



سنجش از دور

,

GIS ایران



سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

سال پانزدهم، شماره اول، بهار ۱۴۰۲
Vol.15, No. 1, Spring 2023

۸۵-۱۰۸

مقاله پژوهشی

تهیه نقشه شاخص سطح برگ گیاه نیشکر

با استفاده از معکوس سازی تصاویر ابرطیفی ماهواره PRISMA

محمد حاجب^۱، سعید حمزه^{۲*}، سید کاظم علوی پناه^۳، جوشم ورنزت^۴

۱. دانشجوی دکتری گروه سنجش از دور و GIS، دانشکده جغرافیا، دانشگاه تهران

۲. دانشیار گروه سنجش از دور و GIS، دانشکده جغرافیا، دانشگاه تهران

۳. استاد گروه سنجش از دور و GIS، دانشکده جغرافیا، دانشگاه تهران

۴. پژوهشگر ارشد آزمایشگاه مشاهدات زمینی، آزمایشگاه پردازش تصویر، دانشگاه والنسیا، اسپانیا

تاریخ پذیرش مقاله: ۱۴۰۱/۰۵/۲۲

تاریخ دریافت مقاله: ۱۴۰۱/۰۴/۰۷

چکیده

شاخص سطح برگ نقش مهمی در تبادل ماده و انرژی بین زمین و اتمسفر دارد. مانند سایر گیاهان، شاخص سطح برگ نیشکر معیار خوبی برای وضعیت سلامت و رشد این محصول است که به دلیل نقش آن در صنایع غذایی و انرژی، اهمیت اقتصادی بسیاری دارد. ماهواره PRISMA که در سال ۲۰۱۹ پرتاب شد، یکی از جدیدترین منابع داده‌های ابرطیفی را فراهم کرده است که به‌ویژه، در تهیه نقشه متغیرهای گیاهی کاربرد دارد. در پژوهش حاضر، نوع جدیدی از شبکه‌های عصبی مصنوعی، موسوم به شبکه عصبی تنظیم‌شده با روش بیزین (BRANN) که قانون بیز را برای غلبه بر مشکل بیش‌برازش شبکه‌های عصبی به‌کار می‌برد، استفاده می‌شود. مدل یادشده روی مجموعه‌ای داده، متشکل از طیف دریافت‌شده از طریق ماهواره PRISMA به‌منزله متغیر مستقل و مقادیر اندازه‌گیری شاخص سطح برگ نیشکر به‌منزله متغیر وابسته، اجرا شد. اندازه‌گیری‌های زمینی شاخص سطح برگ نیشکر در ۱۱۸ واحد نمونه‌برداری زمینی، روی مزارع کشت‌و صنعت نیشکر امیرکبیر در استان خوزستان و در هفت تاریخ متفاوت طی یک دوره رشد نیشکر در سال ۱۳۹۹، انجام شد. مقایسه عملکرد BRANN با یک روش متعارف شبکه عصبی، یعنی شبکه آموزش‌دیده با روش لونیبرگ-مارکوارت (LMANN) در بازیابی شاخص سطح برگ نیشکر از طیف PRISMA، حاکی از این است که RMSE بازیابی از $2/26 \text{ (m}^2/\text{m}^2)$ به‌روش LMANN به $0/67 \text{ (m}^2/\text{m}^2)$ با استفاده از روش BRANN کاهش یافته است. در این پژوهش، به‌منظور کاهش ابعاد داده نیز از تبدیل مؤلفه‌های اصلی استفاده شد. در بازیابی شاخص سطح برگ از بیست مؤلفه اصلی اول نیز RMSE از $1/41 \text{ (m}^2/\text{m}^2)$ با استفاده از روش LMANN به $0/71 \text{ (m}^2/\text{m}^2)$ طبق روش BRANN کاهش یافت. استفاده از مؤلفه‌های اصلی باعث کاهش چشمگیر زمان محاسباتی شد. با اجرای مدل آموزش‌دیده BRANN روی تصاویر PRISMA به‌صورت پیکسل‌به‌پیکسل، نقشه شاخص سطح برگ نیشکر تولید شد. ارزیابی این نقشه نشان داد که این نقشه تغییرات مکانی شاخص سطح برگ نیشکر را به‌خوبی نشان می‌دهد. نتایج این تحقیق بیانگر قابلیت بالای روش BRANN و تصاویر PRISMA برای بازیابی شاخص سطح برگ نیشکر است.

کلیدواژه‌ها: بازیابی پارامترهای گیاهی، شاخص سطح برگ، شبکه‌های عصبی مصنوعی، معکوس‌سازی، سنجش از دور ابرطیفی، نیشکر.

* نویسنده مکاتبه‌کننده: تهران، خیابان انقلاب، خیابان وصال شیرازی، نبش کوچه زرین کوب، صندوق پستی: ۴۶۶۵-۱۴۱۵۵، کدپستی: ۱۴۱۷۸۵۳۹۳۳

۱- مقدمه

به صورت یکی از عوامل تأثیرگذار استفاده می‌شود (Teruel et al., 1997).

کارایی سنجش از دور، به دلیل دید وسیع و قابلیت تکرارپذیری بالا، در بازیابی ویژگی‌های گیاهی در مقیاس‌های محلی و جهانی ثابت شده است (Sellers et al., 1996; Verstraete et al., 1997). روش‌های برآورد متغیرهای پوشش گیاهی از داده‌های سنجش از دور را می‌توان به دو دسته روش‌های فیزیک-مینا و تجربی-آماري تقسیم کرد (Baret & Buis, 2008). روش‌های فیزیک-مینا امکان تعمیم‌پذیری بیشتری دارند و به راحتی می‌توان آنها را در مورد شرایط متفاوت برداشت تصویر و انواع گیاهان، عملی کرد اما استفاده از آنها دشوار است و هنگام معکوس‌سازی آنها، مشکل بدطرح^۲ شدن اجتناب‌ناپذیر است (Combal et al., 2002; Darvishzadeh et al., 2008; Qu et al., 2008). علاوه بر این مهم‌ترین نقص روش‌های فیزیک-مینا این است که از طریق آنها فقط متغیرهای وضعیتی قابل بازیابی‌اند که ورودی‌های مدل انتقال تابش‌اند (Verrelst et al., 2015a; Verstraete et al., 1996). در مقابل، اگرچه روش‌های تجربی-آماري را فقط در منطقه‌ای می‌توان به کار برد که براساس داده‌های اندازه‌گیری شده میدانی آن جا کالیبره شده‌اند، استفاده از آنها آسان است (Atzberger, 2010). این روش‌ها اغلب به منزله مدل‌های معیار برای ارزیابی عملکرد روش‌های فیزیک-مینا در نظر گرفته می‌شوند (Kimes et al., 1998).

شبکه‌های عصبی مصنوعی یکی از شناخته‌شده‌ترین مدل‌های رگرسیون ناپارامتریک غیرخطی‌اند (Verrelst et al., 2015a) که در کاربردهای گوناگون سنجش از دور، از جمله بازیابی پارمترهای بیوفیزیکی/بیوشیمیایی گیاهان، استفاده شده‌اند. جدیدترین کاربردهای شبکه‌های عصبی مصنوعی بازیابی ویژگی‌های گوناگون

گیاهان موتور حیات کره زمین محسوب می‌شوند و آگاهی از ویژگی‌های بیوفیزیکی و بیوشیمیایی آنها، در درک بهتر عملکرد سیستم‌های زمین و مدل‌سازی تبادلات چرخه‌های انرژی، کربن، اکسیژن و آب بین زمین و اتمسفر، نقش مؤثری دارد (Sellers et al., 1997). پارمترهای گیاهی به درک فرایندهای اکوسیستم‌های کشاورزی، مانند تنش‌های آبی گیاهی و برآورد میزان محصول که در کشاورزی دقیق اهمیت فراوان دارند، نیز کمک می‌کنند (Atzberger, 2010). بنابراین تهیه نقشه پارمترهای گیاهی می‌تواند، در امنیت غذایی در سطح ملی و منطقه‌ای نقش مهمی ایفا کند (Dabrowska-Zielinska et al., 2002).

نیشکر گیاه علفی بلند چندساله‌ای از دسته ساکاروم^۱ است که در مناطق گرمسیری و نیمه‌گرمسیری کشت می‌شود و بیش از نیمی از تقاضای جهانی در زمینه شکر را تأمین می‌کند (Som-Ard et al., 2021). این گیاه همچنین در تهیه سوخت گیاهی اتانول کاربرد دارد (Sanches et al., 2019; Urgesa & Keyata, 2021). به علت نقشی که نیشکر در تأمین غذا و انرژی‌های تجدیدپذیر دارد، تقاضای جهانی برای آن در حال افزایش است؛ این مسئله مستلزم بهره‌گیری از روش‌های مؤثرتر در کشت این محصول اقتصادی است. یک راه افزایش بهره‌وری کشت این محصول برآورد و پایش پارمترهای بیوفیزیکی/بیوشیمیایی آن است که می‌توانند بیانگر وضعیت سلامت و رشد گیاه باشند. شاخص سطح برگ یک پارامتر ساختاری گیاه است که به صورت نسبت مجموع مساحت یک سمت برگ‌های سبز موجود در یک محدوده، به مساحت آن محدوده تعریف می‌شود (Watson, 1947). همانند سایر گونه‌های گیاهی، در مورد نیشکر نیز شاخص سطح برگ معیار بسیار خوبی برای رشد و عملکرد محصول است و تغییرات آن در طول چرخه زراعی، با استفاده از مدل‌های رشد نیشکر برای تخمین میزان رشد و محصول نهایی،

1. Saccharum
2. Ill-posed

متغیرهای مورد نظر به کار رفته است. در حوزه مطالعات پوشش گیاهی هم کومارستی^۵ و همکاران (۲۰۱۹) از روش BRANN برای شناسایی بیماری در برگ برنج استفاده کردند. در پژوهشی دیگر، پوساس^۶ و همکاران (۲۰۱۷) کارایی این روش را در مدل سازی وضعیت محتوای آب درخت انگور، با چندین روش یادگیری ماشین دیگر مقایسه کردند. نتایج حاکی از این است که روش BRANN جزء برترین روش های مورد مطالعه بوده است. به رغم کارایی بالای روش BRANN در زمینه های گوناگون، هنوز گزارشی از به کارگیری آن در زمینه برآورد پارامترهای گیاهی براساس داده های سنجش از دور مطرح نشده است (Verrelst et al., 2019).

ماهواره PRISMA که در سال ۲۰۱۹ پرتاب شد (Loizzo et al., 2019) یکی از جدیدترین منابع داده های ابرطیفی را فراهم کرده است. قابلیت تصاویر این ماهواره در بازیابی پارامترهای گوناگون گیاهی، در چند تحقیق، بررسی شده است. تاگلیابو^۷ و همکاران (۲۰۲۲) رویکردی ترکیبی، مبتنی بر مدل انتقال تابش PROSAIL-PRO و الگوریتم رگرسیون فرایند گوسی را به کار بردند تا چند متغیر گیاهی شامل محتوای نیتروژن، کلروفیل و آب در سطح برگ و تاج پوشش را از تصاویر ماهواره PRISMA بازیابی کنند. آنها ادعا کردند دقت و ثبات بالای نتایج تحقیقشان حاکی از قابلیت بالای تصاویر ابرطیفی فضایی در بازیابی متغیرهای گیاهی است. ورلست^۸ و همکاران (۲۰۲۱) از تصاویر ماهواره PRISMA برای تهیه نقشه محتوای نیتروژن تاج پوشش استفاده کردند. در این مقاله، به برتری استفاده از داده های ابرطیفی بر داده های

پوشش گیاهی معرفی شده است (Verrelst et al., 2019). فنگ^۱ و همکاران (۲۰۱۹) نیز، در مورد تحقیقاتی که در آنها از شبکه های عصبی مصنوعی برای بازیابی شاخص سطح برگ استفاده شده است، مروری جامع داشته اند. شبکه های عصبی مصنوعی، با وجود کاربرد فراوان در زمینه های گوناگون، دارای معایبی اند. نتایج این مدل ها به معماری شبکه به کار رفته بازمی گردد که بهینه سازی آن اغلب زمان بر است (Burden & Winkler, 2008) اما چالش اصلی، در استفاده از این مدل ها، مسئله بیش برآزش است (Kimes et al., 2000). مشکل بیش برآزش به ویژه زمانی رخ می دهد که تعداد متغیرهای مستقل زیاد (مانند آنچه در تصاویر ابرطیفی با آن مواجهیم) و تعداد نمونه ها کم باشد (کمتر از صد نمونه (Atzberger et al., 2003)). بیش برآزش قابلیت تعمیم پذیری مدل را به شدت کاهش می دهد؛ به ویژه زمانی که نمونه ها نویزی باشند (Feng et al., 2006; Wang et al., 2009). برای مقابله با این مشکل و افزایش تعمیم پذیری مدل، باید از روش های تنظیم بهره گرفته شود. برای این منظور، روش های تنظیم گوناگونی وجود دارند که دو نمونه از شناخته شده ترین آنها توقف زودهنگام^۳ (Yao et al., 2007) و تنظیم بیزین (MacKay, 1992) است. تحقیقات قبلی نشان داده اند که روش تنظیم بیزین، در بهبود تعمیم پذیری مدل، کارایی بیشتری در قیاس با روش توقف زودهنگام دارد (Okut, 2016).

