

بهبود برآورد پارامترهای بیوفیزیکی مزارع برنج با استفاده فتوگرامتری چندطیفی پهپادی

هادی علی‌زاده^۱، زهرا عزیزی^{۲*}، علی اصغر آل‌شیخ^۳، حسین آقامحمدی^۴، حمیدرضا پورقاسمی^۵

^۱ گروه سنجش از دور و سامانه اطلاعات جغرافیایی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران؛

hadi.alizadeh4620@iau.ac.ir

^۲ گروه مهندسی نقشه برداری، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران؛

zah_azizi@sbu.ac.ir

^۳ گروه سامانه‌های اطلاعات مکانی، دانشکده مهندسی نقشه‌برداری و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی،

تهران، ایران؛ alesheikh@kntu.ac.ir

^۴ گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران؛

aghamohammadi@iau.ac.ir

^۵ گروه علوم خاک، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران؛

ha.pourghasemi@shirazu.ac.ir

(دریافت: آبان ۱۴۰۴، تصویب: دی ۱۴۰۴)

چکیده

پهپادها به دلیل قدرت تفکیک مکانی بالا، هزینه‌ی نسبتاً کم و قابلیت تصویربرداری در بازه‌های زمانی مختلف، به یکی از ابزارهای کلیدی در سنجش از دور و کشاورزی دقیق تبدیل شده‌اند. در این پژوهش، امکان‌سنجی استفاده از تصاویر چندطیفی حاصل از پهپاد مجهز به سنجنده Sequoia برای تخمین پارامترهای بیوفیزیکی و بیوشیمیایی گیاه برنج بررسی شد. داده‌ها در سه مرحله‌ی فنولوژیکی از اراضی شالیزاری مرکز تحقیقات کشاورزی CAPIC در استان مازندران برداشت گردید. در مرحله‌ی نخست، تصاویر پهپادی پس از ارزیابی کیفیت و حذف نویز، تحت تصحیحات تابشی و هندسی قرار گرفتند. سپس شاخص‌های طیفی منتخب شامل NDVI، GNDVI، LCI، NDRE، NDWI و SIPI2 استخراج شدند تا اطلاعاتی در خصوص وضعیت سبزی‌نگی، میزان کلروفیل، آب برگ و سلامت فیزیولوژیکی گیاه فراهم شود. در ادامه، بازتاب طیفی پوشش گیاهی با استفاده از مدل فیزیکی PROSAIL (Physical Radiative Transfer Model) شبیه‌سازی و فرآیند معکوس‌سازی آن به روش جداول مرجع (LUT) برای برآورد پارامترهای بیوفیزیکی از جمله شاخص سطح برگ (LAI)، مقدار کلروفیل برگ (Cab)، محتوای آب برگ (Cw) و ضریب ساختاری (N) اجرا شد. داده‌های میدانی برداشت‌شده جهت اعتبارسنجی نتایج به کار رفتند و عملکرد مدل با شاخص‌های آماری R-squared (R^2) و Mean-Square Error Root (RMSE) ارزیابی گردید. نتایج نشان داد که تصاویر چندطیفی پهپادی دقت بالایی در تخمین پارامترهای گیاهی فراهم می‌کنند و مدل PROSAIL توانسته‌است روندهای فنولوژیکی گیاه برنج را با موفقیت بازتاب دهد. به‌طور خاص، دقت برآورد پارامترهای کلروفیل و ضخامت برگ بسیار بالا بود ($R^2 \approx 0.996$)، در حالی که خطای اندکی ($RMSE < 0.2$) در برخی مراحل رشد مشاهده شد. در مجموع، یافته‌ها حاکی از آن است که ادغام داده‌های چندطیفی پهپاد با مدل‌های فیزیکی نظیر PROSAIL می‌تواند ابزاری کارآمد برای پایش رشد گیاه و بهینه‌سازی مدیریت نهاده‌ها در چارچوب کشاورزی دقیق فراهم آورد. با این حال، محدودیت‌هایی همچون تمرکز مکانی محدود و هزینه‌ی بالای سامانه‌های تصویربرداری وجود دارد که در پژوهش‌های آینده می‌توان با گسترش محدوده‌ی مکانی و به‌کارگیری الگوریتم‌های یادگیری ماشین و یادگیری عمیق، بر آن‌ها غلبه کرد.

واژگان کلیدی: پهپاد، چندطیفی، کشاورزی دقیق، فنولوژی گیاه، PROSAIL.

۱- مقدمه

سنجش از دور به عنوان ابزاری غیرتماسی برای پایش وضعیت گیاهان و مدیریت منابع کشاورزی طی چند دهه گذشته جایگاه ویژه‌ای یافته است. این فناوری امکان جمع‌آوری داده‌ها در مقیاس‌های زمانی و مکانی مختلف را بدون نیاز به تماس مستقیم با سطح زمین فراهم می‌سازد و در شرایطی مانند مساحت زیاد مزارع یا دشواری دسترسی، بسیار کاربردی است [۱]. داده‌های سنجش از دور در مقیاس‌های گوناگون برای مدیریت محصولات کشاورزی به کار گرفته شده‌اند [۲] و به‌ویژه، پهپادها به دلیل ارتفاع پروازی پایین و داده‌های با قدرت تفکیک بالا، قابلیت پایش دقیق‌تری از نواحی خاص را فراهم می‌کنند [۳]. در سال‌های اخیر، سامانه‌های چندطیفی مبتنی بر پهپاد به سرعت توسعه یافته‌اند که نسبت به سامانه‌های هواپرد سرنشین‌دار کوچک‌تر، سبک‌تر و از نظر هزینه برداشت و پردازش مقرون به صرفه‌تر هستند [۴، ۵].

کاربردهای سنجش از دور در کشاورزی بسیار متنوع است و شامل پیش‌بینی عملکرد محصول، پایش خشکسالی، مدیریت منابع آب، شناسایی آفات و بیماری‌ها و تهیه نقشه خاک می‌شود [۶]. در این زمینه، ماهواره‌هایی مانند لندست و سنتینل-۲ داده‌های ارزشمندی با قدرت تفکیک متوسط ارائه کرده‌اند [۷]. این داده‌ها در پایش تغییرات پوشش گیاهی [۸]، ارزیابی سلامت گیاه [۹] و استخراج شاخص‌هایی همچون LAI^۱ [۱۰] و NDVI^۲ مورد استفاده قرار گرفته‌اند. افزون بر این، مطالعات موردی نشان داده‌اند که داده‌های پهپادی چند طیفی و ابرطیفی قادرند شاخص‌هایی مانند کلروفیل و سطح برگ را با دقت بالا برآورد کرده و حتی در پیش‌بینی عملکرد محصولات نیز نقش مؤثری ایفا نمایند [۱۲]. همچنین، رویکردهای جدید ترکیب داده‌های UAV^۳ و الگوریتم‌های یادگیری ماشین برای تخمین شاخص‌های کلیدی همچون شاخص برداشت برنج (HI)^۴ را با موفقیت توسعه داده‌اند [۱۳].

مأموریت ماهواره سنتینل-۲ با ۱۳ باند طیفی، به‌ویژه باندهای لبه‌قرمز، تحولی اساسی در پایش دقیق کلروفیل و نیتروژن گیاهان ایجاد کرده است [۱۴، ۱۵]. با وجود این،

عواملی مانند پوشش ابری و محدودیت تفکیک مکانی، استفاده از داده‌های ماهواره‌ای را در مقیاس‌های خرد دشوار ساخته است [۱۶]. همین چالش‌ها سبب رواج استفاده از پهپادهای مجهز به سنجنده‌های چندطیفی در سال‌های اخیر شده است [۱۷].

ظهور پهپادهای مجهز به سنجنده‌های چندطیفی و فراطیفی را می‌توان نقطه عطفی در کشاورزی دقیق دانست [۱۸]. برخلاف داده‌های ماهواره‌ای که تحت تأثیر پوشش ابری و تناوب بازدید قرار دارند، پهپادها امکان تصویربرداری در شرایط دلخواه و زمان‌های کوتاه‌تر را فراهم می‌کنند [۱۹]. در این میان، سنجنده‌هایی نظیر Sequoia با ثبت بازتاب در باندهای کلیدی (سبز، قرمز، لبه‌قرمز و مادون قرمز نزدیک) و مجهز بودن به حسگر نور خورشید، دقت بالایی در تصحیح تابشی و استخراج شاخص‌هایی چون NDVI، NDRE^۵ و MCARI^۶ ایجاد کرده‌اند [۲۰-۲۵]. مطالعات نشان داده‌اند که تصاویر پهپادی توانایی بیشتری نسبت به داده‌های ماهواره‌ای در تخمین پارامترهایی مانند کلروفیل دارند [۲۶]. افزون بر این، ادغام داده‌های چندطیفی UAV با داده‌های زمینی دقت تخمین نیتروژن را به‌طور چشمگیری افزایش داده است [۲۷].

