ تفاوت معنی داری وجود دارد. این تفاوت در خصوص بازیابی FCOVER نیز اثرات خود را نشان می‌دهد. الگوریتم درخت رگرسین میزان خطای نسبتاً بیشتری را در مقایسه با الگوریتم شبکه عصبی نشان داد. الگوریتم

مراجع

- [1] Y. J. Kaufman, "Atmospheric effect on spatial resolution of surface imagery: errata," *Appl Opt*, vol. 23, no. 22, pp. 4164–4172, 1984, doi: 10.1364/AO.23.004164.
- [2] D. Giggenbach and A. Shrestha, "Atmospheric absorption and scattering impact on optical satellite-ground links," *International Journal of Satellite Communications and Networking*, vol. 40, no. 2, pp. 157–176, Mar. 2022, doi: 10.1002/sat.1426.
- [3] E. F. Vermote and S. Kotchenova, "Atmospheric correction for the monitoring of land surfaces," *Journal of Geophysical Research Atmospheres*, vol. 113, no. 23, Dec. 2008, doi: 10.1029/2007JD009662.
- [4] E. Vermote, N. El Saleous, and B. N. Holben, "Aerosol Retrieval and Atmospheric Correction," in *Advances in the Use of NOAA AVHRR Data for Land Applications*, G. D'Souza, A. S. Belward, and J.-P. Malingreau, Eds., Dordrecht: Springer Netherlands, 1996, pp. 93–124. doi: 10.1007/978-94-009-0203-9_5.
- [5] K. S. Lee, "Atmospheric Correction Issues of Optical Imagery in Land Remote Sensing," 2019, *Korean Society of Remote Sensing*. doi: 10.7780/kjrs.2019.35.6.3.12.
- [6] E. F. Vermote and A. Vermeulen, "MODIS Algorithm Technical Background Document ATMOSPHERIC CORRECTION ALGORITHM: SPECTRAL REFLECTANCES (MOD09)," 1999.
- [7] Mardina. Abdullah, *2013 IEEE International Conference on Space Science and Communication: 1-3 July 2013 Hotel Equatorial Melaka, Malaysia: proceeding: facing the challenges of solar maximum*. IEEE, 2013.
- [8] Y. J. Kaufman and C. Sendra, "Algorithm for automatic atmospheric corrections to visible and near-IR satellite imagery," *Int J Remote Sens*, vol. 9, no. 8, pp. 1357–1381, Aug. 1988, doi: 10.1080/01431168808954942.
- [9] Y. J. Kaufman and D. Tanré, "Strategy for direct and indirect methods for correcting the aerosol effect on remote sensing: From AVHRR to EOS-MODIS," *Remote Sens Environ*, vol. 55, no. 1, pp. 65–79, 1996, doi: https://doi.org/10.1016/0034-4257(95)00193-X.
- [10] H. RAHMAN and G. DEDIEU, "SMAC: a simplified method for the atmospheric correction of satellite measurements in the solar spectrum," *Int J Remote Sens*, vol. 15, no. 1, pp. 123–143, Jan. 1994, doi: 10.1080/01431169408954055.
- [11] Y. Nouvellon *et al.*, "Modelling of daily fluxes of water and carbon from shortgrass steppes," 2000.
- [12] C. Zhang and Y. Ma, Eds., *Ensemble Machine Learning*. New York, NY: Springer New York, 2012. doi: 10.1007/978-1-4419-9326-7.
- [13] S. Jay, F. Maupas, R. Bendoula, and N. Gorretta, "Author-produced version of the article published in Field Crops Research," vol. 210, pp. 33–46, 2017, doi: 10.1016/j.fcr.2017.05.005i.
- [14] J. P. Goffart, M. Olivier, and M. Frankinet, "Potato crop nitrogen status assessment to improve N fertilization management and efficiency: Past-present-future," in *Potato Research*, Dec. 2008, pp. 355–383. doi: 10.1007/s11540-008-9118-x.
- [15] L. Li *et al.*, "Review of ground and aerial methods for vegetation cover fraction (fCover) and related quantities estimation: definitions, advances, challenges, and future perspectives," May 01, 2023, *Elsevier B.V.* doi: 10.1016/j.isprsjprs.2023.03.020.