با استفاده از رویکرد بیزین در تنظیم شبکه های عصبی مصنوعی، روش BRANN^۴ توسعه داده شد. در این روش، با استفاده از یک توزیع پیشین برای پارامترهای مدل (وزن ها و بایاس ها)، وزن های بزرگ جریمه می شوند تا مدلی نرم تر با تعمیم پذیری بیشتر حاصل شود (MacKay, 1992). این روش در موارد گوناگونی، از جمله مطالعات محیطی (Choudhury et al., 2012; Lwin et al., 2020; Ye et al., 2021) اقتصاد (Sariev & Germano, 2020; Yan et al., 2017) و جامعه شناسی (Kayri, 2016) برای تقریب

1. Fang
2. Regularization
3. Early stopping
4. Bayesian Regularized Artificial Neural Network
5. Kumar Sethy
6. Pôças
7. Tagliabue
8. Verrelst

نقشه شاخص سطح برگ تولید می‌شود. این نقشه رزیابی می‌شود تا مشخص شود چه میزان تغییرات مکانی شاخص سطح برگ را منعکس کرده است.

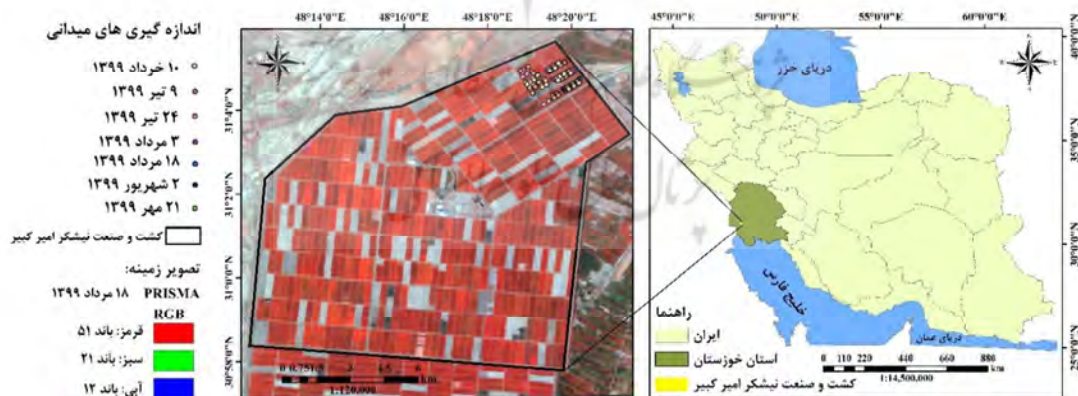
۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

مطالعه حاضر در مزارع نیشکر کشت و صنعت امیرکبیر، واقع در استان خوزستان، بین عرض‌های جغرافیایی $19^{\circ} 12' 48''$ تا $21^{\circ} 23' 48''$ و طول‌های جغرافیایی $21^{\circ} 58' 30''$ و $31^{\circ} 05' 37''$ انجام شده است. شکل ۱ موقعیت منطقه مورد مطالعه را نشان می‌دهد. مساحت کل کشت و صنعت امیرکبیر بالغ بر ۱۴۰۰۰ هکتار است که در ۱۰۰۰۰ هکتار آن، در سال ۱۳۹۹، داشت انجام شده است. بیشتر مزارع شکل یکسان و وسعت ۲۵ هکتار (۱۰۰۰ متر در ۲۵۰ متر) دارند و کشت نیشکر در آنها به صورت همگن انجام شده است. مزارع دارای سیستم آبیاری کم فشار، همراه با سیستم زهکشی زیرسطحی و زهکش‌های با فاصله ۴متر و عمق زهکشی ۱/۸ مترند. منطقه از نظر توپوگرافی هموار و

چندطیفی در رزیابی محتوای نیتروژن گیاه اشاره شده است. کاسا^۱ و همکاران (۲۰۲۰) قابلیت تصاویر دو ماهواره PRISMA و سنتینل-۲ را در رزیابی شاخص سطح برگ و محتوای کلروفیل گیاه، با استفاده از روش‌های یادگیری ماشین ارزیابی و مقایسه کردند. نتایج حاکی از کارایی بالاتر تصاویر ابرطیفی PRISMA در مقایسه با تصاویر چندطیفی سنتینل-۲؛ به‌ویژه در مورد رزیابی محتوای کلروفیل بود. لو^۳ و همکاران (۲۰۲۰) پیشرفت‌های اخیر را در زمینه کاربرد فتاوری تصویربرداری ابرطیفی در کشاورزی، مرور کرده‌اند.

با این مقدمه، هدف اصلی پژوهش حاضر برآورد مقدار شاخص سطح برگ گیاه نیشکر از داده‌های ابرطیفی ماهواره PRISMA، با استفاده از تکنیک شبکه‌های عصبی مصنوعی و در نهایت، تهیه نقشه تغییرات مکانی آن از طریق تصاویر ماهواره نام‌برده است. در این پژوهش، به منظور ارزیابی کمی نتایج، رویکردی کمتر استفاده شده در حوزه سنجش از دور به کار می‌رود؛ به نام بوت‌استرپینگ^۴ و بر مزایای آن تأکید می‌شود. با اجرای مدل کالیبره شده روی کل تصویر PRISMA،



شکل ۱. موقعیت منطقه مورد مطالعه

1. Casa
2. Sentinel-2
3. Lu
4. Bootstrapping

بافت خاک غالب آن رس لومی است که جزء خاک‌های سنگین دسته‌بندی می‌شود. از نظر اقلیمی، منطقه در کلاس نیمه‌خشک قرار دارد. بارش سالیانه آن حدود ۲۶۶ میلی‌متر است که بیشترین مقدار آن در دی ماه اتفاق می‌افتد. میانگین تبخیر و تعرق سالیانه منطقه حدود ۲۷۸۸ میلی‌متر در سال است که بیشترین مقدار آن در مرداد ماه صورت می‌پذیرد. گرمای هوا و رطوبت بالا، به‌علت نزدیک‌بودن به خلیج فارس، آب‌وهوای منطقه را برای کشت نیشکر مساعد ساخته است.

۲-۲- داده‌های مورد استفاده

۱-۲-۲- اندازه‌گیری‌های میدانی

اندازه‌گیری‌های میدانی شاخص سطح برگ، در ده تاریخ متفاوت، از ۲۶ اردیبهشت تا ۲۱ مهر ۱۳۹۹ انجام شد. این تاریخ‌ها با توجه به ویژگی‌های فنولوژی گیاه نیشکر در طول دوره رشد آن، یعنی اردیبهشت تا مهر، انتخاب شدند تا تغییرات شاخص سطح برگ نیشکر را به‌اندازه کافی نشان دهند. اندازه‌گیری شاخص سطح برگ به‌روش تخریبی انجام شد. برای این منظور، ابتدا واحدهای نمونه‌برداری به‌صورت پلات‌هایی به‌ابعاد ۳ متر در ۱/۸۳ متر انتخاب شدند. در هر واحد نمونه‌برداری، تعداد سه گیاه نیشکر به‌صورت نمونه،

برداشت شد. هم‌زمان با برداشت نمونه‌های گیاهی از مزارع، تعداد گیاهان نیشکر موجود در پلات نیز شمارش شد. پس از انتقال به آزمایشگاه، با اسکن برگ‌های گیاهان نمونه، مساحت همه برگ‌های آنها تعیین شد. سپس مقدار مساحت کل برگ‌های واحد نمونه‌برداری، با ضرب کردن مساحت برگ‌های گیاهان نمونه در تعداد گیاهان شمارش‌شده در پلات و تقسیم مقدار حاصل ضرب بر عدد ۳ (یعنی تعداد نمونه‌ها)، برآورد شد. در نهایت، مقدار شاخص سطح برگ واحد نمونه‌برداری، با تقسیم مساحت کل برگ‌ها بر مساحت پلات (۵/۴۹ مترمربع)، به‌دست آمد. در مجموع، شاخص سطح برگ نیشکر در ۱۷۹ واحد نمونه‌برداری به‌روش مذکور اندازه‌گیری شد. باوجوداین با توجه به اینکه در بازه زمانی اندازه‌گیری‌های میدانی، تصاویر ماهواره PRISMA صرفاً در هفت تاریخ (جدول ۱) برداشت شده‌اند، از ۱۷۹ نمونه مورد نظر فقط ۱۱۸ نمونه در این پژوهش به‌کار رفت. موقعیت مکانی نمونه‌ها و تاریخ برداشت آنها در شکل ۱ آورده شده است. جدول ۱ برخی اطلاعات آماری شامل میانگین، انحراف معیار و دامنه تغییرات (کمینه و بیشینه) مقادیر اندازه‌گیری‌شده زمینی شاخص سطح برگ نمونه‌های مورد استفاده را ارائه می‌دهد.

جدول ۱. اطلاعات آماری مقادیر اندازه‌گیری‌شده زمینی شاخص سطح برگ نمونه‌های مورد استفاده، به‌تفکیک تاریخ اندازه‌گیری

تاریخ تصویر	تاریخ اندازه‌گیری زمینی	تعداد نمونه	کمینه (m ² /m ²)	بیشینه (m ² /m ²)	میانگین (m ² /m ²)	انحراف معیار (m ² /m ²)
۱۳۹۹/۳/۱۶	۱۳۹۹/۳/۱۰	۲۴	۰/۳۸	۱/۷۹	۰/۸۹	۰/۳۳
۱۳۹۹/۴/۱۴	۱۳۹۹/۴/۹	۱۳	۰/۶۲	۱/۴۶	۰/۹۸	۰/۲۳
۱۳۹۹/۴/۲۰	۱۳۹۹/۴/۲۴	۳۱	۰/۵۷	۲/۳۱	۱/۳۸	۰/۳۸
۱۳۹۹/۵/۶	۱۳۹۹/۵/۳	۱۹	۰/۹۲	۴/۱۲	۱/۸۸	۰/۸۱
۱۳۹۹/۵/۱۸	۱۳۹۹/۵/۱۸	۸	۱/۳۰	۲/۴۷	۱/۹۷	۰/۴۰
۱۳۹۹/۵/۳۰	۱۳۹۹/۶/۲	۱۲	۱/۰۱	۲/۸۶	۱/۹۴	۰/۵۱
۱۳۹۹/۷/۲۶	۱۳۹۹/۷/۲۱	۱۱	۱/۱۸	۳/۹۴	۲/۴۸	۱/۰۰
	کل نمونه‌ها	۱۱۸	۰/۳۸	۴/۱۲	۱/۵۱	۰/۷۳

۲-۲-۲- تصاویر ماهواره‌ای

ماهواره PRISMA^۱ از سوی آژانس فضایی ایتالیا، در ۲۲ مارس ۲۰۱۹ به فضا پرتاب شد. این ماهواره در گروه ماهواره‌های دارای اندازه کوچک با وزن ۸۳۰ کیلوگرم قرار دارد و طول عمر عملیاتی آن پنج سال است. این ماهواره شامل سنجنده‌ای ابرطیفی است که می‌تواند تصاویر را در ۲۳۹ باند طیفی پیوسته و با قدرت تفکیک طیفی کمتر از ۱۲ نانومتر، در محدوده ۴۰۰ تا ۲۵۰۰ نانومتر برداشت کند. از این تعداد باند طیفی، ۶۶ باند در محدوده مرئی- مادون قرمز نزدیک (VNIR) و ۱۷۳ باند در محدوده طیف مادون قرمز موج کوتاه (SWIR) قرار دارند. البته نه باند در محدوده‌های VNIR و SWIR دارای هم‌پوشانی‌اند. ماهواره PRISMA، از نظر قدرت تفکیک مکانی، قادر به ثبت تصاویر با اندازه پیکسل سی متر و نیز دارای دوربینی پانکروماتیک، با قدرت تفکیک پنج متر است. مدت زمان بازدید مجدد PRISMA در دید نادیر، ۲۹ روز است که با مدیریت زاویه دید خارج از نادیر، می‌تواند حداکثر تا هفت روز کوتاه‌تر شود (Vangi et al., 2021). سنجنده ابرطیفی PRISMA از منشورهایی برای منعکس کردن رادیانس ورودی روی آرایه‌ای دوبعدی از آشکارسازها استفاده می‌کند و هندسه تصویربرداری آن از نوع هندسه خطی^۲ است (ASI, 2020). تصاویر PRISMA را می‌توان در تمامی طول‌های جغرافیایی و در عرض‌های بین ۷۰ درجه جنوبی تا ۷۰ درجه شمالی به دست آورد (Guarini et al., 2017). تصاویر، در حالت استاندارد، به صورت صحنه‌ای ۳۰ × ۳۰ کیلومتری و در حالت نواری، به صورت تصویر با عرض ۳۰ کیلومتر و طول حداکثر ۱۸۰۰ کیلومتر ارائه می‌شوند. این تصاویر در سه سطح پیش‌پردازش در اختیار قرار می‌گیرند. محصول سطح صفر (L0) حاوی داده‌های خام در فایل‌های باینری است که شامل داده‌های کمکی ماهواره، مانند درصد پوشش ابر می‌شود. محصول سطح یک (L1) تصویر رادیانس بالای اتمسفر را دربر می‌گیرد. محصول سطح دو (L2) به سه دسته تقسیم

می‌شود. سطح L2B شامل تصحیح اتمسفری و مکان‌یابی زمینی^۳ محصول L1 (رادیانس پایین اتمسفر) است. سطح L2C تصحیح اتمسفری و مکان‌یابی زمینی محصول L1 (بازتابندگی پایین اتمسفر، شامل ضخامت نوری آئروسول و نقشه بخار آب) را دربر می‌گیرد. سطح L2D دربرگیرنده تصویر اورتو محصول L2C (بازتاب پایین اتمسفر ژئوکدشده) است. محصولات سطح ۲ را می‌توان، با در دسترس بودن نقاط کنترل زمینی، زمین مرجع کرد (Guarini et al., 2017). تصاویر سطوح ۱ و ۲ بر حسب تقاضا تولید می‌شوند و در فرمت داده سلسله‌مراتبی نسخه ۵ (HDF5)^۴ انتشار می‌یابند. تصاویر PRISMA را می‌توان، پس از ثبت نام، به صورت رایگان از سایت <http://prisma-i.it/index.php/en/> دانلود کرد. مشخصات اصلی ماهواره PRISMA در جدول ۲ آورده شده است (ASI, 2020).