مرورهای اخیر همچنین بر نقش داده‌های حرارتی پهپادی در پایش تنش‌های زیستی و غیرزیستی گیاهان تأکید کرده‌اند [۲۸]. پژوهش‌های جدید نیز نشان داده‌اند که ترکیب تصاویر چندطیفی UAV با الگوریتم‌های یادگیری ماشین می‌تواند امکان برآورد دقیق زیست‌توده و ارزیابی سلامت گیاهان را فراهم آورد و به بهبود مدیریت نهاده‌ها در کشاورزی دقیق کمک کند [۲۹]. این یافته‌ها بیانگر آن است که هرچند شاخص‌های طیفی و داده‌های پهپادی ابزارهای قدرتمندی برای پایش مستقیم وضعیت گیاه هستند، اما برای دستیابی به تخمین‌های پایدارتر و فیزیکی‌تر نیاز به مدل‌های انتقال تابش وجود دارد.

مدل‌های فیزیکی انتقال تابش، ابزار اصلی در شبیه‌سازی برهم‌کنش نور و پوشش گیاهی و استخراج ویژگی‌های زیستی از داده‌های سنجش از دور محسوب می‌شوند. در این میان، مدل PROSAIL^۷ که حاصل ادغام PROSPECT (ویژگی‌های نوری برگ) و SAIL (انتقال تابش در تاج) است،

۵ Normalized Difference Red Edge Index

۶ Modified Chlorophyll Absorption Ratio Index

۷ Physical Radiative Transfer Model

۱ Leaf Area Index

۲ Normalized Difference Vegetation Index

۳ Unmanned Aerial Vehicle

۴ Harvest Index

پراکندگی مدل برای تخمین پارامترهایی چون LAI، محتوای کلروفیل، آب برگ و ساختار تاج به شمار می‌رود [۳۰، ۳۱]. فرآیند وارون‌سازی PROSAIL با روش‌هایی مانند جداول مرجع^۱ (LUTs)، الگوریتم‌های بهینه‌سازی عددی یا الگوریتم‌های یادگیری ماشین انجام می‌شود [۳۲، ۳۳]. هر یک از این رویکردها مزایا و محدودیت‌هایی دارند. LUT به دلیل سادگی و شفافیت قابل‌استفاده است، اما پرهزینه و زمان‌بر است؛ بهینه‌سازی عددی دقت بالاتری دارد ولی به شدت به شرایط اولیه حساس است؛ و روش‌های یادگیری ماشین به‌ویژه در داده‌های پرنویز یا ناهمگن، توانایی استخراج روابط غیرخطی و تعمیم‌پذیری بالاتری را نشان داده‌اند [۳۳]. مطالعات مروری اخیر بیانگر آن است که استفاده از روش‌های داده‌محور مانند GPR^۲، شبکه‌های عصبی و درخت‌های تصمیم در بسیاری از شرایط برتری محسوس نسبت به روش‌های کلاسیک دارند [۳۳].

اهمیت این مدل‌ها در تخمین دقیق پارامترهای بیوفیزیکی و بیوشیمیایی مانند LAI، محتوای کلروفیل و غلظت نیتروژن آشکار می‌شود؛ شاخص‌هایی که با فرآیندهای حیاتی گیاه مانند فتوسنتز، تعرق و رشد ارتباط مستقیم دارند [۳۴]. داده‌های چندطیفی و فراطیفی با قدرت تفکیک بالا امکان پایش تغییرات ریزفیزیولوژیکی گیاهان را فراهم کرده‌اند [۳۵] و مشخص شده‌است که باندهای لبه‌قرمز حساسیت ویژه‌ای در برآورد کلروفیل و نیتروژن دارند [۳۶]. توسعه شاخص‌های طیفی پیشرفته مانند MCARI و TCARI^۳ نیز موجب افزایش دقت مدل‌سازی LAI و سبزی‌نگی نسبت به شاخص‌های ساده شده‌است [۱۹]. ترکیب وارون‌سازی PROSAIL با الگوریتم‌های یادگیری ماشین در سال‌های اخیر به‌عنوان راهکاری نوین برای کاهش خطا، پایداری بیشتر و کاهش هزینه‌های محاسباتی مورد توجه قرار گرفته‌است [۳۲، ۳۳، ۳۷]. از سوی دیگر، محتوای نیتروژن برگ به‌عنوان شاخص کلیدی برای سلامت و عملکرد گیاه در کشاورزی دقیق اهمیت زیادی دارد [۳۸]. تخمین غیرمستقیم آن با داده‌های سنجش‌ازدور و شاخص‌های حساس مانند NDRE^۴ عملکرد مطلوبی داشته‌است [۳۹، ۴۰]. داده‌های UAV با سنجنده‌هایی نظیر Sequoia نیز امکان پایش سریع و دقیق تغییرات نیتروژن در طول فصل

رشد را فراهم کرده‌اند [۴۱، ۴۲]. این یافته‌ها مسیر توسعه برنامه‌های کوددهی متغیر^۵ (VRA) و مدیریت بهینه نهاده‌ها را هموار ساخته‌است. در این میان، پژوهش‌ها نشان می‌دهند که مرحله فنولوژیک گیاه نقش تعیین‌کننده‌ای بر دقت تخمین‌ها دارد؛ به‌گونه‌ای که در مراحل اولیه رشد (با ساختار ساده‌تر تاج) دقت بالاتر است و در مراحل پایانی (مانند زرد شدن برگ‌ها) خطا افزایش می‌یابد [۳۷].

در حوزه شاخص‌ها، اگرچه NDVI یکی از پراکندترین شاخص‌ها در مطالعات پوشش گیاهی است، اما محدودیت‌هایی نظیر اشباع در تراکم‌های بالا، حساسیت به پس‌زمینه خاک و ضعف در تخمین مستقیم پارامترهای بیوشیمیایی باعث شده‌است که استفاده صرف از آن ناکافی باشد [۴۳-۴۹]. این امر موجب شد که توجه پژوهش‌ها به سمت شاخص‌های لبه‌قرمز جلب شود که نسبت به کلروفیل و LAI حساس‌تر بوده و مقاومت بیشتری در برابر نویز محیطی نشان می‌دهند [۵۰-۵۲]. مطالعات اخیر نشان داده‌اند که ترکیب این شاخص‌ها با داده‌های پهپادی و فراطیفی می‌تواند برآورد نیتروژن و کلروفیل را با دقت بیشتری انجام دهد [۱۹].

در نهایت، روند پژوهش‌های نوین به سمت ادغام شاخص‌های طیفی با مدل‌های فیزیکی حرکت کرده‌است. این رویکرد نیمه‌فیزیکی باعث می‌شود شاخص‌ها نه تنها به‌عنوان خروجی، بلکه به‌عنوان قیود معنادار در فرآیند وارون‌سازی PROSAIL عمل کنند و فضای جستجو را محدود سازند [۳۲، ۳۳]. استفاده از شاخص‌هایی با نسبت سیگنال به نویز بالا مانند NDRE یا ترکیب‌های پیشرفته مثل NDRE×MCARI موجب افزایش دقت و پایداری مدل‌ها شده‌است. چارچوب‌های یادگیری عمیق مانند PROSAIL-Net نیز با تلفیق شبکه‌های عصبی و شاخص‌های لبه‌قرمز، توانسته‌اند تخمین بسیار دقیقی از LAI و Cab بر پایه داده‌های سنتینل-۲ ارائه دهند [۵۳]. بسیاری از این پژوهش‌ها همچنین بر انجام تحلیل حساسیت پیش از ادغام شاخص‌ها تأکید دارند تا مؤثرترین شاخص‌ها انتخاب شده و از ورود نویزهای اضافی جلوگیری شود [۵۴].