- [16] J. M. Fernández-Guisuraga, L. Calvo, C. Quintano, A. Fernández-Manso, and P. M. Fernandes, "Fractional vegetation cover ratio estimated from radiative transfer modeling outperforms spectral indices to assess fire severity in several Mediterranean plant communities," *Remote Sens Environ*, vol. 290, May 2023, doi: 10.1016/j.rse.2023.113542.

- [17] J. Verrelst *et al.*, "Experimental Sentinel-2 LAI estimation using parametric, non-parametric and physical retrieval methods - A comparison," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 108, pp. 260–272, Oct. 2015, doi: 10.1016/j.isprsjprs.2015.04.013.
- [18] F. Baret *et al.*, "Remote Sensing of Environment," vol. 110, no. 3, 2007, doi: 10.1016/j.rse.2007.02.018i.
- [19] G. Gutman and A. Ignatov, "The derivation of the green vegetation fraction from NOAA/AVHRR data for use in numerical weather prediction models," *Int J Remote Sens*, vol. 19, no. 8, pp. 1533–1543, Jan. 1998, doi: 10.1080/014311698215333.
- [20] J. Verrelst *et al.*, "Quantifying Vegetation Biophysical Variables from Imaging Spectroscopy Data: A Review on Retrieval Methods," May 01, 2019, *Springer Science and Business Media B.V.* doi: 10.1007/s10712-018-9478-y.
- [21] F. J. García-Haro *et al.*, "Derivation of global vegetation biophysical parameters from EUMETSAT Polar System." [Online]. Available: <https://landsat.ipma.pt>
- [22] A. J. Scardino, D. Hudleston, Z. Peng, N. A. Paul, and R. de Nys, "Biomimetic characterisation of key surface parameters for the development of fouling resistant materials," *Biofouling*, vol. 25, no. 1, pp. 83–93, Jan. 2009, doi: 10.1080/08927010802538480.
- [23] T. Hastie, R. Tibshirani, and J. Friedman, "Unsupervised Learning," in *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, T. Hastie, R. Tibshirani, and J. Friedman, Eds., New York, NY: Springer New York, 2009, pp. 485–585. doi: 10.1007/978-0-387-84858-7_14.
- [24] B. Dzwonkowski and X. -H. Yan, "Development and application of a neural network based ocean colour algorithm in coastal waters," *Int J Remote Sens*, vol. 26, no. 6, pp. 1175–1200, Mar. 2005, doi: 10.1080/01431160512331326549.
- [25] P. Cipollini, G. Corsini, M. Diani, and R. Grasso, "Retrieval of Sea Water Optically Active Parameters from Hyperspectral Data by Means of Generalized Radial Basis Function Neural Networks," 2001.
- [26] A. Plaza *et al.*, "Recent advances in techniques for hyperspectral image processing," *Remote Sens Environ*, vol. 113, no. SUPPL. 1, Sep. 2009, doi: 10.1016/j.rse.2007.07.028.
- [27] E. Pasolli, F. Melgani, M. Donelli, R. Attoui, and M. De Vos, "Automatic detection and classification of buried objects in GPR images using genetic algorithms and support vector machines," in *International Geoscience and Remote Sensing Symposium (IGARSS)*, Institute of Electrical and Electronics Engineers Inc., 2008, pp. 525–528. doi: 10.1109/IGARSS.2008.4779044.
- [28] I. Sola *et al.*, "Assessment of atmospheric correction methods for Sentinel-2 images in Mediterranean landscapes," *International Journal of Applied Earth Observation and Geoinformation*, vol. 73, pp. 63–76, 2018, doi: <https://doi.org/10.1016/j.jag.2018.05.020>.
- [29] T. Dong *et al.*, "Assessing the consistency of crop leaf area index derived from seasonal Sentinel-2 and Landsat 8 imagery over Manitoba, Canada," *Agric For Meteorol*, vol. 332, p. 109357, 2023, doi: <https://doi.org/10.1016/j.agrformet.2023.109357>.
- [30] G. P. Anderson *et al.*, "FLAASH and MODTRAN4: state-of-the-art atmospheric correction for hyperspectral data," in *1999 IEEE Aerospace Conference. Proceedings (Cat. No.99TH8403)*, 1999, pp. 177–181 vol.4. doi: 10.1109/AERO.1999.792088.