داده‌های ابرطیفی ماهواره PRISMA در قیاس با داده‌های سنجنده‌های چندطیفی، قابلیت بالایی در مطالعات گوناگون، به ویژه مطالعات گیاهی دارند. باین حال اغلب تحقیقات در این حوزه پژوهشی بر استفاده از تصاویر چندطیفی تمرکز داشته‌اند و تعداد تحقیقات انجام‌شده، با استفاده از داده‌های ابرطیفی، به صورت نسبی کمتر است؛ بنابراین ضرورت بهره‌گیری بیشتر و بهتر از تصاویر ماهواره‌های جدید، همچون PRISMA، بسیار احساس می‌شود.

تصاویر ماهواره‌ای مورد استفاده در مطالعه حاضر، برای بازیابی شاخص سطح برگ گیاه نیشکر و تهیه نقشه آن، شامل تصاویر سطح پردازش L2D ماهواره PRISMA است که به صورت هم‌زمان یا با فاصله کوتاهی از تاریخ‌های اندازه‌گیری‌های میدانی برداشت شده‌اند.

1. PRecursores IperSpettrale della Missione Applicativa
2. Pushbroom
3. Geolocation
4. Hierarchical Data Format-Earth Observing System (HDF-EOS5)

جدول ۲. مشخصات اصلی ماهواره PRISMA

ارتفاع مدار	۶۱۵ کیلومتر
نوار برداشت / میدان دید	۳۰ کیلومتر / ۲.۷۷ درجه
فاصله نمونه زمینی	ابر طیفی ۳۰ متر پانکروماتیک ۵ متر
محدوده طیفی	مرئی- مادون قرمز ۴۰۰ تا ۱۰۱۰ نانومتر (۶۶) مادون قرمز طول موج کوتاه ۹۲۰ تا ۲۵۰۰ نانومتر (۱۷۳) پانکروماتیک ۴۰۰ تا ۷۵۰ نانومتر
قدرت تفکیک طیفی	۱۲ نانومتر
نسبت سیگنال به نویز	مرئی- مادون قرمز بزرگتر از ۲۰۰:۱ مادون قرمز طول موج کوتاه بزرگتر از ۱۰۰:۱ پانکروماتیک بزرگتر از ۲۴۰:۱

منبع: ASI, 2020

آموزش می‌بیند. در نهایت، مدل آموزش دیده روی هریک از هفت تصویر PRISMA (تاریخ تصاویر در جدول ۱ آورده شده است) به صورت پیکسل به پیکسل اجرا شد تا هفت نقشه شاخص سطح برگ، در هریک از تاریخ‌های مورد نظر، تولید شود.

۳-۲- روش کار

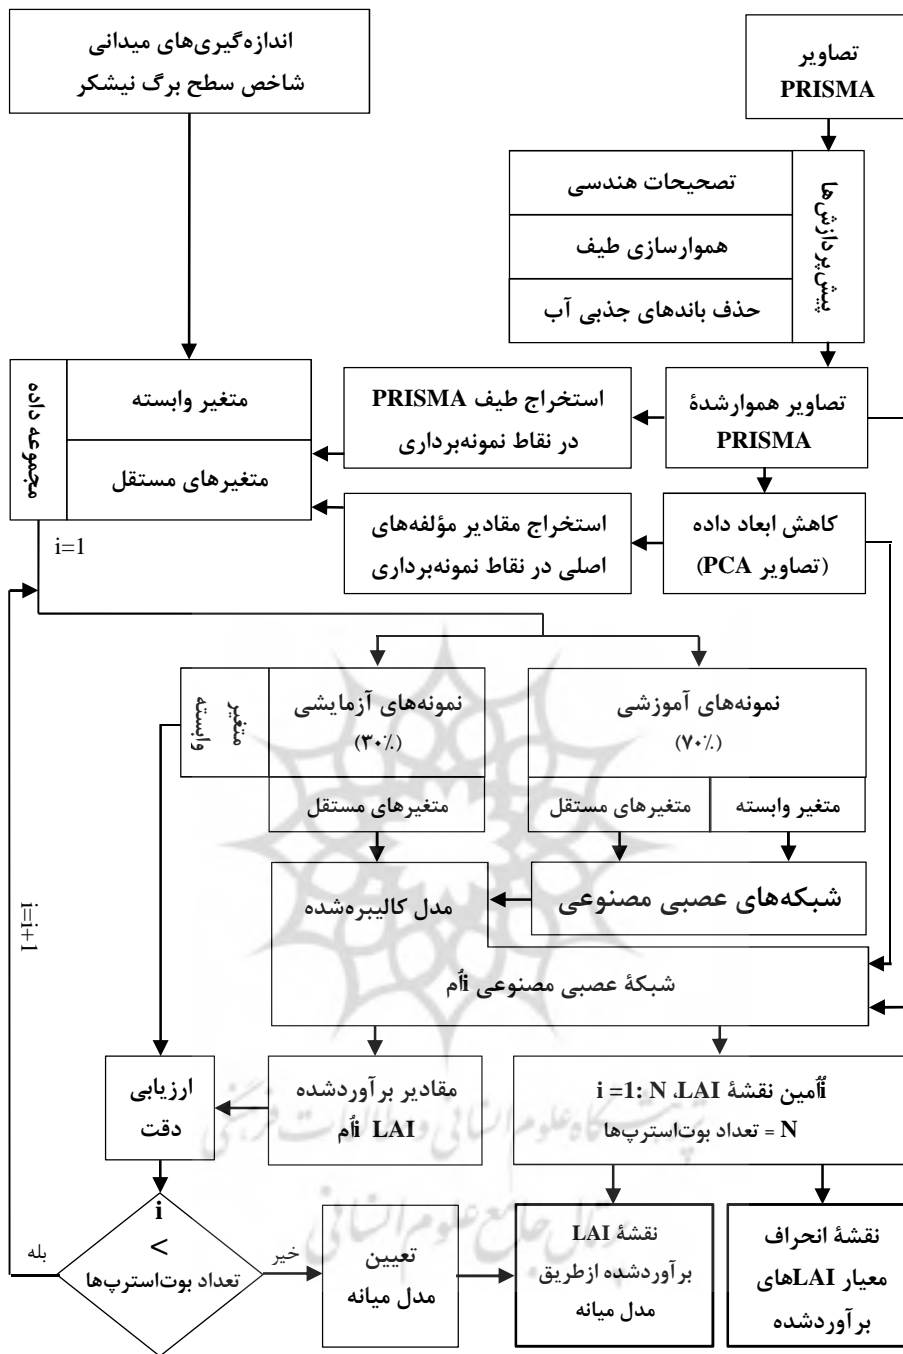
در این بخش، ابتدا توضیح مختصری در مورد روش BRANN داده می‌شود. شکل ۲ فلوجارت مراحل اجرای روش مورد استفاده برای بازیابی و تهیه نقشه شاخص سطح برگ نیشکر را نشان می‌دهد. مراحل گوناگون اجرای مدل به کاررفته برای این منظور، در زیربخش روش اجرای مدل بازیابی تشریح می‌شود. در این بخش، روش مورد استفاده با هدف ارزیابی دقت و صحت نتایج نیز توضیح داده خواهد شد.

۱-۳-۲- تنظیم شبکه عصبی مصنوعی با روش بیزین

در روش BRANN، سه مفهوم شبکه عصبی بازانتشار خطا^۱ (Rumelhart et al., 1986)، روش‌های تنظیم (Tikhonov, 1963) و رویکرد بیزین (Buntine, 1991) با هم ترکیب می‌شوند. در ادامه، هریک از این مفاهیم را به اختصار توضیح می‌دهیم.

1. Back Propagation ANN

به طور خلاصه، مجموعه داده مورد استفاده، در تحقیق حاضر، شامل مقادیر اندازه گیری شده زمینی شاخص سطح برگ نیشکر در ۱۱۸ نمونه زمینی و طیف ابرطیفی متناظر آنهاست که با استفاده از ماهواره PRISMA برداشت شده است. این ۱۱۸ نمونه زمینی در هفت تاریخ متفاوت، طی دوره رشد نیشکر، برداشت شدند تا دامنه متنوعی از مقادیر شاخص برگ در داده‌های آموزشی وجود داشته باشد. به ازای هریک از این هفت تاریخ اندازه گیری میدانی (جدول ۱)، یک تصویر PRISMA با فاصله زمانی اندک از آن تاریخ، یعنی در مجموع هفت تصویر که هریک کل منطقه مورد مطالعه را پوشش می‌دهد، دانلود شد. طیف ابرطیفی متناظر با هریک از ۱۱۸ نمونه یادشده در موقعیت مکانی آنها و با توجه به تاریخ برداشت نمونه، از تصویر متناظر با همان تاریخ استخراج شد. در فرایند معکوس سازی طیف PRISMA، به منظور بازیابی شاخص سطح برگ نیشکر، این مقادیر اندازه گیری شده زمینی شاخص سطح برگ به منزله متغیر وابسته و طیف PRISMA متناظر آنها به منزله متغیر مستقل، در فرایند آموزش مدل رگرسیونی مورد استفاده، به کار رفت. با توجه به تنوع مقادیر شاخص سطح برگ، مدل مورد استفاده براساس رابطه بین این مقادیر متنوع شاخص سطح برگ به منزله متغیر وابسته و طیف PRISMA متناظر آنها به منزله متغیر مستقل، به خوبی



شکل ۲. فلوچارت مراحل کار

از طریق انتشار روبه جلو و روبه عقب خطاها، انجام می‌دهد. در مرحله روبه جلو، وزن‌ها و بایاس‌های شبکه از لایه ورودی به سمت لایه خروجی به روز می‌شوند. در گام روبه عقب، وزن‌های بین‌نورونی از لایه خروجی به

پرسپترون چندلایه^۱، با الگوریتم یادگیری بازانتشار خطا، محبوب‌ترین و پرکاربردترین نمونه شبکه عصبی مصنوعی در بسیاری از کاربردهای عملی است. الگوریتم یادگیری بازانتشار خطا برای آموزش شبکه‌های عصبی، اصلاح وزن‌ها و به‌روزرسانی فعالیت‌های نورون‌ها را

1. Multi-Layer Perceptron

تشکیل می‌شود. برعکس، اگر نسبت کوچک‌تر شود، در آموزش شبکه برای برازش بیشتر مدل بر نمونه‌های آموزشی و کاهش خطا تلاش می‌شود (Dan Foresee & Hagan, 1997)؛ بنابراین یافتن مقادیر بهینه برای پارامترهای تنظیم، که بهترین توازن بین پیچیدگی مدل و خوبی برازش آن را به همراه دارد، چالشی مهم در عملی کردن روش‌های تنظیم است. برای حل مشکل بهینه‌سازی پارامترهای تنظیم، رویکرد تنظیم بیزی یکی از کارآمدترین روش‌هاست (MacKay, 1992).

در روش BRANN از تئوری بیز^۲ در قالب یک طرح تنظیم برای بهینه‌سازی پارامترهای تنظیم استفاده می‌شود. این کار به شیوه‌ای تکرارشونده و مبتنی بر احتمال که مک کی^۳ (۱۹۹۲) پیشنهاد داده است، انجام می‌شود. در این روش، یک توزیع احتمال پیشین مشخص برای وزن‌های مدل در نظر گرفته می‌شود. در این حالت، براساس قانون بیز، توزیع احتمال پسین وزن‌ها طبق رابطه (۲) تعیین می‌شود.

شواهد/احتمال پیشین × درست‌نمایی = احتمال پسین
رابطه (۲)

هدف انتخاب وزن‌هایی است که توزیع احتمال پسین وزن‌ها را بیشینه کنند. وزن‌ها، در هر تکرار، به روزرسانی می‌شود. مراحل تعیین مقادیر بهینه برای پارامترهای تنظیم، طبق روش BRANN، بدین شرح است:

گام نخست: اختصاص مقدار اولیه به α و β و وزن‌های مدل. معمولاً مقدار اولیه صفر برای α و مقدار اولیه ۱ برای β در نظر گرفته می‌شود. پس از اولین مرحله آموزش، پارامترهای تنظیم از این مقادیر اولیه بازیابی خواهد شد.

گام دوم: اجرای الگوریتم یادگیری لئونبرگ-مارکوآرت^۴ برای کمینه کردن تابع هزینه رابطه (۱) و محاسبه وزن‌های جدید.

لایه ورودی تغییر می‌کنند. هر رفت و برگشت یک اپوک^۱ نام دارد و در آن، یک خطا برای پیش‌بینی‌ها محاسبه می‌شود. در هر اپوک، وزن‌ها به روزرسانی می‌شوند و طی هر فرایند تکراری، مقدار خطای محاسبه شده در هر اپوک کاهش می‌یابد. این فرایند تا زمانی ادامه می‌یابد که یکی از معیارهای توقف برآورده شود. معیارهای توقف شامل حداکثر تعداد اپوک، همگراشدن خطا یا رسیدن به کمترین خطای مشخص شده است (Demuth & Beale, 2004). یکی از مشکلات اصلی این روش بیش‌برازش است که بدون به‌کارگیری روش‌های تنظیم، اجتناب‌ناپذیر است (Okut, 2016).