در سال‌های اخیر، استفاده از تصاویر چندطیفی پهپادها (UAV) به‌عنوان ابزاری قدرتمند و انعطاف‌پذیر برای

۴ Normalized Difference Red Edge

۵ Variable Rate Application

۱ Look-Up Tables


۲ Gaussian Process Regression

۳ Transformed Chlorophyll Absorption in Reflectance Index

۲- منطقه مورد مطالعه و داده

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در تحقیق حاضر شامل اراضی شالیزاری مرکز تحقیقاتی کاپیک (CAPIC) واقع در استان مازندران ایران است که مساحتی بالغ بر ۵۰ هکتار را در بر می‌گیرد. این اراضی در حدود ۱۰ کیلومتری شمال شهر آمل و ۸ کیلومتری جنوب سواحل دریای خزر قرار گرفته‌اند و به دلیل موقعیت جغرافیایی ویژه، از اقلیم معتدل خیزی، بارندگی مناسب و دسترسی به منابع آب سطحی و زیرزمینی بهره‌مند هستند. خاک‌های آبرفتی، شیب اندک و ساختار زمین‌پوش طبیعی منطقه، بستر مناسبی برای زراعت برنج فراهم آورده‌است. لذا، در تحقیق حاضر این بخش به عنوان منطقه مورد مطالعه انتخاب شده‌است که موقعیت جغرافیایی آن در شکل ۱ نشان داده شده‌است.



شکل ۱- موقعیت منطقه مورد مطالعه

۲-۲- داده‌های مورد استفاده

تصاویر چندطیفی، از مهم‌ترین منابع داده در فتوگرامتری و سنجش از دور به‌شمار می‌روند و با ثبت بازتاب سطح زمین و باندهای طیفی مختلف، امکان استخراج دقیق پارامترهای زیستی و فیزیولوژیکی گیاه را فراهم می‌کنند. در سال‌های اخیر، پهپادهای مجهز به سنجنده‌های چندطیفی به دلیل قدرت تفکیک مکانی بالا، هزینه‌ی مناسب و قابلیت تصویربرداری در زمان‌های دلخواه، جایگاه ویژه‌ای در مطالعات کشاورزی دقیق یافته‌اند. در پژوهش حاضر از تصاویر چندطیفی پهپاد Sequoia برای تخمین پارامترهای کلیدی گیاه برنج استفاده شده‌است.

این داده‌ها با فراهم‌سازی جزئیات دقیق از وضعیت تاج پوشش گیاهی، امکان پایش و مدل‌سازی دقیق‌تر ویژگی‌های

استخراج پارامترهای بیوفیزیکی و بیوشیمیایی محصولات کشاورزی با قدرت تفکیک مکانی و زمانی بسیار بالا مورد توجه قرار گرفته‌است. با این حال، بیشتر مطالعات پیشین عمدتاً بر روش‌های آماری یا شاخص‌محور متکی بوده‌اند که اگرچه در شرایط خاص کاربردی هستند، اما فاقد تبیین فیزیکی بوده و در تعمیم‌پذیری میان محصولات و مراحل فنولوژیکی مختلف عملکرد محدودی دارند.

برای رفع این محدودیت‌ها، در این پژوهش یک چارچوب نیمه‌فیزیکی بر پایه‌ی مدل PROSAIL توسعه داده شد تا پارامترهای کلیدی برگ و تاج گیاه از جمله شاخص سطح برگ (LAI)، کلروفیل (Cab)، کاروتنوئیدها (Car)، محتوای آب برگ (Cw)، ماده خشک برگ (Cm) و ضریب ساختاری (N) برای چند نوع محصول زراعی در سه مرحله کلیدی رشد (جوانه‌زنی، پنجه‌زنی و خوشه‌دهی) تخمین زده شود. براین اساس، تصاویر چندطیفی پهپادی با قدرت تفکیک بالا توسط سنجنده‌ی Sequoia شامل باند حساس لبه‌قرمز در مراحل مختلف رشد گیاه (جوانه‌زنی، پنجه‌زنی و خوشه‌دهی) برداشت گردید تا شبیه‌سازی و وارون‌سازی مدل با دقت بیشتری انجام شود.

در این چارچوب، مجموعه‌ای از شاخص‌های طیفی شامل ^{4}LCI ، $^{2}NDWI$ ، $^{3}SIPI2$ ، $^{1}NDRE$ ، $^{1}GNDVI$ ، $^{1}NDVI$ محاسبه شدند تا روند زمانی رشد و تغییرات فیزیولوژیکی محصولات در مراحل مختلف فنولوژیکی بررسی گردد. نتایج حاصل از مدل‌سازی با داده‌های میدانی برداشت‌شده برای اعتبارسنجی تطبیق داده شد تا قابلیت اطمینان برآوردها ارزیابی شود. نوآوری اصلی این پژوهش، توسعه یک چارچوب نیمه‌فیزیکی مبتنی بر مدل PROSAIL برای تخمین هم‌زمان مجموعه‌ای جامع از پارامترهای بیوفیزیکی و بیوشیمیایی برنج (LAI، Cab، Car، Cw، Cm و N) در سه مرحله کلیدی رشد (جوانه‌زنی، پنجه‌زنی و خوشه‌دهی) است. برخلاف مطالعاتی همچون Zheng et al. (2018) و Kanning et al. (2018) که عمدتاً بر مدل‌های آماری یا تک‌پارامتری متکی هستند، این پژوهش تحلیل فیزیکی رفتار فنولوژیکی گیاه را ارائه داده و نتایج آن با داده‌های میدانی واقعی اعتبارسنجی شده‌است. این رویکرد قابلیت تعمیم‌پذیری بیشتری داشته و مبنای مناسبی برای توسعه سامانه‌های کشاورزی دقیق فراهم می‌کند.

^۳ Structure Insensitive Pigment Index-2

^۴ Leaf Chlorophyll Index

^۱ Green Normalized Difference Vegetation Index

^۲ Normalized Difference Water Index

فیزیولوژیکی و فنولوژیکی گیاه را فراهم می کنند و می توانند مبنای مؤثری برای توسعه ای سامانه های تصمیم یار در کشاورزی دقیق باشند.

۲-۲-۱- تصاویر پهپاد eBee با سنجنده چندطیفی سکویا

پهپادها یا سامانه های پرنده هدایت پذیر از دور (UAV/Drone)، به دلیل ویژگی هایی همچون قدرت تفکیک مکانی بسیار بالا، هزینه ی نسبتاً پایین، سهولت به کارگیری و توانایی تصویربرداری چندزمانه، به یکی از ابزارهای کلیدی در علوم ژئوماتیک و کشاورزی دقیق تبدیل شده اند. این سامانه ها با قابلیت تجهیز به سنجنده های پیشرفته ی نوری و چندطیفی، داده هایی با ارزش بالا برای پایش وضعیت پوشش گیاهی، برآورد عملکرد محصول، تشخیص تنش آبی و ارزیابی سلامت گیاه فراهم می کنند.

در این پژوهش از پهپاد مجهز به سنجنده ی چندطیفی Sequoia استفاده شده است که با چهار باند طیفی اصلی (سبز، قرمز، لبه قرمز و مادون قرمز نزدیک) و حسگر تابش سنجی مجزا، امکان محاسبه ی شاخص های کلیدی نظیر NDWI، LCI، NDRE، GNDVI، NDVI را برای استخراج پارامترهای بیوفیزیکی و بیوشیمیایی گیاه فراهم می سازد.

پهپادهای مورد استفاده در سنجش از دور به طور کلی در دو گروه اصلی بال ثابت و چندملخه (عمودپرواز) تقسیم می شوند. هر یک از این دو نوع پهپاد مزایا و محدودیت های خاص خود را دارند و انتخاب میان آنها بسته به نوع مأموریت، مقیاس مطالعه و شرایط محیطی صورت می گیرد. پهپادهای بال ثابت، به دلیل طراحی آبرودینامیکی، توان پرواز طولانی تر و پوشش مکانی وسیع تری را در هر مأموریت فراهم می کنند، در حالی که پهپادهای چندملخه به دلیل پایداری پروازی بالا، کنترل دقیق زاویه دوربین و قابلیت برخاست و فرود عمودی، برای تصویربرداری دقیق در فضاهای محدود یا مناطق ناهموار مناسب تر هستند.