- [31] M. W. Matthew *et al.*, "Atmospheric correction of spectral imagery: Evaluation of the FLAASH algorithm with AVIRIS data," in *Proceedings - Applied Imagery Pattern Recognition Workshop*, Institute of Electrical and Electronics Engineers Inc., 2002, pp. 157–163. doi: 10.1109/AIPR.2002.1182270.
- [32] D. Meyer, R. J. Hogan, P. D. Dueben, and S. L. Mason, "Machine Learning Emulation of 3D Cloud Radiative Effects," *J Adv Model Earth Syst*, vol. 14, no. 3, Mar. 2022, doi: 10.1029/2021MS002550.
- [33] X. Zhou, W. Zhang, Z. Chen, S. Diao, and T. Zhang, "Efficient Neural Network Training via Forward and Backward Propagation Sparsification."
- [34] C. Bacour, F. Baret, D. Béal, M. Weiss, and K. Pavageau, "Neural network estimation of LAI, fAPAR, fCover and LAI×Cab, from top of canopy MERIS reflectance data: Principles and validation," *Remote Sens Environ*, vol. 105, no. 4, pp. 313–325, 2006, doi: <https://doi.org/10.1016/j.rse.2006.07.014>.
- [35] J. A. Smith, "LAI inversion using a back-propagation neural network trained with a multiple scattering model," *IEEE Trans. Geosci. Remote. Sens.*, vol. 31, pp. 1102–1106, 1993, [Online]. Available: <https://api.semanticscholar.org/CorpusID:21769398>
- [36] S. Gopal and C. Woodcock, "Remote Sensing of Forest Change using Artificial Neural Networks," 1996.
- [37] C. D. Sutton, "Classification and Regression Trees, Bagging, and Boosting," 2005, *Elsevier*. doi: 10.1016/S0169-7161(04)24011-1.

- [38] S. W. Norton, "Generating Better Decision Trees."
- [39] M. S. M. Alamgir, M. N. Sultana, and K. Chang, "Link Adaptation on an Underwater Communications Network Using Machine Learning Algorithms: Boosted Regression Tree Approach," *IEEE Access*, vol. 8, pp. 73957–73971, 2020, doi: 10.1109/ACCESS.2020.2981973.
- [40] "Classification And Regression Trees."
- [41] L. Breiman, "Random Forests," 2001.
- [42] J. A. Gamon, C. B. Field, D. A. Roberts, S. L. Ustin, and R. Valentini, "Functional Patterns in an Annual Grassland during an AVIRIS Overflight."
- [43] E. Adam, O. Mutanga, and D. Rugege, "Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review," *Wetl Ecol Manag*, vol. 18, no. 3, pp. 281–296, 2010, doi: 10.1007/s11273-009-9169-z.
- [44] F. Gao, J. Masek, M. Schwaller, and F. Hall, "On the blending of the landsat and MODIS surface reflectance: Predicting daily landsat surface reflectance," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, no. 8, pp. 2207–2218, Aug. 2006, doi: 10.1109/TGRS.2006.872081.
- [45] L. Martínez-Ferrer *et al.*, "Quantifying uncertainty in high resolution biophysical variable retrieval with machine learning," *Remote Sens Environ*, vol. 280, p. 113199, 2022, doi: <https://doi.org/10.1016/j.rse.2022.113199>.
- [46] H. Fang, F. Baret, S. Plummer, and G. Schaepman-Strub, "An Overview of Global Leaf Area Index (LAI): Methods, Products, Validation, and Applications," Sep. 01, 2019, *Blackwell Publishing Ltd*. doi: 10.1029/2018RG000608.
- [47] Z. Li *et al.*, "East Asian Study of Tropospheric Aerosols and their Impact on Regional Clouds, Precipitation, and Climate (EAST-AIRCPC)," Dec. 16, 2019, *Blackwell Publishing Ltd*. doi: 10.1029/2019JD030758.
- [48] D. Haboudane, J. R. Miller, E. Pattey, P. J. Zarco-Tejada, and I. B. Strachan, "Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture," *Remote Sens Environ*, vol. 90, no. 3, pp. 337–352, Apr. 2004, doi: 10.1016/j.rse.2003.12.013.
- [49] H. Jethva, O. Torres, and Y. Yoshida, "Accuracy assessment of MODIS land aerosol optical thickness algorithms using AERONET measurements over North America," *Atmos Meas Tech*, vol. 12, no. 8, pp. 4291–4307, 2019, doi: 10.5194/amt-12-4291-2019.