با اجرای روش تنظیم، پیش‌بینی‌ها به سمت مقادیری که احتمال بیشتری دارند متمایل می‌شوند؛ بدین ترتیب واریانس پیش‌بینی‌ها، به‌قیمت افزایش بایاس، کاهش می‌یابد و در نتیجه، شبکه پاسخی نرم‌تر با تعمیم‌پذیری بیشتر ایجاد می‌کند. برای این منظور، در روش تنظیم پارامترهای مدل (وزن‌ها و بایاس‌ها) برای کمینه کردن یک تابع هدف در نظر گرفته می‌شود. در روش‌های متعارف یادگیری، تابع هدف اغلب فقط به صورت جمع مربعات خطاها $F = E_D$ تعریف می‌شود ولی در روش‌های تنظیم شده، علاوه بر جمع مربع خطا، یک جمله اضافی نیز برای کاهش وزن‌ها (E_W) در نظر گرفته می‌شود که وزن‌های بزرگ را جریمه می‌کند. بدین صورت تابع هدف تنظیم شده به صورت ترکیبی خطی از جمله‌های مذکور تعریف می‌شود که مطابق رابطه (۱) نوشته می‌شود.

$$F(w) = \beta E_D(w) + \alpha E_W(w) \quad (1)$$

E_W به صورت جمع مربعات وزن‌های شبکه تعریف می‌شود. α و β پارامترهای تنظیم‌اند. نسبت α/β تأکید بر آموزش را مشخص و میزان مؤثر بودن پیچیدگی شبکه را کنترل می‌کند. هرچه این نسبت بزرگ‌تر باشد، در آموزش شبکه بر کاهش وزن‌ها، حتی به‌قیمت افزایش خطای شبکه، تأکید می‌شود؛ بنابراین شبکه‌ای هموارتر و در نتیجه، با تعمیم‌پذیری بیشتر

1. Epoch
2. Bayes' Theorem
3. MacKay
4. Levenberg-Marquardt

وجود دارد. مزید^۲ و همکاران (۲۰۲۲) نیز جابه‌جایی حداکثر تا پنج پیکسل را در تصاویر PRISMA مورد استفاده در تحقیق خود، گزارش کردند؛ بنابراین ابتدا یک مرحله تصحیح هندسی تصاویر PRISMA، با استفاده از نقشه‌های موجود از مزارع منطقه مورد مطالعه، انجام شد. از آن‌جاکه تصاویر سطح L2D به صورت بازتابندگی زمینی^۳ ارائه می‌شوند، پردازش اضافه‌تری برای تصحیحات اتمسفری انجام نشد. در ادامه، برخی باندها شامل باندهای دارای هم‌پوشانی بین محدوده‌های VNIR و SWIR و باندهای با نسبت سیگنال به نویز پایین حذف شدند. مقادیر بازتابندگی در باندهای حذف‌شده با استفاده از تابع درون‌یابی اسپلاین برآورد شد. سپس یک مرحله هموارسازی طیف، با استفاده از تابع هموارسازی اسپلاین^۴ به‌منظور کاهش نویزهای سیستمی که در طیف PRISMA مشاهده می‌شود، صورت پذیرفت. بدین ترتیب طیف هموارشده نهایی به‌دست آمد. توابع درون‌یابی و هموارسازی اسپلاین در نرم‌افزار MATLAB اجرا شدند. در هر دو مورد، اسپلاین به‌کاررفته از یک تابع چندجمله‌ای درجه سوم تکه‌ای^۵ استفاده می‌کند. در نهایت، باندهای جذبی بخار آب از طیف هموارشده حذف شدند. تمامی مراحل پیش‌پردازش بیان‌شده براساس روش پیشنهادی تاگلیابو (۲۰۲۲) انجام شدند. به‌منظور کاهش ابعاد داده، از روش تحلیل مؤلفه‌های اصلی (PCA) استفاده شد و بیست مؤلفه اول به‌منزله متغیر مستقل، به‌منظور ورود به مدل‌های شبکه عصبی مورد استفاده، در نظر گرفته شدند. تحقیقات متعددی نشان داده‌اند که بیست مؤلفه اول، برای رسیدن به دقت‌های بالا در برآورد شاخص سطح برگ

گام سوم: محاسبه تعداد بهینه وزن‌های مدل (γ) با استفاده از تقریب گاوس-نیوتن روی ماتریس هسین^۱ که در الگوریتم یادگیری لونیبرگ-مارکوارت در دسترس است. تعداد بهینه وزن‌های مدل، با استفاده از رابطه (۳)، این‌گونه محاسبه می‌شود:

$$\gamma = m - \alpha \text{Trace } H^{-1} \quad (3)$$

در این معادله، m تعداد کل وزن‌های مدل و H نیز ماتریس هسین است که به صورت رابطه (۴) تعریف می‌شود.

$$H = \nabla^2 F(w) \approx 2\beta J^T J + 2\alpha I_m \quad (4)$$

در معادله بالا، I_m ماتریس همانی با اندازه m است. J ماتریس ژاکوبی خطاهای مجموعه آموزشی و $\nabla^2(\cdot)$ بیانگر عملگر دیفرانسیلی لاپلاس است. علامت T ترانپوز ماتریس را نشان می‌دهد.

گام چهارم: محاسبه مقادیر جدید برای پارامترهای تنظیم، از طریق روابط (۵) و (۶).

$$\alpha = \frac{\gamma}{2E_w(w)} \quad (5)$$

$$\beta = \frac{N-\gamma}{2E_D(w)} \quad (6)$$

در این معادلات، N تعداد نمونه‌های آموزشی است. گام پنجم: تکرار گام‌های دوم تا چهارم، تا رسیدن به همگرایی.

برای خوانندگان علاقه‌مند به کسب اطلاعات بیشتر در مورد روش BRANN، مروری جامع بر این روش آورده شده است (Bishop, 1995; Mackay, 1995; Neal, 2012).

۲-۳-۲- روش اجرای مدل باز یابی

ابتدا برخی پیش‌پردازش‌ها در مورد تصاویر استاندارد سطح L2D ماهواره PRISMA انجام شد که در ادامه، توضیح داده می‌شوند. با وجود اینکه تصاویر PRISMA سطح L2D استفاده‌شده در این مطالعه بر مبنای دیتوم WGS-84 و با سیستم تصویر UTM، منطقه ۳۹ شمالی ژئوکدشده‌اند، هنگام مقایسه با نقشه مزارع مورد مطالعه که شرکت کشت و صنعت امیرکبیر آنها را نقشه‌برداری کرده است، همچنان در همه تصاویر جابه‌جایی اندکی

1. Hessian Matrix
1. Mzid
1. Ground Reflectance
1. Spline Smoothing
1. Piecewise Cubic Polynomial

که خروجی مدل، در این شرایط، در محدوده مشخص شده برای استانداردسازی (یعنی صفر تا یک) خواهد بود؛ بنابراین یک فرایند معکوس‌سازی، برای بازگرداندن مقادیر خروجی نرمال شده به مقادیر واقعی شاخص سطح برگ (LAI_{Real}) صورت گرفت. معکوس‌سازی مقادیر نرمال شده از طریق تابع وارون رابطه (۷)، طبق رابطه (۸)، انجام شد.

$$LAI_{Real} = \left[\left(\frac{LAI_{Normalized} - a_{min}}{a_{max} - a_{min}} \right) \times (LAI_{max} - LAI_{min}) \right] + LAI_{min} \quad \text{رابطه (۸)}$$

تعریف متغیرهای استفاده شده در رابطه (۸) مطابق رابطه (۷) است.

بهبودسازی معماری شبکه‌های عصبی مورد استفاده شامل تعداد لایه‌های پنهان و تعداد نورون‌های آنها با استفاده از روش سعی و خطا انجام شد. همچنین تابع فعال‌سازی تانژانت سیگموئید^۱ برای لایه‌های پنهان و تابع خطی برای لایه خروجی به کار رفت. در تحقیقات قبلی، نشان داده شد که شبکه‌ای، با این ترکیب از توابع فعال‌سازی، قادر است هر تابع پیوسته‌ای را به خوبی تقریب بزند (Demuth & Beale, 2004).

۳-۳-۲- روش و معیارهای ارزیابی صحت^۲ و دقت^۳ در پژوهش حاضر، از معیارهای RMSE و MBE^۴ (Richter et al., 2012) به‌منزله معیارهای آماری ارزیابی کیفیت نتایج استفاده شده است. این معیارها در قالب روش ارزیابی دقت بوت‌استرپینگ که در ادامه توضیح داده می‌شود، محاسبه و استفاده شدند. روش ارزیابی دقت بوت‌استرپینگ، درموردی که تعداد نمونه‌ها کم است (کمتر از صد نمونه) (Richter et al., 2012)، ارزیابی مورد اعتمادتری از نتایج را در قیاس با

از داده‌های ابرطیفی، کافی‌اند (Danner et al., 2021; De Grave et al., 2020; Rivera-Caicedo et al., 2021; Verrelst et al., 2017). برای بررسی بیشتر، طیف‌های هموارشده PRISMA، بدون کاهش ابعاد نیز به‌منزله متغیر مستقل با هدف بازیابی مستقیم شاخص سطح برگ از آنها، وارد مدل‌های شبکه عصبی مورد استفاده شدند.

از آن‌جا که متغیرهای ورودی (مستقل) و خروجی (وابسته) ماهیت فیزیکی متفاوت دارند و بنابراین دارای محدوده مقادیر گوناگون‌اند، نرمال‌سازی آنها می‌تواند به همگرایی بهتر مدل در مرحله یادگیری و افزایش پایداری عددی آن کمک کند (Bacour et al., 2006; Gianola et al., 2011)؛ بنابراین مقادیر متغیر وابسته، یعنی اندازه‌گیری‌های میدانی شاخص سطح برگ، در محدوده صفر تا یک نرمال شدند. مقدار نرمال‌شده شاخص سطح برگ ($LAI_{Normalized}$) با استفاده از رابطه‌ای خطی، به‌صورت رابطه (۷) محاسبه شد.

$$LAI_{Normalized} = \left[\frac{LAI - LAI_{min}}{LAI_{max} - LAI_{min}} \right] \times (a_{max} - a_{min}) + a_{min} \quad \text{رابطه (۷)}$$

در این معادله، LAI مقدار اندازه‌گیری‌شده شاخص سطح برگ و LAI_{min} و LAI_{max} به ترتیب کمینه و بیشینه مقادیر اندازه‌گیری‌شده شاخص سطح برگ است. a_{max} و a_{min} به ترتیب حد پایین و بالای محدوده نرمال‌سازی است. با توجه به اینکه در این تحقیق، نرمال‌سازی در محدوده صفر تا یک انجام شده است، a_{min} برابر صفر و a_{max} برابر با یک در نظر گرفته شدند.

درمورد متغیرهای مستقل، فرایند نرمال‌سازی فقط درمورد مؤلفه‌های اصلی انجام شد؛ بدین‌صورت که مقادیر آنها نیز در محدوده صفر تا یک نرمال شد. از آن‌جا که طیف‌های هموارشده PRISMA به‌صورت بازتابندگی‌اند و ذاتاً در محدوده صفر تا یک قرار دارند، فرایند نرمال‌سازی درمورد آنها انجام نشد. بدیهی است

1. Tangent Sigmoid
2. Accuracy
3. Precision
4. Mean Bias Error

میانگین دو مقدار وسط مشخص می‌شود و در واقع، ممکن است این مقدار مستقیماً از طریق هیچ‌یک از آنها تولید نشده باشد.

در تحقیق حاضر، جهت مقایسه نتایج روش‌های مورد استفاده، مقادیر RMSE‌های حاصل از آنها بر اساس یک آزمون آماری با هم مقایسه شدند. بدین منظور ابتدا، با استفاده از آزمون شاپیرو-ویلک^۴، نرمال بودن مقادیر RMSE بررسی شد. سپس در صورت نرمال بودن توزیع RMSE‌های هر دو روش مورد مقایسه، از آزمون پارامتریک t-test و در غیر این صورت، از آزمون ناپارامتریک ویلکاکسون^۵ برای مقایسه نتایج استفاده شد.

۴-۳-۲- تهیه نقشه شاخص سطح برگ نیشکر

پس از ارزیابی دقت و مشخص شدن اینکه کدام گروه از متغیرهای مستقل مورد بررسی (طیف هموارشده PRISMA یا مؤلفه‌های اصلی) نتایج بهتری داشته‌اند، از بین ۲۰۱ مدل شرکت‌کننده در تکرارهای بوت‌استرپ، مدلی که مقدار میانه معیار RMSE را ارائه کرده است روی کل تصویر متغیر مستقل مربوط بار دیگر اجرا شد تا شاخص سطح برگ نیشکر به صورت پیکسل‌به‌پیکسل برآورد شود و بدین ترتیب نقشه آن تولید شود.

۳- نتایج و بحث

در این بخش، نتایج مراحل گوناگون بازیابی و تهیه نقشه شاخص سطح برگ گیاه نیشکر مطرح می‌شود.