مزایا و معایب پهپادهای بال ثابت و چندملخه به صورت خلاصه در جدول ۱ ارائه شده است. به طور کلی، داده های چندطیفی حاصل از پهپاد Sequoia، با ترکیب دقت طیفی مناسب و قدرت تفکیک مکانی بالا، بستر ارزشمندی برای پایش دقیق رشد و سلامت گیاه برنج در مقیاس مزرعای فراهم می کنند.

پهپاد eBee، تولیدشده توسط شرکت SenseFly، یکی از پرکاربردترین و معتبرترین سامانه های بال ثابت در حوزه نقشه برداری و سنجش از دور به شمار می رود (شکل ۲). این شرکت با رویکردی تخصصی، انواع پهپادها و سنجنده های متناسب با نیازهای کاربران حرفه ای را طراحی و عرضه نموده است. پهپاد eBee از طراحی ماژولار برخوردار است و قابلیت نصب سنجنده های مختلف نظیر دوربین های حرارتی، مالتی اسپکترال و دوربین های فتوگرامتری دقیق را دارد؛ که این امر، آن را برای کاربردهای متنوع نقشه برداری و پایش محیطی بسیار انعطاف پذیر ساخته است.

جدول ۱- مقایسه معایب و مزایای پهپادهای بال ثابت و چندملخه

پهپاد بال ثابت	پهپاد عمود پرواز
مدایوت پروازی بیشتر (حدود ۴۵ تا ۶۰ دقیقه)	مدایوت پروازی کمتر (حدود ۱۵ تا ۶۰ دقیقه)
پوشش سطح بیشتر (حدود ۱۰۰ تا ۲۰۰ هکتار)	پوشش سطح کمتر (حدود ۱۰ تا ۱۰۰ هکتار)
قدرت تفکیک مکانی پایین تر (۱۰ الی ۲۰ سانتیمتر)	قدرت تفکیک مکانی بالاتر (حدود ۱ الی ۱۰)
فضای زیادی جهت فرود مورد نیاز است	فضای کمی جهت پرواز و فرود مورد نیاز است.
پایداری کمتر و خطای ناشی از تیلت بیشتر	پایداری بالا و خطای ناشی از تیلت کم

از جمله ویژگی های برجسته این پهپاد، بهره مندی از نرم افزار مانیتورینگ مستقل eMotion برای برنامه ریزی و کنترل پرواز و نیز نرم افزار Postflight برای پردازش داده های تصویری به صورت اختصاصی است؛ این نرم افزارها توسط کمپانی سازنده برای بهره برداری بهینه از سامانه طراحی شده اند. طراحی بدنه به گونه ای انجام شده که امکان جداسازی بال ها از بدنه و قرارگیری تمامی قطعات در یک کیف حمل مطابق با استانداردهای حمل و نقل هوایی بین المللی IATA را فراهم می سازد و این ویژگی جابجایی آن را به ویژه در مأموریت های میدانی تسهیل می کند.

پهپاد eBee با وزنی کمتر از ۷۰۰ گرم، یکی از سبک ترین پهپادهای تجاری مورد استفاده در فتوگرامتری و سنجش از دور به شمار می رود (جدول ۲). در طراحی بدنه این سامانه، از فوم انعطاف پذیر برای افزایش ایمنی و نیز از پیشرانه ای در انتهای پهپاد بهره گرفته شده است. این طراحی سبک، راه اندازی پهپاد به صورت دستی (Hand-Launched) را امکان پذیر کرده است.

سنجنده Sequoia، یکی از سنجنده‌های پیشرفته چندطیفی است که با هدف به‌کارگیری در کاربردهای کشاورزی طراحی و تولید شده که بر روی پهپاد eBee نصب شده‌است. این سنجنده قابلیت نصب بر روی انواع پهپادهای بال ثابت و عمودپرواز را داشته و به‌صورت همزمان شامل یک دوربین چندطیفی با چهار باند طیفی (Red, Green, NIR^۱ و Red Edge) و یک دوربین RGB می‌باشد. قدرت تفکیک مکانی تصاویر ثبت‌شده توسط سنسور چندطیفی برابر با ۱.۲ مگاپیکسل و برای دوربین RGB برابر با ۱۶ مگاپیکسل است.



شکل ۲- سامانه پهپاد eBee برای کشاورزی و کاربردهای نقشه‌برداری


جدول ۲- مشخصات پهپاد بال ثابت eBee

حداکثر زمان پرواز	وزن	۵۰ دقیقه	۷۰۰ گرم
سرعت	طول بال	36 – 57 km/h (10-16 m/s)	۹۶ سانتی متر
ماکسیمم ارتباط رادیویی	جنس بدنه	up to 3km (1.86miles)	فوم EPP
حداکثر پوشش (در یک پرواز)	پیش رانش	10 km ²	پروانه با انرژی الکتریکی
(GSD) ^۲	باتری	1.5 – 5 cm	11.1 V, 2100 mAh
دقت مسطحانی / ارتفاعی	دوربین	3 – 5 cm 5 – 10 cm	16MP IXUS/ELPH

سنجنده Sequoia از دو بخش اصلی تشکیل شده‌است: بدنه اصلی و حسگر تابش خورشیدی (Sunshine Sensor). بخش اصلی شامل ماژول‌های تصویربرداری چندطیفی و RGB است، در حالی که Sunshine Sensor به‌منظور اندازه‌گیری تابش لحظه‌ای^۳ و نیز ثبت اطلاعات موقعیت و جهت‌گیری از طریق سامانه‌های GPS و IMU طراحی شده‌است. تغییرات شدت نور محیطی در طول زمان می‌تواند باعث اختلال در دقت داده‌های منعکس‌شده از سطح گیاهان

شود و در نهایت بر صحت نتایج پردازش تأثیر منفی بگذارد. برای مقابله با این چالش، سنسور Sunshine به‌گونه‌ای طراحی شده که در قسمت فوقانی پهپاد نصب گردد و در طول پرواز، به‌طور پیوسته شرایط نوری را در محدوده باندهای طیفی سنسور اصلی پایش و ثبت نماید.

وجود این سنسور کمکی، سنجنده Sequoia را قادر می‌سازد تا حتی در شرایط نوری متغیر مانند آسمان نیمه‌ابری نیز، داده‌هایی با دقت طیفی بالا ثبت کند (شکل ۳). این ویژگی‌ها، Sequoia را به ابزاری توانمند برای پایش دقیق سلامت پوشش گیاهی، تخمین عملکرد محصولات، و سایر تحلیل‌های کشاورزی دقیق بدل کرده‌است.



شکل ۳- مشخصات سنجنده سکویا

۲-۳- روش تحقیق

فرآیند پیاده‌سازی روش پیشنهادی در فلوچارت شکل ۴ نشان داده شده‌است. با توجه به شکل ۴، ابتدا داده‌های چندطیفی در چند زمان‌های مختلف جمع‌آوری و پیش‌پردازش شدند (تصحیح هندسی، رادیومتریک و استخراج بازتاب سطحی). سپس متغیرهای ورودی مدل PROSAIL و محدوده تغییرات آن‌ها تعریف شده و طیف بازتابی پوشش گیاهی در ترکیب‌های مختلف شبیه‌سازی می‌گردد. این طیف‌های شبیه‌سازی‌شده با بازتاب طیفی واقعی مقایسه شده و میزان خطا^۴ (RMSE) محاسبه می‌شود. ترکیب‌هایی که RMSE کمتری دارند انتخاب شده و در مرحله وارون‌سازی مدل PROSAIL، پارامترهای زیستی گیاه مانند LAI، کلروفیل و آب برگ) تخمین زده می‌شوند. در ادامه، خروجی‌های مدل با استفاده از برداشت‌های میدانی ارزیابی شده‌اند. نهایتاً نقشه‌ها و مقادیر نهایی پارامترهای گیاهی استخراج شده و مبنایی برای تحلیل تغییرات پوشش گیاهی در طول فصل رشد فراهم می‌شود. جزئیات روند پژوهشی در ادامه مطرح شده‌است.