- [50] X. Xiao, B. Braswell, Q. Zhang, S. Boles, S. Frolking, and B. M. Iii, "Sensitivity of vegetation indices to atmospheric aerosols: continental-scale observations in Northern Asia." [Online]. Available: <http://lwf.ncdc.noaa>.
- [51] O. P. Hasekamp *et al.*, "Aerosol measurements by SPEXone on the NASA PACE mission: expected retrieval capabilities," *J Quant Spectrosc Radiat Transf*, vol. 227, pp. 170–184, Apr. 2019, doi: 10.1016/j.jqsrt.2019.02.006.
- [52] Y. Wang *et al.*, "Automatic detection of suspected sewage discharge from coastal outfalls based on Sentinel-2 imagery," *Science of The Total Environment*, vol. 853, p. 158374, 2022, doi: <https://doi.org/10.1016/j.scitotenv.2022.158374>.
- [53] W. T. Chen, A. Nenes, H. Liao, P. J. Adams, J. L. F. Li, and J. H. Seinfeld, "Global climate response to anthropogenic aerosol indirect effects: Present day and year 2100," *Journal of Geophysical Research Atmospheres*, vol. 115, no. 12, 2010, doi: 10.1029/2008JD011619.
- [54] T. Cui *et al.*, "Chemical Characterization of Isoprene- and Monoterpene-Derived Secondary Organic Aerosol Tracers in Remote Marine Aerosols over a Quarter Century," *ACS Earth Space Chem*, vol. 3, no. 6, pp. 935–946, Jun. 2019, doi: 10.1021/acsearthspacechem.9b00061.
- [55] O. Dubovik *et al.*, "Variability of Absorption and Optical Properties of Key Aerosol Types Observed in Worldwide Locations."
- [56] A. Bsaibes *et al.*, "Albedo and LAI estimates from FORMOSAT-2 data for crop monitoring," *Remote Sens Environ*, vol. 113, no. 4, pp. 716–729, Apr. 2009, doi: 10.1016/j.rse.2008.11.014.
- [57] H. Tan *et al.*, "An observational study of the hygroscopic properties of aerosols over the Pearl River Delta region," *Atmos Environ*, vol. 77, pp. 817–826, 2013, doi: <https://doi.org/10.1016/j.atmosenv.2013.05.049>.
- [58] H. Mao, J. Meng, F. Ji, Q. Zhang, and H. Fang, "Comparison of machine learning regression algorithms for cotton leaf area index retrieval using Sentinel-2 spectral bands," *Applied Sciences (Switzerland)*, vol. 9, no. 7, Apr. 2019, doi: 10.3390/app9071459.
- [59] B. Combal *et al.*, "Retrieval of canopy biophysical variables from bidirectional reflectance Using prior information to solve the ill-posed inverse problem." [Online]. Available: www.elsevier.com/locate/rse
- [60] M. Weiss and F. Baret, "Evaluation of Canopy Biophysical Variable Retrieval Performances from the Accumulation of Large Swath Satellite Data," *Remote Sens Environ*, vol. 70, no. 3, pp. 293–306, 1999, doi: [https://doi.org/10.1016/S0034-4257\(99\)00045-0](https://doi.org/10.1016/S0034-4257(99)00045-0).

- [61] A. M. Prasad and A. Liaw, "New machine learning tools for predictive vegetation mapping after climate change: Bagging and Random Forest perform better than regression tree analysis," 2004. [Online]. Available: <https://www.researchgate.net/publication/284410648>
- [62] A. Bannari, D. Morin, F. Bonn, and A. R. Huete, "A review of vegetation indices," *Remote Sensing Reviews*, vol. 13, no. 1–2, pp. 95–120, Aug. 1995, doi: 10.1080/02757259509532298.
- [63] F. Gao *et al.*, "Fusing Landsat and MODIS Data for Vegetation Monitoring," *IEEE Geosci Remote Sens Mag*, vol. 3, no. 3, pp. 47–60, 2015, doi: 10.1109/MGRS.2015.2434351.
- [64] J. Verrelst *et al.*, "Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties - A review," Oct. 01, 2015, *Elsevier B.V.* doi: 10.1016/j.isprsjprs.2015.05.005.
- [65] O. Kira, A. L. Nguy-Robertson, T. J. Arkebauer, and R. Linker, "Informative spectral bands for remote green LAI estimation in C3 and C4 crops," 2015.