۱-۳- پیش‌پردازش تصاویر PRISMA

در مرحله پیش‌پردازش، ابتدا هشت باند دارای هم‌پوشانی بین محدوده‌های VNIR و SWIR، در محدوده طیفی ۹۳۰ تا ۹۹۸ نانومتر و هشتاد باند با

روش‌های رایج همچون ارزیابی متقابل چندمرتب‌ای^۱ یا کنارگذاشتن تکی^۲، به‌دست می‌دهد (Efron & Tibshirani, 1994). از مزایای به‌کارگیری این روش، می‌توان به این موارد اشاره کرد: (۱) این روش تخمینی بی‌طرفانه و با انحراف اندک از دقت نتایج به‌دست می‌دهد؛ (۲) با این روش می‌توان توزیع فراوانی معیارهای ارزیابی دقت را مشخص کرد که این توزیع می‌تواند، علاوه بر ارزیابی صحت (کارایی) مدل، برای ارزیابی دقت (پایداری) آن نیز به‌کار رود (Atzberger et al., 2003)؛ (۳) در این روش تمامی نقاط نمونه می‌توانند، در فرایند کالیبره کردن مدل، به‌کار روند (Richter et al., 2012). با توجه به مزایای بیان‌شده، به‌رغم اینکه تعداد نمونه‌های موجود در پژوهش حاضر بیشتر صد عدد است، به‌منظور بهره‌گیری از مزیت‌های رویکرد بوت‌استرپینگ از این روش برای ارزیابی دقت نتایج استفاده شد. برای این کار، داده‌های نمونه‌برداری زمینی به‌صورت تصادفی به دو زیرمجموعه، شامل یک مجموعه آموزشی متشکل از ۷۰٪ نمونه‌ها و یک مجموعه آزمایشی متشکل از ۳۰٪ نمونه‌ها، تقسیم شدند. مدل با استفاده از نمونه‌های آموزشی کالیبره شد و مدل کالیبره‌شده، با استفاده از نمونه‌های آزمایشی، ارزیابی شد. این فرایند به تعداد ۲۰۱ مرتبه تکرار شد؛ بدین ترتیب ۲۰۱ مقدار متفاوت، برای معیار ارزیابی دقت مورد استفاده، به‌دست آمد و مقدار میانه آنها، به‌منزله صحت نهایی نتایج که بیانگر کارایی مدل است، در نظر گرفته شد. انحراف معیار این مقادیر نیز به‌منزله دقت نهایی نتایج که بیانگر پایداری مدل است، در نظر گرفته شد. مبنای انتخاب عدد ۲۰۱، برای تعداد بوت‌استرپ‌ها، پیشنهاد استیربرگ^۳ و همکاران (۲۰۰۱) بوده که در آن، دوپست بوت‌استرپ پیشنهاد شده است. در این مطالعه، یک بوت‌استرپ بیشتر اضافه شد تا عددی فرد حاصل شود؛ با این هدف که مقدار میانه از طریق یکی از مدل‌های شرکت‌کننده در تکرارهای بوت‌استرپ تولید شده باشد. توجه داشته باشید که در صورت زوج بودن تعداد تکرارها، مقدار میانه به‌صورت

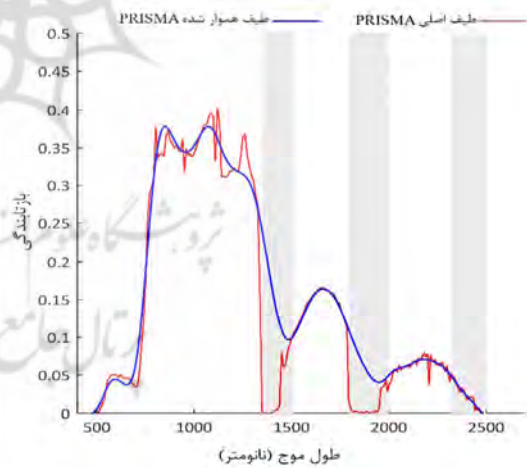
1. K-Fold Cross Validation
2. One-Leave-Out
3. Steyerberg
4. Shapiro-Wilk Test
5. Wilcoxon

معیارهای مذکور، حاصل از ۲۰۱ تکرار بوت‌استرپ، به‌منزله معیاری از صحت برآوردها و مقدار انحراف معیار آنها نیز به‌منزله معیاری از دقت آنها در نظر گرفته شدند. در نمودار شکل ۴، مقدار میانه RMSE حاصل از دو مدل شبکه عصبی به‌کاررفته، یعنی BRANN و LMANN، با هم مقایسه شده‌اند. در این نمودار، نتایج استفاده از ۱۷۰ باند هموارشده PRISMA بیست مؤلفه اصلی اول استخراج‌شده از آنها نیز با هم مقایسه شده است. نتایج مقایسه آماری عملکرد مدل‌های بازیابی، شامل مقادیر آماره z-statistic آزمون ویلکاکسون و p-value و سطح معنی‌داری آزمون برای هر یک از زوج مقایسه‌های مذکور، در جدول ۳ آورده شده است.

همان‌طور که در نمودار شکل ۴ مشاهده می‌شود، میزان RMSE بازیابی‌ها در حالت استفاده از باندهای هموارشده PRISMA از $2/26 (m^2/m^2)$ ، با استفاده از روش LMANN به $0/67 (m^2/m^2)$ ، با استفاده از روش BRANN، کاهش یافته؛ درحالی‌که هنگام استفاده از مؤلفه‌های اصلی، میزان RMSE بازیابی‌ها از $1/41 (m^2/m^2)$ ، با استفاده از روش LMANN، به $0/71 (m^2/m^2)$ ، با استفاده از روش BRANN کاهش یافته است. بنابراین می‌توان نتیجه گرفت که روش BRANN توانسته است، در هر دو حالت استفاده از همه باندهای هموارشده PRISMA و بیست مؤلفه اصلی اول به‌منزله ورودی مدل، نتایج بهتری را در بازیابی شاخص سطح برگ نیشکر به‌دست دهد. میزان بهبود نتایج بازیابی به‌ویژه هنگامی چشمگیرتر است که از همه ۱۷۰ باند هموارشده PRISMA در بازیابی استفاده شده باشد. این نکته به قابلیت تعمیم‌پذیری بیشتر روش BRANN، در مقایسه با روش LMANN و توانایی غلبه کردن آن بر مشکل بیش‌برازش، به‌ویژه هنگام مواجهه با تعداد بیشتر متغیر مستقل واردشده در مدل بازمی‌گردد.

نتیجه دیگر که می‌توان از نمودار شکل ۴ استنباط کرد، این است که در بازیابی به‌روش LMANN، استفاده از مؤلفه‌های اصلی نتایجی بهتر از کاربرد باندهای هموارشده PRISMA در پی داشته؛ درحالی‌که

نسبت سیگنال به نویز پایین در طول موج‌های ۵۳۵ تا ۵۵۰، ۷۵۵ تا ۷۸۰، ۸۱۰ تا ۸۵۵، ۸۸۵ تا ۹۷۰، ۱۰۱۵ تا ۱۰۵۰، ۱۰۸۰ تا ۱۱۶۵، ۱۲۲۵ تا ۱۲۸۵، ۱۳۳۰ تا ۱۴۹۰، ۱۶۸۵ تا ۱۷۰۰، ۱۷۲۵ تا ۱۷۵۰، ۱۷۸۰ تا ۱۹۶۰ و ۱۹۹۰ تا ۲۰۳۰ نانومتر حذف شدند. پس از درون‌یابی باندهای حذف‌شده و هموارسازی طیف با روش اسپلاین، طیف هموارشده به‌دست آمد. در نهایت، باندهای جذبی بخار آب شامل بیست باند، در طول موج‌های ۱۳۵۰ تا ۱۵۱۰ نانومتر، ۱۷۹۵ تا ۲۰۰۰ نانومتر و آخرین بخش محدوده SWIR بین طول موج‌های ۲۳۲۰ تا ۲۵۰۰ نیز حذف شدند و در مجموع، ۱۷۰ باند هموارشده به‌منزله متغیرهای مستقل وارد مدل بازیابی شدند. شکل ۳ نمونه‌ای از طیف PRISMA قبل و پس از هموارسازی را نشان می‌دهد. در این شکل، محدوده باندهای جذبی آب که حذف شده و در مدل بازیابی وارد نشده‌اند، به‌صورت ستون‌های خاکستری، نمایش داده شده‌اند.



شکل ۳. نمونه‌ای از نتیجه هموارسازی طیف دریافت‌شده از طریق PRISMA

۲-۳- بازیابی شاخص سطح برگ نیشکر

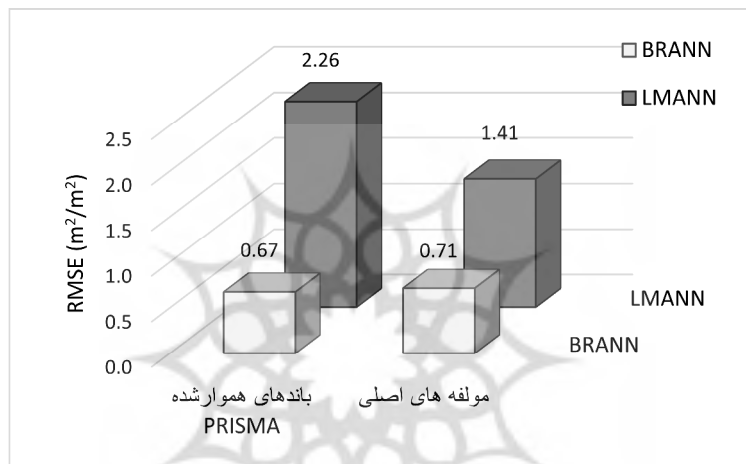
نتایج براساس مقایسه مقادیر بازیابی‌شده شاخص سطح برگ با مقادیر اندازه‌گیری‌شده زمینی و محاسبه معیارهای RMSE و MBE ارزیابی شد. مقدار میانه

جدول ۳. آزمون فرضیه‌های آماری برای مقایسه شبکه‌های عصبی LMANN و BRANN

مقایسه	z-statistic	p-value	میان RMSE I
مقایسه در مقابل LMANN	-۱۱/۶۸۳	$۱/۵۵۹ \times ۱۰^{-۳۱}$	BRANN : LMANN
مقایسه در مقابل BRANN	-۱۲/۲۹۳	$۹/۸۴۶ \times ۱۰^{-۳۵}$	۰/۷۱ : ۱/۴۱
مقایسه	z-statistic	p-value	میان RMSE
مقایسه در مقابل LMANN	-۴/۰۸۲	$۴/۴۶۴ \times ۱۰^{-۵}$	مؤلفه‌های اصلی: باندهای هموار شده
مقایسه در مقابل BRANN	-۳/۶۰۵	$۳/۱۲۳ \times ۱۰^{-۴}$	۲/۲۶ : ۱/۴۱
مقایسه در مقابل BRANN			۰/۷۱ : ۰/۶۷

*** بیانگر این است که مقایسه در $p < 0.0001$ معنی‌دار است

** بیانگر این است که مقایسه در $p < 0.001$ معنی‌دار است



شکل ۴. مقایسه مقادیر RMSE حاصل از روش‌های مورد استفاده برای بازیابی شاخص سطح برگ نیشکر

به‌دست آمده از نمونه‌های آزمایشی $۲/۲۶$ (m^2/m^2) است که مقدار مناسبی برای بازیابی شاخص سطح برگ نیست. اما RMSE به‌دست آمده از نمونه‌های آموزشی مقدار بسیار پایین $۴/۵۱ \times ۱۰^{-۸}$ (m^2/m^2) بوده است که به‌وضوح نشانه‌ای برای بیش‌برازش در نظر گرفته می‌شود. با کاهش تعداد متغیرهای مستقل، از ۱۷۰ باند هموار شده PRISMA به بیست مؤلفه اصلی اول و به‌دنبال آن، کاهش تعداد پارامترهای مدل، این مشکل تا حد زیادی کمتر شده؛ به طوری که RMSE حاصل از نمونه‌های آزمایشی به $۱/۴۱$ (m^2/m^2) کاهش یافته است. RMSE حاصل از نمونه‌های آموزشی، در این حالت، $۰/۵۳$ (m^2/m^2) بوده است. به این دلیل که روش BRANN، با جریمه کردن وزن‌های بزرگ و تعدیل تعداد پارامترهای مدل، از پیچیده شدن بیش‌از حد آن

در بازیابی با استفاده از روش BRANN، نتایج به‌کاربردن باندهای هموار شده PRISMA اندکی بهتر از نتایج به‌کارگیری مؤلفه‌های اصلی بوده است. در روش LMANN، وقتی متغیرهای مستقل بیشتری به‌صورت ورودی استفاده می‌شود، تعداد پارامترهای مدل (یعنی تعداد وزن‌ها و بایاس‌ها) افزایش می‌یابد. در این شرایط، بدون اعمال هیچ محدودیتی برای کاهش تعداد پارامترهای مدل، مدل به سمت بیش‌برازش سوق پیدا می‌کند که در نتیجه آن، تعمیم‌پذیری مدل کاهش می‌یابد. این باعث می‌شود که دقت بازیابی، در مورد نمونه‌های آموزشی، بسیار بالا ولی در مورد نمونه‌های آزمایشی، نامناسب باشد. همین وضعیت هنگام بازیابی با استفاده از ۱۷۰ باند هموار شده PRISMA از طریق روش LMANN رخ داده است. در این مورد، RMSE

با ورودی مؤلفه‌های اصلی، مقدار میانه RMSE کمتری را در قیاس با استفاده از باندهای هموارشده ارائه داده است، به دلیل نوسان بالا در برآوردها، نتایج آن چندان مورد اعتماد نیست.

به طور کلی می‌توان نتیجه گرفت روش BRANN که در تحقیق حاضر برای برآورد شاخص سطح برگ نیشکر پیشنهاد شده است، هم از نظر صحت و هم از نظر دقت بر روش متداول LMANN برتری دارد زیرا بازیابی‌هایی با خطای کمتر دربر داشته که اعتمادپذیری به آنها نیز بیشتر است.

در نمودار شکل ۵، زمان محاسباتی روش‌های مورد استفاده برای بازیابی شاخص سطح برگ نیشکر با هم مقایسه شده است. طبق این نمودار، استفاده از مؤلفه‌های اصلی به کاهش چشمگیر زمان محاسبات، به‌ویژه در مورد روش BRANN منجر شده است. این امر استفاده از مؤلفه‌های اصلی به جای همه باندهای در دسترس را به‌ویژه در پروژه‌های عملیاتی که زمان در آنها اهمیت بیشتری دارد، برجسته می‌کند. زمان‌های محاسباتی ارائه‌شده در نمودار شکل ۵ براساس اجرای مدل در نرم‌افزار MATLAB R2018b با استفاده از رایانه شخصی core i5-4460 3.20 GHz و حافظه داخلی ۸ گیگابایت محاسبه شده‌اند.