^۳ Irradiance


^۴ Root Mean Square Error

^۱ Near-Infrared

^۲ Ground Sampling Distance

۲-۳-۱- عملیات پرواز و عکسبرداری

در این تحقیق، عملیات تصویربرداری هوایی با استفاده از پهپاد بال ثابت eBee ساخت شرکت SenseFly انجام شد. این پهپاد به سنجنده‌ی چندطیفی Sequoia مجهز است که چهار باند طیفی اصلی شامل سبز (Green)، قرمز (Red)، لبه قرمز (Red-Edge) و فروسرخ نزدیک (NIR) را پوشش می‌دهد. کلیه پروازها در ساعت ۱۰:۳۰ صبح به وقت محلی با هدف ثبت تصاویر در شرایط نوری پایدار و حداقل سایه انجام گرفت. برای اطمینان از پوشش کامل منطقه و دستیابی به داده‌های مناسب جهت پردازش، درصد همپوشانی طولی و عرضی تصاویر به ترتیب ۷۰ درصد و ۸۰ درصد در نظر گرفته شد. مسیر پرواز پهپاد eBee در شکل ۵ نشان داده شده است.



شکل ۴- فلوچارت اجرای روش پیشنهادی

تصویربرداری از کل سطح مزرعه با استفاده از سنجنده‌ی چندطیفی Sequoia انجام شد و داده‌های حاصل برای برآورد پارامترهای بیوفیزیکی و بیوشیمیایی گیاه مورد استفاده قرار گرفت. جزئیات فنی و زمانی پروازها در جدول ۳ ارائه شده است.

۲-۳-۲- پیش پردازش داده‌ها

در نخستین گام از روند پژوهش، تصاویر خام برداشت‌شده توسط پهپاد از نظر کیفیت مورد ارزیابی قرار گرفتند تا داده‌های نامناسب پیش از ورود به مراحل پردازش حذف شوند. عواملی مانند پرواز در ارتفاع بسیار پایین (حدود ۲ تا ۳ متر)، تاری ناشی از لرزش یا کشیدگی تصویر هنگام تصویربرداری، و همچنین انحراف زاویه دوربین بر اثر وزش باد می‌توانند موجب افت کیفیت داده‌ها شوند؛ از این رو شناسایی و حذف تصاویر فاقد کیفیت از اهمیت بالایی برخوردار بود. فرآیند پردازش داده‌ها بر روی تصاویر چندطیفی حاصل از سنجنده Sequoia نصب‌شده بر روی پهپاد eBee در نرم‌افزارهای Pix4Dmapper و Pix4Dfields انجام گرفت. در این مرحله، ابتدا عملیات هم‌ترازی تصاویر برای تعیین موقعیت و جهت‌گیری دقیق هر تصویر براساس مختصات مرکزی و بازسازی هندسه‌ی نسبی آن‌ها صورت گرفت. سپس با استفاده از الگوریتم‌های تطابق چندتصویری، مجموعه‌ای از نقاط سه‌بعدی استخراج شد تا ابرنقطه‌ای متراکم از سطح زمین و پوشش گیاهی تولید شود. در ادامه، این ابرنقاط به منظور بازسازی پیوسته‌ی سطح و تولید مدل رقومی سطح (DSM)^۱ مورد استفاده قرار گرفتند.




جدول ۳- مشخصات و تاریخ عملیات عکسبرداری با استفاده از پهپاد

ردیف	تاریخ	مرحله	ارتفاع (متر)	GSD (cm)
۱	۱۳۹۹/۰۳/۲۱	نشاء کاری	۱۲۰	۱۳/۰۶
۲	۱۳۹۹/۰۴/۲۱	سردهی	۱۲۰	۱۲/۹۷
۳	۱۳۹۹/۱۲/۰۵	برداشت	۱۲۰	۱۲/۸۴

پس از آن، تصحیحات هندسی لازم اعمال گردید تا اثرات ناشی از زاویه‌ی دوربین، توپوگرافی و ناپایداری پرواز حذف شده و در نهایت، ارتوفتوهای چندطیفی دقیق تولید شوند. تصاویر حاصل در سه مقطع زمانی مختلف چرخه‌ی رشد گیاه برنج پردازش و

برنامه‌ریزی و مدیریت پروازها از طریق نرم‌افزار eMotion انجام گرفت. منطقه‌ی مورد مطالعه شامل اراضی شالیزاری مرکز تحقیقات کشاورزی کاپیک (CAPIC) واقع در استان مازندران، ایران است که مساحتی حدود ۵۰ هکتار را در بر می‌گیرد. به منظور پایش تغییرات فنولوژیکی گیاه برنج، سه مرحله‌ی زمانی کلیدی به‌عنوان نماینده‌ی از چرخه‌ی رشد گیاه انتخاب شد که شامل مراحل نشاء کاری، سردهی (حداکثر سبزی‌نگی) و رسیدگی کامل (پیش از برداشت محصول) بودند. در هر یک از این مراحل،

^۱ Digital Surface Model



شکل ۶- مقایسه تصاویر ارتو حاصل از پهپاد در سه زمان مختلف

مرحله اول: پردازش تصاویر و استخراج بازتاب سطحی گیاهان

به منظور کاهش اثر تغییرات تابش لحظه‌ای در تصاویر پهپاد، یک فرآیند استاندارد تصحیح رادیومتریک برای داده‌های چندطیفی سنسور Sequoia اجرا شد. پیش از هر پرواز، پنل بازتاب استاندارد تحت تابش مستقیم خورشید تصویربرداری شد تا ضرایب کالیبراسیون هر باند برای تبدیل مقادیر خام DN به بازتاب سطحی استخراج شود. در طول پرواز، سنسور نورسنج پهپاد تابش خورشید را به صورت

به ارتوفتو تبدیل گردیدند. نمونه‌ای از نتایج این مرحله در شکل ۶ ارائه شده است که نمایانگر دقت و کیفیت بالای داده‌های تولیدی از سنجنده Sequoia است.

۲-۳-۳- فریند استخراج پارامترهای گیاه

هدف نهایی این تحقیق، استخراج پارامترهای زیست‌فیزیکی پوشش گیاهی مانند شاخص سطح برگ (LAI)، میزان کلروفیل (Cab)، محتوای آب برگ (Cw) و دیگر ویژگی‌های ساختاری از تصاویر چندطیفی ثبت‌شده توسط سنجنده Sequoia نصب‌شده روی پهپاد است که جزئیات آن در ادامه مطرح می‌گردد.



عکسبرداری eBee در تاریخ ۹۹-۰۳-۲۱



عکسبرداری eBee در تاریخ ۹۹-۰۴-۲۱



عکسبرداری eBee در تاریخ ۹۹-۰۵-۱۲

شکل ۵- سه مرحله عکسبرداری با پهپاد از منطقه مورد مطالعه در سه مرحله فنولوژی

پیوسته اندازه‌گیری کرد تا تغییرات روشنایی ناشی از تغییر زاویه خورشید یا عبور ابر جبران شود. عملیات تصحیح رادیومتری در نرم‌افزار Pix4Dfields با استفاده از مدل White Panel + Irradiance انجام گرفت تا یکنواختی بازتاب‌پذیری در تمام تصاویر تضمین شود. همچنین، با توجه به ارتفاع پایین پرواز (حدود ۸۰ تا ۱۲۰ متر)، اثرات اتمسفری نظیر پراکندگی ریلی، اثرات آتروسول و جذب اوزون بسیار محدود بوده و نیاز به اجرای مدل‌های کلاسیک تصحیح اتمسفری (مانند S_۶ یا MODTRAN) را مرتفع می‌سازد. همچنین کلیه پروازها تحت شرایط نوری پایدار انجام شد؛ از این رو، ترکیب «تصحیح رادیومتری اولیه + داده‌های نورسنج» برای تولید بازتاب سطحی دقیق کافی بوده‌است. بنابراین، در این مرحله داده‌های خام حاصل از سنجنده Sequoia با استفاده از نرم‌افزارهای تخصصی تصحیح اتمسفری، کالیبراسیون رادیومتری و حذف نویز شدند. سپس بازتاب سطحی در باندهای مختلف برای هر پیکسل به‌صورت عددی استخراج شد و برای تحلیل‌های بعدی مورد استفاده قرار گرفت. به‌منظور اطمینان از صحت رادیومتری داده‌ها در شرایط نوری متغیر، از پنل کالیبراسیون رفلکتانس، حسگر تابش محیطی نصب‌شده بر روی سنجنده Sequoia و همچنین تصحیحات استاندارد رادیومتری در محیط نرم‌افزار سازنده استفاده شد. علاوه بر این، پروازها در شرایط جوی پایدار و نزدیک به زمان خورشید میانه‌روز انجام شد تا تغییرات لحظه‌ای تابش نور خورشید به حداقل برسد.

مرحله دوم: تعریف متغیرها و محدوده تغییرات

در این مرحله متغیرهای ورودی مدل PROSAIL بر اساس برداشت‌های میدانی، ویژگی‌های گیاه مورد مطالعه و مشخصات فنی سنجنده تعریف گردیدند. این متغیرها شامل: پارامترهای فیزیولوژیکی گیاه: N, Cm, Cw, Cab، پارامترهای ساختاری تاج پوشش: LAI, ALA, HOT، شرایط مشاهده: زاویه دید سنجنده، زاویه خورشید، زاویه بین آن‌ها (φ)

پارامترهای خاک: روشنایی و رطوبت خاک (Rs, psoil) محدوده تغییرات این متغیرها با توجه به داده‌های مطالعات پیشین، آزمایش‌های میدانی و استانداردهای جهانی مانند مقادیر پیشنهادی و بازه‌های تغییرات آن‌ها مشخص شد (جدول ۴).

مقادیر اولیه و محدوده تغییرات پارامترهای Cab, Cw, Cm و N بر اساس اندازه‌گیری‌های میدانی نمونه‌برگ‌ها و همچنین توصیه‌های مطالعات استاندارد مرتبط با PROSAIL برای محصولات علفی تعیین شدند [۳۰]. همچنین، پارامترهای ساختاری تاج پوشش (LAI, ALA, HOT) مطابق با وضعیت واقعی مزرعه در سه زمان برداشت، و بر اساس اندازه‌گیری‌های میدانی LAI و مشاهدات زاویه برگ در مزرعه تنظیم شدند. افزون بر این، زاویه خورشید از داده‌های متادیتای پرواز و زاویه دید سنجنده بر اساس مشخصات فنی دوربین Sequoia تعیین گردید. بنابراین، تنظیم تمامی پارامترهای ورودی PROSAIL بر مبنای ترکیبی از داده‌های واقعی مزرعه، ویژگی‌های فیزیولوژیکی گیاه برنج و بازه‌های استاندارد گزارش‌شده در مطالعات معتبر انجام شد (جدول ۴).

مرحله سوم: شبیه‌سازی طیف بازتاب پوشش گیاهی با مدل PROSAIL

با استفاده از مدل PROSAIL که ترکیبی از مدل‌های PROSPECT (برای برگ) و SAIL (برای تاج پوشش) است، بازتاب طیفی گیاهان در طول موج‌های ۴۰۰ تا ۲۵۰۰ نانومتر به ازای تمام ترکیب‌های ممکن پارامترهای تعریف‌شده، شبیه‌سازی شد. برای هر ترکیب از پارامترها، یک طیف بازتابی شبیه‌سازی و ذخیره شد. در مجموع چند هزار ترکیب مختلف تولید شد که پوشش مناسبی از فضای پارامترها را فراهم می‌کرد. در رابطه ۱ مدل PROSAIL ارائه شده‌است.

$$ptoc = SAIL(refl, tran, LAI, ALA, HOT, SKYL, R_s, \theta_s, \theta_v, \phi) \quad (1)$$

که در آن θ_s و θ_v زاویه زنیت خورشید و سنجنده و ϕ زاویه آزیموت بین سنجنده و خورشید است. بازتابندگی خاک پشت زمینه شرط مرز پایینی مدل SAIL است و با Rs نشان می‌دهند. بازتاب خاک پشت زمینه به شرایط هندسه تصویربرداری، زبری سطح، ترکیبات کانی‌ها، مقدار مواد غیرآلی و رطوبت خاک بستگی دارد.

مرحله چهارم: وارون‌سازی مدل PROSAIL جهت تخمین پارامترهای گیاهی

برای تخمین پارامترهای زیستی گیاه مانند LAI, Cab, CNC و CCC از روی بازتاب طیفی حاصل از تصاویر سنجنده

Sequoia، فرآیند وارون سازی مدل PROSAIL اجرا شد. این مرحله شامل تطبیق بازتاب شبیه سازی شده از مدل با بازتاب اندازه گیری شده واقعی و یافتن مقادیر بهینه پارامترهای ورودی است.

برای معکوس سازی مدل PROSAIL در این پژوهش از روش جداول مرجع (Look-Up Table, LUT) استفاده شد. این روش که به طور گسترده در مطالعات سنجش از دور به کار گرفته می شود، شامل دو مرحله اصلی است: (۱) تعریف فضای متغیرها و تولید پایگاه داده طیفی (LUT) از بازتاب های شبیه سازی شده با ترکیب های مختلف پارامترهای ورودی، و (۲) مقایسه بازتاب های واقعی برداشت شده با مقادیر شبیه سازی شده و انتخاب ترکیبی که کمترین خطا براساس معیارهایی نظیر RMSE داشته باشد. بدین ترتیب، پارامترهای بیوفیزیکی و بیوشیمیایی گیاه (مانند LAI، Cab و Cw) از روی داده های طیفی استخراج شدند. برای انتخاب ترکیب بهینه، از شاخص خطای جذر میانگین مربعات (RMSE) میان بازتاب طیفی مدل و بازتاب واقعی استفاده شد (رابطه ۲). در این فرایند، ترکیب پارامترهایی که کمترین RMSE را در مقایسه با بازتاب برداشت شده داشتند، به عنوان مقادیر بهینه پارامترهای گیاهی در نظر گرفته شدند. این روش وارون سازی ساده و مؤثر، با فرض همگنی شرایط نوری، دقت سنجنده، و تطابق هندسی داده ها اجرا گردید.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{\text{measured}}^{(i)} - R_{\text{LUT}}^{(i)})^2} \quad (2)$$

مرحله پنجم: وارون سازی مدل PROSAIL در زمان های مختلف

برای هر تصویر برداشت شده در یک بازه زمانی مشخص، مقادیر بازتاب در باندهای مختلف با طیف های شبیه سازی شده در جدول مرجع همان زمان مقایسه شد. برای هر پیکسل، ترکیبی از پارامترها که کمترین RMSE را در مقایسه با بازتاب واقعی داشتند، به عنوان مقادیر تخمینی پارامترهای گیاهی آن پیکسل در آن زمان در نظر گرفته شد. این فرآیند برای تمامی تاریخ ها یا زمان های برداشت تکرار شد و در نهایت، تغییرات زمانی پارامترهایی

مانند LAI، Cab، CCC و غیره در طول دوره مطالعه استخراج گردید.

در تولید جدول مرجع مدل PROSAIL، دامنه پارامترهای بیوفیزیکی بر اساس مقادیر گزارش شده در ادبیات و اندازه گیری های میدانی محدود شد و گام های پارامتری به گونه ای انتخاب گردیدند که فضای پاسخ مدل به طور کامل پوشش داده شود، اما از ایجاد حجم بسیار بزرگ LUT جلوگیری شود. هرچند از روش های بهینه سازی پیشرفته مانند نمونه برداری لاتین هایپرکیوب استفاده نشد، اما انتخاب دامنه های محدود شده و گام های مناسب موجب کاهش طبیعی حجم LUT و بهبود کارایی محاسباتی شد. بنابراین، این رویکرد نه تنها تخمین مکانی دقیق تری فراهم کرد، بلکه امکان تحلیل روندهای زمانی رشد گیاه یا پاسخ آن به تنش ها را نیز میسر ساخت.

مرحله ششم: ارزیابی دقت نتایج و تحلیل حساسیت

ارزیابی دقت پارامترهای تخمینی مدل PROSAIL با استفاده از مقایسه آماری بین بازتاب شبیه سازی شده و بازتاب واقعی ثبت شده توسط سنجنده Sequoia انجام گرفت. در این راستا، پروازهای پهنادی و برداشت های میدانی در مساحتی حدود ۵۰ هکتار از مزارع برنج در مرکز تحقیقات CAPIC صورت گرفت که در مجموع ۲۰۰ نمونه مرجع زمینی در سه مرحله فنولوژیکی جمع آوری شد تا ارزیابی پارامترهای بیوفیزیکی تاج پوشش پشتیبانی شده و نمایندگی مناسبی از تنوع درون مزرعه ای تضمین گردد. نمونه برداری به صورت تصادفی طبقه بندی شده^۱ انجام گرفت تا تنوع درون مزرعه ای و تغییرات پوشش گیاهی به درستی لحاظ شود. توزیع نقاط در سطح مزرعه به صورت یکنواخت و با فاصله گذاری مشخص انجام شد و برای اندازه گیری LAI از LAI-2200C و برای اندازه گیری پارامترهای برگ، از نمونه برداری مستقیم برگ و دستگاه کلروفیل متر SPAD استفاده شد. برای این منظور از شاخص های آماری مانند RMSE و ضریب تعیین (R^2) استفاده شد. برای تحلیل میزان تأثیرگذاری متغیرهای ورودی بر پاسخ مدل، تحلیل حساسیت یک متغیره نیز انجام شد. در این تحلیل، هر پارامتر به صورت مجزا تغییر داده شد و تأثیر آن بر خروجی بازتاب مدل بررسی شد.