۳-۳- تهیه نقشه شاخص سطح برگ نیشکر

برای تهیه نقشه شاخص سطح برگ نیشکر در منطقه مورد مطالعه، مدل BRANN با ورودی ۱۷۰ باند هموارشده PRISMA که بهترین نتیجه را در مرحله قبل در پی داشته است، به کار رفت. برای این منظور، از بین ۲۰۱ مدل شرکت‌کننده در فرایند بوت‌استرپینگ، مدلی انتخاب شد که مقدار میانه RMSE را به دست داد. این مدل، به صورت پیکسل به پیکسل، روی تمامی تصاویر PRISMA دریافتی از منطقه مورد مطالعه اجرا شد. شکل ۶، به طور نمونه، نقشه حاصل متعلق به چهار تاریخ ۱۶ خرداد، ۲۰ تیر، ۱۸ مرداد و ۲۶ مهر ۱۳۹۹ را نمایش می‌دهد. مطابق این شکل، نقشه‌های شاخص

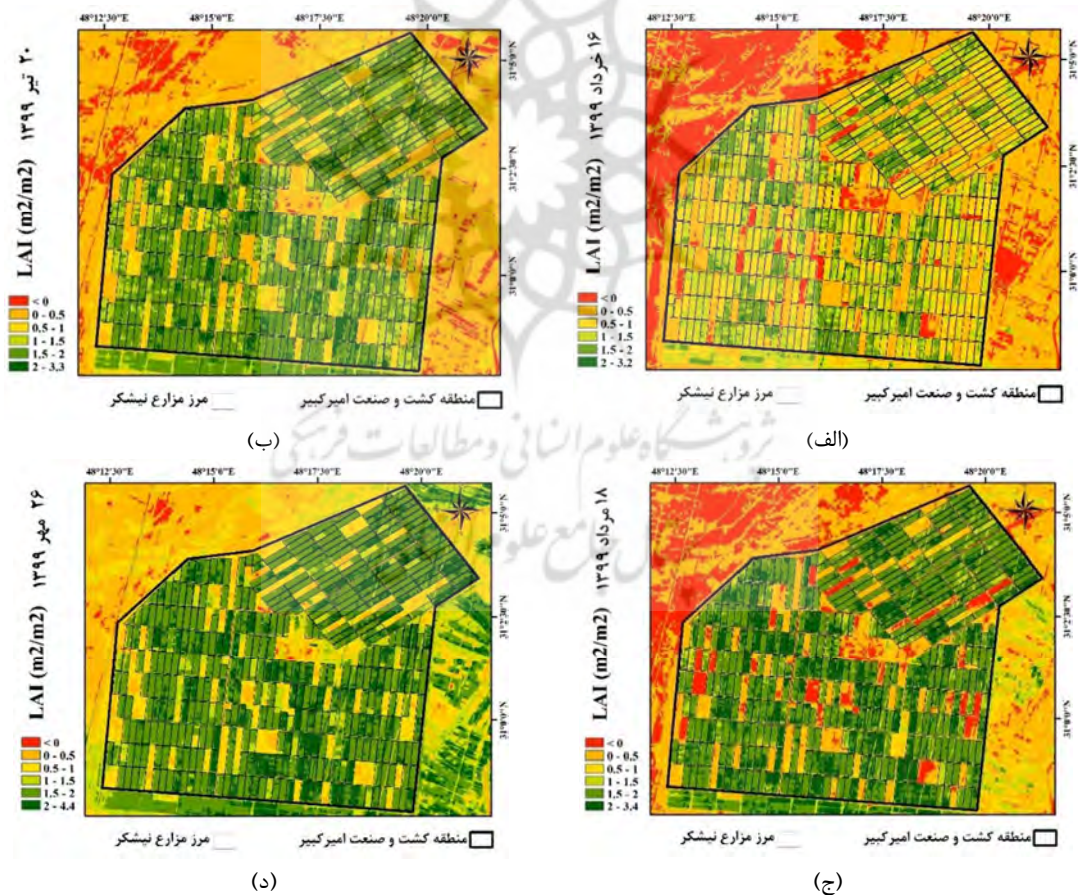
جلوگیری می‌کند، با به‌کارگیری این شیوه امکان استفاده از متغیرهای مستقل بیشتری به‌منزله ورودی، بدون ایجاد مشکل بیش‌برازش، فراهم می‌شود. در این حالت، استفاده از همه ۱۷۰ باند هموارشده PRISMA با RMSE $0.67 (m^2/m^2)$ به نتایج اندکی بهتر از حالت به‌کارگیری بیست مؤلفه اصلی اول، با RMSE $0.71 (m^2/m^2)$ منجر شده است. شایان ذکر است که RMSE حاصل از نمونه‌های آموزشی با استفاده از باند هموارشده PRISMA $0.58 (m^2/m^2)$ و به‌کارگیری بیست مؤلفه اصلی اول $0.70 (m^2/m^2)$ بوده است.

بررسی مقدار میانه معیار MBE نشان می‌دهد که مقدار این معیار در همه مدل‌های مورد بررسی، غیر از مدل LMANN هنگامی که از مؤلفه‌های اصلی به‌منزله ورودی برای بازیابی استفاده می‌کند، بسیار پایین است. این نشان می‌دهد که برآوردها به‌طور متوسط نه بیش‌برآورد و نه کم‌برآورد شده‌اند. مقدار میانه MBE برای مدل BRANN با ورودی باندهای هموارشده PRISMA $0.03 (m^2/m^2)$ و با ورودی مؤلفه‌های اصلی $0.01 (m^2/m^2)$ محاسبه شده است. این مقدار برای مدل LMANN با ورودی باندهای هموارشده PRISMA $0.08 (m^2/m^2)$ و با ورودی مؤلفه‌های اصلی $0.372 (m^2/m^2)$ بوده است.

از نظر دقت برآوردهای شاخص سطح برگ، RMSE نتایج حاصل از مدل BRANN انحراف معیار بسیار کمی دارند که نشان‌دهنده پایداری این مدل در بازیابی شاخص سطح برگ است. انحراف معیار RMSE بازیابی‌های مدل BRANN، هنگامی که از همه باندهای هموارشده PRISMA در بازیابی استفاده شده است، $0.10 (m^2/m^2)$ و هنگامی که از بیست مؤلفه اصلی استفاده شده، $0.09 (m^2/m^2)$ محاسبه شد. این در حالی است که انحراف معیار RMSE‌های نتایج مدل LMANN $1/61 (m^2/m^2)$ ، هنگام استفاده از همه باندهای هموارشده PRISMA و $99/65 (m^2/m^2)$ در شرایطی است که از بیست مؤلفه اصلی اول برای بازیابی استفاده می‌شود. بر این اساس، اگرچه مدل LMANN



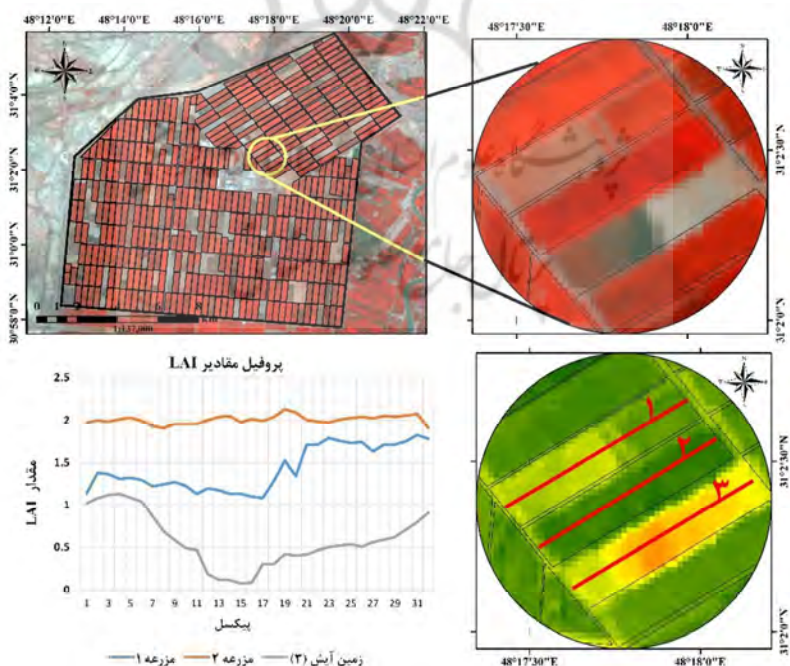
شکل ۵. مقایسه زمان محاسباتی روش های مورد استفاده برای بازیابی شاخص سطح برگ نیشکر



شکل ۶. نقشه شاخص سطح برگ نیشکر تولیدشده در تاریخ های ۱۶ خرداد (الف)؛ ۲۰ تیر ۱۳۹۹ (ب)؛ ۱۸ مرداد ۱۳۹۹ (ج)؛ ۲۶ مهر ۱۳۹۹ (د)

برگ مقادیر بالاتر از $2 \text{ (m}^2/\text{m}^2)$ را نشان می‌دهد. در مزرعه شماره ۳ که زیر کشت نیشکر قرار ندارد و به صورت آیش است، شاهد مقادیر پایین شاخص سطح برگ هستیم. همان‌طور که در پروفیل مزرعه شماره ۳ دیده می‌شود، در برخی بخش‌ها، مقدار شاخص برگ نزدیک به صفر برآورد شده است. میانگین مقادیر شاخص سطح برگ، در این پروفیل، $0.58 \text{ (m}^2/\text{m}^2)$ است. خارج از محدوده کشت و صنعت امیرکبیر و در بخش شرقی آن، برخی مزارع یا مناطق دارای پوشش گیاهی نسبتاً کم تراکم وجود دارند که الگوی تغییرات مکانی آنها در نقشه به خوبی مشاهده می‌شود. مقدار شاخص سطح برگ، در مورد این مناطق، به طرز معقولی کمتر از مزارع متراکم نیشکر برآورد شده است. در سمت شمال شرق تصویر، نواحی پوشیده با خاک و فاقد پوشش گیاهی وجود دارند که در مورد آنها، مقادیر شاخص سطح برگ نزدیک به صفر و حتی در برخی پیکسل‌ها، منفی برآورد شده است. در مجموع، می‌توان نتیجه گرفت نقشه شاخص سطح برگ تولید شده تغییرات مکانی این متغیر را در منطقه مورد مطالعه

سطح برگ تولید شده انطباق خوبی بر الگوی مکانی مزارع دارد. تغییرات درون هر یک از مزارع که ناشی از فعالیت‌های مدیریت کشت مانند آبیاری، کوددهی یا برداشت‌اند نیز به خوبی در نقشه انعکاس یافته‌اند. مزارع آیش به طور معقولی با مقادیر پایین شاخص سطح برگ مشخص و از سایر مزارع، تفکیک شده‌اند. شکل ۷، به صورت نمونه، پروفیل مقادیر شاخص سطح برگ برآورد شده از تصویر ۲۶ مهر ۱۳۹۹ را روی سه مزرعه با ویژگی‌های متفاوت، نشان می‌دهد. طبق این شکل با در نظر گرفتن تاریخ نقشه، یعنی اواخر مهر که دوره برداشت محصول آغاز می‌شود، در مزرعه شماره ۱، محصول تا تقریباً نیمه مزرعه برداشت شده است. این نکته در پروفیل برداشت شده از این مزرعه به خوبی منعکس شده است؛ به صورتی که شاهد مقادیر شاخص سطح برگ کمتر از $1/5 \text{ (m}^2/\text{m}^2)$ در بخش‌های برداشت شده هستیم. اما در بخشی که برداشت انجام نشده است، پروفیل شاخص سطح برگ مقادیر نزدیک به $2 \text{ (m}^2/\text{m}^2)$ را نشان می‌دهد. در مزرعه شماره ۲ که یک مزرعه متراکم نیشکر است، پروفیل شاخص سطح




شکل ۷. پروفیل مقادیر شاخص سطح برگ برآورد شده روی سه نمونه مزرعه. پروفیل‌های ۱ و ۲ روی مزارع نیشکر و پروفیل ۳ روی مزرعه‌ای آیش برداشت شده‌اند. تصویر PRISMA و نقشه شاخص برگ متناظر آن متعلق به تاریخ ۲۶ مهر ۱۳۹۹ است

قطعیت برآوردها در نظر گرفت. پیکسل‌هایی که مقدار انحراف معیار در آنها بالاست نشان می‌دهند مدل، در برآورد شاخص سطح برگ آنها با دشواری بیشتری مواجه بوده و بنابراین دامنه تغییرات، در مقادیر بازیابی شده، بیشتر است. این مسئله عدم قطعیت بیشتر در برآوردهای روش مورد استفاده را بیان می‌کند. شکل ۸، به‌طور نمونه، نقشه انحراف معیار تولیدشده متعلق به تاریخ ۲۱ مهر ۱۳۹۹ را نمایش می‌دهد. همان‌طور که در این شکل دیده می‌شود، مزارع زیرکشت نیشکر کمترین انحراف معیار را دارند؛ به این دلیل که مدل بازیابی‌کننده، در اساس، با استفاده از داده‌هایی آموزش دیده است که از مزارع نیشکر برداشت شده‌اند. مناطق پوشش گیاهی خارج از محدوده کشت و صنعت امیرکبیر نیز انحراف معیار اندکی دارند. این نکته پایداری روش مورد استفاده را در برآورد شاخص سطح برگ این نواحی می‌رساند. بیشترین مقادیر انحراف معیار در نواحی غیرپوشش گیاهی، همچون مزارع آیش و محدوده‌های پوشیده با خاک مشاهده می‌شود؛ به این دلیل که ویژگی‌های طیفی چنین مناطقی در داده‌های آموزشی مشخص نشده است.

به‌خوبی نمایش می‌دهد. با مقایسه مقادیر شاخص سطح برگ بازیابی شده در تاریخ‌های متفاوت، روند افزایشی این شاخص در طول دوره رشد نیشکر به‌وضوح مشاهده می‌شود. روند افزایشی شاخص سطح برگ، درمورد مزارع قرارگرفته در خارج از محدوده کشت و صنعت امیرکبیر در سمت شرق آن، نیز به چشم می‌خورد؛ بنابراین نتیجه گرفته می‌شود که نقشه‌های تولیدشده تغییرات زمانی شاخص سطح برگ را نیز به‌طور معقولی نمایش می‌دهند.