جدول ۴- محدوده تغییرات متغیرها در مراحل مختلف رشد گیاه برنج

پارامتر	واحد	مرحله رشد اولیه	مرحله رشد میانی	مرحله نهایی	توضیح
N	-	۱/۱-۱/۵	۱/۳-۱/۷	۱/۲-۱/۵	به شکل غیرمستقیم با ضخامت برگ مرتبط است
Cab	$\mu\text{g}/\text{cm}^2$	۱۵-۳۵	۳۵-۶۵	۱۰-۳۰	در اوج رشد بیشترین مقدار را دارد
Car	$\mu\text{g}/\text{cm}^2$	۵-۱۰	۷-۱۵	۵-۱۰	معمولاً حدود ۲۰ درصد Cab در نظر گرفته می‌شود
Cw	g/cm^2	۰/۰۰۵ تا ۰/۰۱۰	۰/۰۲۵ تا ۰/۰۱۵	۰/۰۱۵ تا ۰/۰۰۵	در مرحله رسیدگی کاهش می‌یابد
Cm	g/cm^2	۰/۰۰۵ تا ۰/۰۰۲	۰/۰۱۵ تا ۰/۰۰۶	۰/۰۲۰ تا ۰/۰۱۰	با رشد و خشکی برگ افزایش می‌یابد
LAI	m^2/m^2	۰/۲-۲	۳-۶/۵	۲-۴	اوج در مرحله خوشه‌دهی، سپس کاهش
ALA	درجه	۳۰-۴۵	۳۰-۵۰	۴۰-۶۰	در برنج معمولاً نسبتاً ایستاده
Hotspot	-	۰/۰۱-۰/۱	۰/۰۱-۰/۱	۰/۰۱-۰/۱	وابسته به ساختار سایه‌ها
TTS	درجه	۲۰-۵۰	۲۰-۵۰	۲۰-۵۰	بسته به زمان تصویربرداری
TTO	درجه	۰-۲۰	۰-۲۰	۰-۲۰	برای داده‌های نادیر پهنای معمولاً صفر است
PSI	درجه	۰	۰	۰	برای پهنای معمولاً صفر در نظر گرفته می‌شود
بازتاب خاک	-	کم	بسیار کم	کم تا متوسط	چون زمین برنجی معمولاً غرقاب است

مرحله هفتم: استخراج نقشه پارامترهای گیاهی و

تفسیر اکولوژیک

در این مرحله، نتایج وارون‌سازی مدل برای تمامی پیکسل‌ها به نقشه‌های فضایی از پارامترهای گیاهی مانند نقشه Cab، LAI، CCC و CNC تبدیل شدند. این نقشه‌ها برای هر یک از تاریخ‌های برداشت داده‌ها به‌صورت مجزا تولید گردیدند، به‌گونه‌ای که برای هر بازه زمانی، مجموعه‌ای کامل از نقشه‌های پارامترهای زیستی به‌دست آمد. این خروجی‌ها امکان بررسی و مقایسه وضعیت پوشش گیاهی در مقاطع مختلف زمانی را فراهم ساختند. این نقشه‌ها به‌منظور تحلیل اکولوژیک، شناسایی تنش‌های زیستی، پایش روندهای فصلی رشد گیاه و مدیریت بهینه منابع گیاهی مورد استفاده قرار گرفتند و پایه‌ای برای تصمیم‌گیری‌های مکانی-زمانی دقیق در مدیریت پوشش گیاهی فراهم کردند.

۳- نتایج

در بخش حاضر، نتایج حاصل از پیاده‌سازی مراحل تحقیق ارائه و تحلیل می‌شوند. بدین منظور، ابتدا شاخص‌های طیفی منتخب در سه بازه زمانی مختلف رشد گیاه محاسبه و روند تغییرات آن‌ها بررسی می‌شود. در ادامه، خروجی مدل PROSAIL برای برآورد پارامترهای کلیدی گیاهی از جمله شاخص سطح برگ (LAI)، محتوای کلروفیل برگ (Cab) و آب برگ (Cw) استخراج و میزان دقت آن‌ها با بهره‌گیری از نمونه‌های میدانی برداشت شده و معیارهای آماری مناسب ارزیابی می‌گردد. در پایان نیز، با هدف مقایسه قابلیت‌ها، نتایج شاخص‌های طیفی و مدل‌سازی PROSAIL در کنار یکدیگر تحلیل شده و توانمندی‌ها و محدودیت‌های هر رویکرد مورد بحث قرار خواهد گرفت.


۳-۱- نتایج شاخص‌های طیفی مستخرج

در این بخش، نتایج حاصل از استخراج شاخص‌های طیفی از تصاویر پهنای مجهز به سنجنده‌ی چندطیفی Sequoia در سه مقطع زمانی مختلف از دوره‌ی رشد گیاه برنج ارائه می‌گردد. هدف از محاسبه‌ی این شاخص‌ها، پایش تغییرات مکانی-زمانی پوشش گیاهی و فراهم‌سازی بستری برای برآورد غیرمستقیم پارامترهای کلیدی گیاه مانند شاخص سطح برگ (LAI)، محتوای کلروفیل (Cab)، کاروتنوئیدها (Car) و آب برگ (Cw) است.

شاخص‌های استخراج‌شده از داده‌های سنجنده‌ی Sequoia شامل NDVI، NDRE، MCARI، LCI، GNDVI و SIPI2 هستند که هر یک بیانگر جنبه‌ای خاص از ویژگی‌های فیزیولوژیکی و ساختاری گیاه می‌باشند. برای مثال، شاخص‌های NDVI و GNDVI مستقیماً با میزان سبزی‌نگی و تراکم کلروفیل برگ در ارتباط بوده و معمولاً به‌عنوان شاخص‌های اصلی رشد و سلامت گیاه مورد استفاده قرار می‌گیرند. شاخص LCI با بهره‌گیری از باند لبه قرمز، حساسیت بالایی به تغییرات محتوای کلروفیل در شرایط تراکم بالای پوشش گیاهی دارد، در حالی که MCARI با کاهش اثر پس‌زمینه‌ی خاک، تمرکز بیشتری بر تغییرات رنگی‌ها دارد. از سوی دیگر، شاخص NDRE به دلیل استفاده از باندهای لبه قرمز و مادون قرمز نزدیک، عملکرد مناسبی در آشکارسازی تغییرات کلروفیل در مراحل میانی و پایانی رشد گیاه نشان می‌دهد. همچنین، شاخص NDWI نسبت به تغییرات محتوای آب برگ حساس بوده و اطلاعاتی در خصوص وضعیت آبی گیاه ارائه می‌کند. در نهایت، شاخص SIPI2 با بهره‌گیری از روابط طیفی در محدوده‌ی آبی و قرمز، نسبت کاروتنوئید به کلروفیل را منعکس کرده و می‌تواند نشانه‌ای از بروز تنش‌های نوری یا فیزیولوژیکی در گیاه باشد.


بررسی روند تغییرات این شاخص‌ها در سه مرحله‌ی فنولوژیکی انتخاب‌شده، تصویری جامع از وضعیت رشد و سلامت گیاه برنج ارائه می‌دهد. این تغییرات نه تنها الگوهای مکانی و زمانی سبزی‌نگی و وضعیت فیزیولوژیکی گیاه را نشان می‌دهند، بلکه مبنای معتبری برای برآورد پارامترهای بیوفیزیکی از طریق مدل‌های شبیه‌سازی و معکوس‌سازی نظیر PROSAIL فراهم می‌سازند. در واقع، تنوع شاخص‌های انتخاب‌شده موجب می‌شود که وضعیت گیاه از جنبه‌های مختلف مورد تحلیل قرار گیرد و محدودیت‌های ناشی از تکیه

بر یک شاخص منفرد کاهش یابد. نتایج حاصل از شاخص‌های طیفی استخراج‌شده از تصاویر سنجنده‌ی Sequoia به‌ترتیب در شکل (۷) برای زمان اول، در شکل (۸) برای زمان دوم و در شکل (۹) برای زمان سوم ارائه شده‌اند.