در این تحقیق، نقشه انحراف معیار برآوردهای شاخص سطح برگ نیز تولید شد. برای این کار، با اجرای تمامی ۲۰۱ مدل مشارکت‌کننده در فرایند بوت‌استرپینگ روی تصاویر PRISMA به‌صورت پیکسل‌به‌پیکسل، به همین تعداد نقشه شاخص سطح برگ تولید شد. بدین ترتیب برای هر پیکسل، ۲۰۱ برآورد در دست بود که با محاسبه انحراف معیار آنها، نقشه انحراف معیار برآوردهای شاخص سطح برگ تولید شد. اگرچه این نقشه هیچ ارزیابی کمی‌ای از کیفیت برآوردها ارائه نمی‌دهد، می‌توان آن را معیاری برای عدم



شکل ۸. نقشه انحراف معیار بازیابی‌های شاخص سطح برگ نیشکر در تاریخ ۲۶ مهر ۱۳۹۹

به دست می آید که قابلیت تعمیم پذیری بیشتری از شبکه‌های عصبی متعارف دارد.

از دیگر نتایج مطالعه حاضر این است که استفاده از بیست مؤلفه اصلی اول، به جای همه باندهای PRISMA، در زمان استفاده از روش LMANN برای بازیابی، منجر به بهبود نتایج شد؛ در صورتی که با استفاده از روش BRANN، هنگام به کارگیری باندهای اصلی PRISMA، نتایج بازیابی اندکی بهتر از نتایج به کارگیری مؤلفه‌های اصلی بوده است. با این حال استفاده از مؤلفه‌های اصلی به کاهش چشمگیر زمان محاسباتی هر دو مدل BRANN و LMANN منجر شده است. این نکته، در پروژه‌های عملیاتی که زمان در آنها اهمیت بیشتری دارد، بسیار مهم است.

نقشه شاخص سطح برگ که با اجرای مدل BRANN روی کل تصویر PRISMA به دست آمد، تغییرات مکانی و زمانی این متغیر را به خوبی نشان می‌دهد. همچنین ارزیابی نقشه انحراف معیار برآوردهای شاخص سطح برگ بیان می‌کند برآوردها در مناطق پوشش گیاهی، با داشتن انحراف معیار کمتر، اعتمادپذیری بیشتری دارند. برعکس در مناطق غیرپوشش گیاهی، انحراف معیار بالای برآوردها نشان‌دهنده عدم قطعیت بالا و اطمینان اندک به نتایج در این مناطق است.

از نقاط قوت پژوهش حاضر استفاده از روش ارزیابی دقت بوت‌استرپینگ است که امکانات منحصر به فردی را در ارزیابی نتایج، در اختیار کاربر قرار می‌دهد. با استفاده از این روش، علاوه بر ارزیابی کارایی مدل در رسیدن به نتایج صحیح، پایداری و ثبات مدل نیز ارزیابی می‌شود. به کارگیری این رویکرد ارزیابی دقت امکان مقایسه بین نتایج مدل‌های گوناگون بر اساس آزمونی آماری را فراهم می‌کند. امکان تولید نقشه انحراف معیار پیش‌بینی‌ها از متغیر (گیاهی) مورد نظر که می‌توان آن را معیاری برای عدم قطعیت برآوردها تفسیر کرد، مزیت دیگری است که با اجرای روش بوت‌استرپینگ، در اختیار کاربر قرار می‌گیرد؛ بنابراین،

نکته شایان ذکر، در این مورد، این است که اصولاً در نظر گرفتن مقدار یک متغیر گیاهی، مانند شاخص سطح برگ، برای نواحی غیرپوشش گیاهی کار معقولی نیست؛ با وجود این در تحقیق حاضر، مقادیر برآورده شده شاخص سطح برگ و نیز انحراف معیار برآوردها، علاوه بر مزارع نیشکر و مناطق پوشش گیاهی، در مناطق غیرپوشش گیاهی نیز بررسی شدند تا میزان منطقی بودن بازیابی‌ها مشخص شود. این کار در تحقیقات قبلی نیز انجام شده است (Rivera et al., 2014, Verrelst et al., 2013).

۴- نتیجه‌گیری

در این تحقیق، بازیابی و تهیه نقشه شاخص سطح برگ گیاه نیشکر، به منزله یکی از محصولات مهم در صنایع غذایی، با استفاده از تصاویر ابرطیفی ماهواره PRISMA و از طریق شبکه‌های عصبی مصنوعی انجام شد. شبکه‌های عصبی مصنوعی از جمله روش‌های یادگیری ماشین‌اند که به دلیل قابلیت بسیار در کشف روابط غیرخطی بین متغیرهای مستقل و وابسته، کاربرد فراوانی در زمینه‌های گوناگون دارند. با وجود این یکی از مشکلات اساسی آنها مشکل بیش‌برازش است که در قابلیت تعمیم‌پذیری مدل نیز تأثیر منفی می‌گذارد. در این مطالعه، روش BRANN برای بازیابی و تهیه نقشه شاخص سطح برگ به کار رفته است که در آن، برای غلبه بر مشکل بیش‌برازش و افزایش تعمیم‌پذیری مدل، از قضیه بیز استفاده می‌شود. به منظور ارزیابی قابلیت مدل BRANN در بازیابی شاخص سطح برگ، نتایج حاصل از آن با نتایج شبکه عصبی متداول LMANN، با به کارگیری یک آزمون آماری، مقایسه شد. نتیجه این مقایسه آماری بیان می‌کند مدل BRANN بر روش شبکه عصبی متعارف برتری داشته است. این برتری می‌تواند به آن دلیل باشد که در مدل BRANN، وزن‌های شبکه با مقادیر بزرگ حذف می‌شوند و در نتیجه، مدلی ساده‌تر و با مشکل بیش‌برازش کمتر

- Associated Problems**, Adv. L. Remote Sens. Syst. Model. Invers. Appl., PP. 173-201, https://doi.org/10.1007/978-1-4020-6450-0_7.
- Bishop, C.M., 1995, **Neural Networks for Pattern Recognition**, Oxford University Press.
- Buntine, W.L., 1991, **Bayesian Back-Propagation** 5.
- Burden, F. & Winkler, D., 2008, **Bayesian Regularization of Neural Networks**, Methods Mol. Biol., 458, PP. 25-44, https://doi.org/10.1007/978-1-60327-101-1_3.
- Casa, R., Upreti, D., Palombo, A., Pascucci, S., Yang, H., Yang, G., Huang, W. & Pignatti, S., 2020, **Evaluation and Exploitation of Retrieval Algorithms for Estimating Biophysical Crop Variables Using Sentinel-2, Venus and PRISMA Satellite Data**, J. Geod. Geoinf. Sci., 3, PP. 79-88, <https://doi.org/10.11947/j. JGGS.2020.0408>
- Choudhury, T.A., Hosseinzadeh, N. & Berndt, C.C., 2012, **Improving the Generalization Ability of an Artificial Neural Network in Predicting In-Flight Particle Characteristics of an Atmospheric Plasma Spray Process**, J. Therm. Spray Technol., 21, PP. 935-949, <https://doi.org/10.1007/s11666-012-9775-9>.
- Combal, B., Baret, F. & Weiss, M., 2002, **Improving Canopy Variables Estimation from Remote Sensing Data by Exploiting Ancillary Information, Case Study on Sugar Beet Canopies**, Agronomie, 22, PP. 205-215, <https://doi.org/10.1051/agro:2002008>.
- Dabrowska-Zielinska, K., Kogan, F., Ciolkosz, A., Gruszczynska, M. & Kowalik, W., 2002, **Modelling of crop Growth Conditions and Crop Yield in Poland Using AVHRR-Based Indices**, Int. J. Remote Sens., 23, PP. 1109-1123, <https://doi.org/10.1080/01431160110070744>.
- Dan Foresee, F. & Hagan, M.T., 1997, **Gauss-Newton Approximation to Bayesian Learning**, in: IEEE International Conference on Neural Networks - Conference Proceedings. PP. 1930-1935, <https://doi.org/10.1109/ICNN.1997.614194>.
- اگرچه روش بوتاسترپینگ کمتر از روش‌های کنارگذاشتن تکی و ارزیابی متقابل رواج دارد، با توجه به مزایای منحصر به فرد آن پیشنهاد می‌شود، در تحقیقات آتی، بیشتر به کار رود.
- به طور خلاصه، نتایج این تحقیق بیانگر قابلیت بالای شبکه عصبی BRANN و نیز تصاویر ابرطیفی ماهواره PRISMA در بازیابی و تهیه نقشه شاخص سطح برگ گیاه نیشکر است.
- ### ۵- تشکر و قدردانی
- از موسسه تحقیقات و آموزش توسعه نیشکر و صنایع جانبی خوزستان و نیز شرکت کشت و صنعت نیشکر امیرکبیر به دلیل در اختیار قرار دادن داده های اندازه گیری زمینی و نقشه های مزارع نیشکر منطقه مورد مطالعه، قدردانی می شود.
- ### ۶- منابع
- ASI, 2020, **PRISMA Product Specifications**, 1-262.
- Atzberger, C., 2010, **Inverting the PROSAIL Canopy Reflectance Model Using Neural Nets Trained on Streamlined Databases**, J. Spectr. Imaging, 1, P. a2, <https://doi.org/10.1255/jsi.2010.a2>.
- Atzberger, C., Jarmer, T., Schlerf, M., Kötz, B. & Werner, W., 2003, **Spectroradiometric Determination of Wheat Bio-Physical Variables: Comparison of Different Empirical-Statistical Approaches**, Remote Sens. Transitions, Proc. 23rd EARSeL Symp, Belgium 2-5.
- Bacour, C., Baret, F., Béal, D., Weiss, M. & Pavageau, K., 2006, **Neural Network Estimation of LAI, fAPAR, fCover and LAI×Cab, from Top of Canopy MERIS REFLECTANCE DATA: PRINCIPLES and Validation**, Remote Sens. Environ., 105, PP. 313-325, <https://doi.org/10.1016/j.rse.2006.07.014>.
- Baret, F. & Buis, S., 2008, **Estimating Canopy Characteristics from Remote Sensing Observations: Review of Methods and**

- Danner, M., Berger, K., Woche, M., Mauser, W. & Hank, T., 2021, **Efficient RTM-Based Training of Machine Learning Regression Algorithms to Quantify Biophysical & Biochemical Traits of Agricultural Crops**, ISPRS J. Photogramm. Remote Sens., 173, PP. 278-296, <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2021.01.017>.
- Darvishzadeh, R., Skidmore, A., Schlerf, M. & Atzberger, C., 2008, **Inversion of a Radiative Transfer Model for Estimating Vegetation LAI and Chlorophyll in a Heterogeneous Grassland**, Remote Sensing of Environment, 112(5), PP. 2592-2604, <https://doi.org/10.1016/j.rse.2007.12.003>.
- De Grave, C., Verrelst, J., Morcillo-Pallarés, P., Pipia, L., Rivera-Caicedo, J.P., Amin, E., Belda, S. & Moreno, J., 2020, **Quantifying Vegetation Biophysical Variables from the Sentinel-3/FLEX Tandem Mission: Evaluation of the Synergy of OLCI and FLORIS Data Sources**, Remote Sens. Environ., 251, P. 112101, <https://doi.org/10.1016/j.rse.2020.112101>.
- Demuth, H. & Beale, M., 2004, **Neural Network Toolbox - For Use with MATLAB**, Matlab.
- Efron, B. & Tibshirani, R.J., 1994, **An Introduction to the Bootstrap**, CRC press.
- Fang, H., Baret, F., Plummer, S. & Schaepman-Strub, G., 2019, **An Overview of Global Leaf Area Index (LAI): Methods, Products, Validation, and Applications**, Rev. Geophys., 57, PP. 739-799, <https://doi.org/10.1029/2018RG000608>.
- Feng, N., Wang, F. & Qiu, Y., 2006, **Novel Approach for Promoting the Generalization Ability of Neural Networks**, Int. J. Signal Process, 2.
- Gianola, D., Okut, H., Weigel, K.A. & Rosa, G.J., 2011, **Predicting Complex Quantitative Traits with Bayesian Neural Networks: A Case Study with Jersey Cows and Wheat**, BMC Genet., 12, P. 87, <https://doi.org/10.1186/1471-2156-12-87>.
- Guarini, R., Loizzo, R., Longo, F., Mari, S., Scopa, T. & Varacalli, G., 2017, **Overview of the Prisma Space and Ground Segment and Its Hyperspectral Products**, in: International Geoscience and Remote Sensing Symposium (IGARSS), PP. 431-434, <https://doi.org/10.1109/IGARSS.2017.8126986>.
- Kayri, M., 2016, **Predictive Abilities of Bayesian Regularization and Levenberg-Marquardt Algorithms in Artificial Neural Networks: A Comparative Empirical Study on Social Data**, Math. Comput. Appl., 21, P. 20, <https://doi.org/10.3390/mca21020020>.
- Kimes, D.S., Nelson, R.F., Manry, M.T. & Fung, A.K., 1998, **Attributes of Neural Networks for Extracting Continuous Vegetation Variables from Optical and Radar Measurements**, Int. J. Remote Sens., 19, PP. 2639-2663, <https://doi.org/10.1080/014311698214433>.
- Kimes, D.S., Knyazikhin, Y., Privette, J.L., Abuelgasim, A.A. & Gao, F., 2000, **Inversion Methods for physically-Based Models**, Remote Sens. Rev., 18, PP. 381-439, <https://doi.org/10.1080/02757250009532396>.
- Kumar Sathy, P., Kanta Barpanda, N., Rath, A., Sathy, P.K., Patel, K. & Rath, A.K., 2019, **BRANN Model for Identification of Rice Leaf Diseases Using Texture Feature**, JETIR, 6(5), PP. 569-573.
- Loizzo, R., Daraio, M., Guarini, R., Longo, F., Lorusso, R., D'Ini, L. & Lopinto, E., 2019, **Prisma Mission Status and Perspective**, in: International Geoscience and Remote Sensing Symposium (IGARSS), PP. 4503-4506, <https://doi.org/10.1109/IGARSS.2019.8899272>.
- Lu, B., Dao, P.D., Liu, J., He, Y. & Shang, J., 2020, **Recent Advances of Hyperspectral Imaging Technology and Applications in Agriculture**, Remote Sens., 12, P. 2659, <https://doi.org/10.3390/RS12162659>.
- Lwin, A., Yang, D. & Hong, X., 2020, **Leveraging Bayesian Deep Learning for Spaceborne GNSS-R Retrieval on Global Soil**

- Moisture**, 2020 Int. Conf. Artif. Intell. Inf. Commun. ICAIIC 2020, PP. 352-355, <https://doi.org/10.1109/ICAIIC48513.2020.9065053>.
- MacKay, D.J.C., 1992, **Bayesian Interpolation**, Neural Comput., 4, PP. 415-447, <https://doi.org/10.1162/neco.1992.4.3.415>.
- MacKay, D.J.C., 1995, **Probable Networks and Plausible Predictions — A Review of Practical Bayesian Methods for Supervised Neural Networks**, Netw. Comput. Neural Syst., 6, PP. 469-505, https://doi.org/10.1088/0954-898X_6_3_011.
- Mzid, N., Castaldi, F., Tolomio, M., Pascucci, S., Casa, R. & Pignatti, S., 2022, **Evaluation of Agricultural Bare Soil Properties Retrieval from Landsat 8, Sentinel-2 and PRISMA Satellite Data**, Remote Sens., 14, P. 714, <https://doi.org/10.3390/rs14030714>.
- Neal, R.M., 2012, **Bayesian Learning for Neural Networks**, Springer Science & Business Media.
- Okut, H., 2016, **Bayesian Regularized Neural Networks for Small n Big p Data, Artificial Neural Networks - Models and Applications**, IntechOpen, <https://doi.org/10.5772/63256>.
- Pôças, I., Gonçalves, J., Costa, P.M., Gonçalves, I., Pereira, L.S. & Cunha, M., 2017, **Hyperspectral-Based Predictive Modelling of Grapevine Water Status in the Portuguese Douro Wine Region**, Int. J. Appl. Earth Obs. Geoinf., 58, PP. 177-190, <https://doi.org/https://doi.org/10.1016/j.jag.2017.02.013>.
- Qu, Y., Wang, J., Wan, H., Li, X. & Zhou, G., 2008, **A Bayesian Network Algorithm for Retrieving the Characterization of Land Surface Vegetation**, Remote Sens. Environ., 112, PP. 613-622, <https://doi.org/https://doi.org/10.1016/j.rse.2007.03.031>.
- Richter, K., Atzberger, C., Hank, T.B. & Mauser, W., 2012, **Derivation of Biophysical Variables from Earth Observation Data: Validation and Statistical Measures**, J. Appl. Remote Sens., 6, PP. 063557-1, <https://doi.org/10.1117/1.jrs.6.063557>.
- Rivera-Caicedo, J.P., Verrelst, J., Leonenko, G. & Moreno, J., 2013, **Multiple Cost Functions and Regularization Options for Improved Retrieval of Leaf Chlorophyll Content and LAI through Inversion of the PROSAIL Model**, Remote Sens., 5, PP. 3280-3304.
- Rivera-Caicedo, J.P., Verrelst, J., Muñoz-Marí, J., Camps-Valls, G. & Moreno, J., 2017, **Hyperspectral Dimensionality Reduction for Biophysical Variable Statistical Retrieval**, ISPRS J. Photogramm. Remote Sens., 132, PP. 88-101, <https://doi.org/10.1016/j.isprsjprs.2017.08.012>.
- Rumelhart, D.E., Hinton, G.E. & Williams, R.J., 1986, **Learning Representations by Back-Propagating Errors**, Nature, 323, PP. 533-536, <https://doi.org/10.1038/323533a0>.
- Sanches, G.M., Graziano Magalhães, P.S. & Junqueira Franco, H.C., 2019, **Site-Specific Assessment of Spatial and Temporal Variability of Sugarcane Yield Related to Soil Attributes**, Geoderma, 334, PP. 90-98, <https://doi.org/https://doi.org/10.1016/j.geoderma.2018.07.051>.
- Sariev, E. & Germano, G., 2020, **Bayesian Regularized Artificial Neural Networks for the Estimation of the Probability of Default**, Quant. Financ., 20, PP. 311-328, <https://doi.org/10.1080/14697688.2019.1633014>.
- Sellers, P.J., Dickinson, R.E., Randall, D.A., Betts, A.K., Hall, F.G., Berry, J.A., Collatz, G.J., Denning, A.S., Mooney, H.A., Nobre, C.A., Sato, N., Field, C.B. & Henderson-Sellers, A., 1997, **Modeling the Exchanges of Energy, Water, and Carbon between Continents and the Atmosphere**, Science (80-.), 275, PP. 502-509, <https://doi.org/10.1126/science.275.5299.502>.
- Som-Ard, J., Atzberger, C., Izquierdo-Verdiguier, E., Vuolo, F., Immitzer, M., 2021, **Remote Sensing Applications in Sugarcane Cultivation: A Review**, Remote Sens., <https://doi.org/10.3390/rs13204040>.
- Steyerberg, E.W., Harrell, F.E.J., Borsboom, G.J., Eijkemans, M.J., Vergouwe, Y. &

- Habbema, J.D., 2001, **Internal Validation of Predictive Models: Efficiency of Some Procedures for Logistic Regression Analysis**, J. Clin. Epidemiol., 54, PP. 774-781, [https://doi.org/10.1016/s0895-4356\(01\)00341-9](https://doi.org/10.1016/s0895-4356(01)00341-9).
- Tagliabue, G., Boschetti, M., Bramati, G., Candiani, G., Colombo, R., Nutini, F., Pompilio, L., Rivera-Caicedo, J.P., Rossi, M., Rossini, M., Verrelst, J. & Panigada, C., 2022, **Hybrid Retrieval of Crop Traits from Multi-Temporal PRISMA Hyperspectral Imagery**, ISPRS J. Photogramm. Remote Sens., 187, PP. 362-377, <https://doi.org/10.1016/j.isprsjprs.2022.03.014>.
- Teruel, D.A., Barbieri, V., & Ferraro Jr., L.A., 1997, **Sugarcane Leaf Area Index Modeling under Different Soil Water Conditions**, Sci. Agric., 54, PP. 39-44, <https://doi.org/10.1590/s0103-90161997000300008>.
- Tikhonov, A.N., 1963, **On the Solution of Ill-Posed Problems and the Method of Regularization**, in: Doklady Akademii Nauk, Russian Academy of Sciences, PP. 501-504.
- Urgesa, G.D. & Keyata, E.O., 2021, **Effect of Harvesting Ages on Yield and Yield Components of Sugar Cane Varieties Cultivated at Finchaa Sugar Factory, Oromia, Ethiopia**, Int. J. Food Sci., 2021, PP. 1-6, <https://doi.org/10.1155/2021/2702095>.
- Vangi, E., D'amico, G., Francini, S., Giannetti, F., Lasserre, B., Marchetti, M. & Chirici, G., 2021, **The New Hyperspectral Satellite Prisma: Imagery for Forest Types Discrimination**, Sensors (Switzerland), 21(4), P. 1182, <https://doi.org/10.3390/s21041182>.
- Verrelst, J., Rivera, J.P., Leonenko, G., Alonso, L. & Moreno, J., 2014, **Optimizing LUT-Based RTM Inversion for Semiautomatic Mapping of Crop Biophysical Parameters from Sentinel-2 and -3 Data: Role of Cost Functions**, IEEE Trans. Geosci. Remote Sens., 52, PP. 257-269, <https://doi.org/10.1109/TGRS.2013.2238242>.
- Verrelst, J., Camps-valls, G., Muñoz-mari, J., Pablo, J., Veroustraete, F., Clevers, J.G.P.W. & Moreno, J., 2015a, **ISPRS Journal of Photogrammetry and Remote Sensing Optical Remote Sensing and the Retrieval of Terrestrial Vegetation Bio-Geophysical Properties – A Review**, ISPRS J. Photogramm. Remote Sens., 108, PP. 273-290, <https://doi.org/10.1016/j.isprsjprs.2015.05.005>.
- Verrelst, J., Rivera, J.P., Veroustraete, F., Muñoz-Mari, J., Clevers, J.G.P.W., Camps-Valls, G. & Moreno, J., 2015b, **Experimental Sentinel-2 LAI Estimation Using Parametric, Non-Parametric and Physical Retrieval Methods – A Comparison**, ISPRS J. Photogramm. Remote Sens., 108, PP. 260-272, <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2015.04.013>.
- Verrelst, J., Malenovský, Z., Van der Tol, C., Camps-Valls, G., Gastellu-Etchegorry, J.-P., Lewis, P., North, P. & Moreno, J., 2019, **Quantifying Vegetation Biophysical Variables from Imaging Spectroscopy Data: A Review on Retrieval Methods**, Surv. Geophys., 40, PP. 589-629, <https://doi.org/10.1007/s10712-018-9478-y>.
- Verrelst, J., Rivera-Caicedo, J.P., Reyes-Muñoz, P., Morata, M., Amin, E., Tagliabue, G., Panigada, C., Hank, T. & Berger, K., 2021, **Mapping Landscape Canopy Nitrogen Content from Space Using PRISMA Data**, ISPRS J. Photogramm. Remote Sens., 178, PP. 382-395, <https://doi.org/10.1016/j.isprsjprs.2021.06.017>.
- Verstraete, M.M., Pinty, B. & Myneni, R.B., 1996, **Potential and Limitations of Information Extraction on the Terrestrial Biosphere from Satellite Remote Sensing**, Remote Sens. Environ., 58, PP. 201-214, [https://doi.org/https://doi.org/10.1016/S0034-4257\(96\)00069-7](https://doi.org/https://doi.org/10.1016/S0034-4257(96)00069-7).
- Watson, D.J., 1947. **Comparative physiological studies on the growth of field crops: I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years**. Annals of botany, 11(41), pp.41-76.

- Yan, D., Zhou, Q., Wang, J. & Zhang, N., 2017, **Bayesian Regularisation Neural Network Based on Artificial Intelligence Optimisation**, Int. J. Prod. Res., 55, PP. 2266-2287, <https://doi.org/10.1080/00207543.2016.1237785>.
- Yao, Y., Rosasco, L. & Caponnetto, A., 2007, **On Early Stopping in Gradient Descent Learning**, Constr. Approx., 26, PP. 289-315, <https://doi.org/10.1007/s00365-006-0663-2>.
- Ye, L., Jabbar, S.F., Abdul Zahra, M.M. & Tan, M.L., 2021, **Bayesian Regularized Neural Network Model Development for Predicting Daily Rainfall from Sea Level Pressure Data: Investigation on Solving Complex Hydrology Problem**, Complexity, 2021, PP. 1-14, <https://doi.org/10.1155/2021/6631564>.





مجله علمی سنجش از دور و GIS ایران



سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

سال پانزدهم، شماره اول، بهار ۱۴۰۲
Vol.15, No. 1, Spring 2023

85-108

Mapping Sugarcane Leaf Area Index by Inverting PRISMA Hyperspectral Images

Hajeb M.¹, Hamzeh S.^{2*}, Alavipanah S.K.³, Verrelst J.⁴

1. Ph.D. Student, Dep. of Remote Sensing and GIS, Faculty of Geography, University of Tehran, Tehran
2. Associate Prof., Dep. of Remote Sensing and GIS, Faculty of Geography, University of Tehran, Tehran
3. Prof. of Dep. of Remote Sensing and GIS, Faculty of Geography, University of Tehran, Tehran
4. Image Processing Laboratory (IPL), Parc Científic, Universitat de València, València, Spain

Abstract

Leaf Area Index (LAI) plays a critical role in the mass and energy exchanges between the earth and the atmosphere. Like of other plants, LAI of sugarcane is a good indicator of the health status and growth of this crop which is of great economic importance due to its role in the food and energy industries. Launched in 2019, the PRISMA satellite provides one of the most recent hyperspectral data sources which are applicable especially for mapping plant variables. In this study, a new kind of Artificial Neural Networks (ANN) so-called Bayesian Regularized Artificial Neural Network (BRANN) which applies Bayes' theorem to overcome the overfitting problem of neural networks is used. The model was implemented on a data set consisting of spectrum obtained by PRISMA satellite as an independent variable and sugarcane LAI measurements as a dependent variable. The ground measurements of sugarcane LAI were carried out in 118 elementary sampling units on the fields of Amir Kabir sugarcane cultivation and industry in Khuzestan province and on seven different dates during a sugarcane growth period in 2020. Comparing the performance of BRANN in retrieving sugarcane LAI from PRISMA spectra with that of a conventional ANN trained with the Levenberg-Marquardt algorithm (LMANN) indicates that the retrieval RMSE is reduced from 2.26 m²/m² applying LMANN to 0.67 m²/m² applying the BRANN method. In this study, the principle component analysis was also used dimensionality reduction. Retrieving LAI from the first 20 principle components, RMSE was also reduced from 1.41 m²/m² applying LMANN to 0.71 m²/m² applying BRANN. Exploiting principal components significantly reduced computational time. By implementing the calibrated BRANN model over the PRISMA image pixel by pixel, the sugarcane LAI map was generated. Evaluating this map showed that this map represents the spatial variations of sugarcane LAI well. The results of this study indicate the high performance of the BRANN method and high potential of PRISMA images to retrieve sugarcane LAI.

Keywords: Vegetation parameter retrieval, Leaf Area Index, Artificial Neural Networks, Inverting, Hyperspectral Remote Sensing, Sugarcane.

* Correspondence Address: Faculty of Geography, University of Tehran, No. 1, Zarrinkoub Alley, Vesal Shirazi St., Enqelab St., Tehran, Post Box: 14155-4665, Postal Code: 1417853933.
Email: saeid.hamzeh@ut.ac.ir