شکل ۷- شاخص‌های طیفی مستخرج از پهنای سکویا (a-g) در زمان مشاهداتی اول

همان‌گونه که مشاهده می‌شود، تغییرات شاخص‌ها در سه بازه زمانی انتخاب‌شده بیانگر روند تکاملی رشد گیاه برنج بوده و می‌تواند اطلاعات ارزشمندی پیرامون وضعیت سبزی‌نگی، محتوای رنگی‌ها، تراکم پوشش و محتوای آب گیاه ارائه دهد.




شکل ۸- شاخص‌های طیفی مستخرج از پهنای سکویا (a-g) در زمان مشاهداتی دوم

در زمان اول (مرحله استقرار و آغاز رشد گیاه)، شاخص‌هایی مانند NDVI و GNDVI مقادیر نسبتاً پایین‌تری داشته‌اند که بیانگر تراکم پایین پوشش گیاهی و غلبه اثر پس‌زمینه خاک است. از سوی دیگر، مقادیر نسبتاً

بالای NDWI در این مرحله نشان دهنده وجود آب کافی در بستر کشت و شرایط غرقابی اولیه است که برای کشت برنج رایج می باشد.

در زمان دوم (مرحله رشد رویشی و حداکثر توسعه پوشش گیاهی)، بیشترین تغییرات مثبت در شاخص های مرتبط با کلروفیل، از جمله NDRE، LCI و MCARI مشاهده می شود. این شاخص ها با استفاده از باندهای لبه قرمز حساسیت بالایی به افزایش غلظت کلروفیل و تراکم برگ نشان داده و بنابراین به خوبی وضعیت سبزیگی و سلامت گیاه را در اوج رشد گیاهی توصیف می کنند. شاخص NDVI نیز در این مرحله به مقادیر نزدیک به اشباع رسیده است که مطابق انتظار در پوشش های متراکم گیاهی رخ می دهد. در همین زمان، شاخص SIPI2 مقادیر پایین تری نسبت به مرحله قبل ثبت کرده که می تواند بیانگر نسبت بالاتر کلروفیل به کاروتنوئید و در نتیجه سلامت فیزیولوژیکی مناسب گیاه باشد.



شکل ۹- شاخص های طیفی مستخرج از پهپاد سکویا (a-g) در زمان مشاهداتی سوم

در زمان سوم (مرحله زایشی و آغاز رسیدگی)، کاهش تدریجی مقادیر NDVI و GNDVI مشاهده می شود که ناشی از کاهش سبزیگی و شروع فرایند پیری برگ ها است. شاخص های NDRE و LCI نیز روند کاهشی داشته اند و این موضوع مؤید کاهش تدریجی غلظت کلروفیل در برگ ها می باشد. در مقابل، شاخص SIPI2 نسبت به مراحل قبلی افزایش یافته است که نشان دهنده افزایش نسبی کاروتنوئیدها در مقایسه با کلروفیل و در نتیجه بروز استرس فیزیولوژیکی و آغاز فرایند زردشدگی برگ ها است. از سوی دیگر، NDWI

نیز روند نزولی را نشان می دهد که ناشی از کاهش محتوای آب برگ ها و تغییر شرایط آبیاری در انتهای دوره رشد است. به طور کلی، تغییرات شاخص های طیفی در سه مقطع زمانی بیانگر همخوانی منطقی با مراحل فنولوژیکی گیاه برنج است؛ به گونه ای که در مرحله اول مقادیر پایین شاخص های سبزیگی مشاهده شد که ناشی از غالب بودن اثر خاک است. در مرحله دوم، افزایش چشمگیر شاخص های کلروفیل و رسیدن NDVI به مقادیر اشباع نشانگر بیشینه رشد و توسعه کامل پوشش گیاهی بود. در مرحله سوم، روند کاهشی شاخص های کلروفیل و سبزیگی همراه با افزایش SIPI2 و کاهش NDWI مشاهده شد که بیانگر آغاز فرایند پیری و کاهش محتوای آب گیاه است. این نتایج تأیید می کند که شاخص های طیفی، به ویژه شاخص های مبتنی بر باند قرمز لبه (مانند NDRE و LCI) و شاخص های مرتبط با نسبت رنگینها (مانند SIPI2)، از توان بالایی در تشخیص تغییرات فیزیولوژیکی گیاه برنج در طول فصل رشد برخوردار بوده و می توانند به عنوان ورودی های ارزشمند در مدل سازی پارامترهای بیوفیزیکی در مراحل بعدی استفاده شوند.


انتخاب شاخص های طیفی شامل NDVI، GNDVI، NDRE، MCAIR، SIPI2 و LCI بر اساس گزارش های متعدد در ادبیات تحقیق انجام شد که این شاخص ها را به عنوان شاخص های حساس نسبت به تغییرات Pigment، ساختار تاج پوشش و وضعیت فیزیولوژیک گیاه معرفی کرده اند. در این پژوهش، هدف اصلی از به کارگیری این شاخص ها تقویت تحلیل روندهای فنولوژیکی برنج و فراهم کردن مبنایی برای مقایسه با خروجی مدل PROSAIL بوده است. لازم به ذکر است که تحلیل حساسیت اختصاصی با هدف رتبه بندی یا انتخاب شاخص ها انجام نشده و انتخاب آنها بر پایه شواهد تجربی و گزارش های معتبر پیشین صورت گرفته است.

از آنجا که شاخص های طیفی تنها تخمینی نسبی از وضعیت گیاه فراهم می کنند، استفاده از آنها به عنوان داده های کمکی در کنار مدل سازی فیزیکی (PROSAIL) نه تنها موجب افزایش دقت تخمین پارامترهای گیاهی می شود، بلکه امکان ارزیابی اعتبار نتایج مدل سازی را نیز فراهم می سازد. بنابراین، نتایج ارائه شده در این بخش مقدمه ای برای بخش بعدی است که به تحلیل و برآورد مستقیم پارامترهای بیوفیزیکی با بهره گیری از مدل PROSAIL اختصاص دارد.

۳-۲- نتایج تخمین پارامترهای گیاهی

۳-۲-۱- نتایج وارون سازی مدل PROSAIL


نتایج حاصل از وارون سازی مدل PROSAIL برای شش پارامتر بیوفیزیکی Cab، Car، Cm، Cw، LAI و N در سه مقطع زمانی به ترتیب در شکل های ۱۰، ۱۱، ۱۲ ارائه شده است. این نتایج نشان دهنده روندی منطقی و هماهنگ با مراحل فنولوژیکی گیاه برنج است. در زمان اول که مربوط به مرحله استقرار و آغاز رشد است، مقادیر LAI و Cab پایین بوده و اثر خاک و آب پس زمینه در سیگنال طیفی غالب است، در حالی که Cw به دلیل شرایط مرطوب مزرعه مقدار نسبتاً بالایی دارد. همچنین، مقادیر Car در زمان اول پایین است، اما در زمان دوم با رشد فعال گیاه کمی افزایش پیدا می کند و نقش حفاظتی در برابر تنش های نوری دارد. در زمان سوم، برخلاف کاهش کلروفیل، کاروتنوئیدها نسبی افزایش بیشتری نشان می دهند؛ زیرا در این مرحله کاروتنوئیدها به عنوان رنگیزه های غالب باقی می مانند و در فرآیند پیری برگ ها اهمیت بیشتری پیدا می کنند. این تغییرات با شاخص هایی نظیر SIPI2 همسو است که در مراحل پایانی فصل افزایش می یابد.



شکل ۱۰- نتایج حاصل از تخمین پارامترهای گیاهی برای زمان اول

در رابطه با ماده خشک برگ، در مرحله اول مقدار Cm پایین است و برگ ها هنوز بافت کامل و ضخیم ندارند. در مرحله دوم، با توسعه سطح برگ و افزایش زیست توده، مقدار Cm افزایش می یابد. در مرحله سوم نیز برخلاف کاهش کلروفیل، Cm روند افزایشی بیشتری نشان می دهد؛ زیرا در فرآیند پیری، محتوای خشک برگ ها بیشتر شده و بافت های غیرفعال جایگزین بخش زنده می شوند. این روند یکی از ویژگی های کلیدی در شناسایی مراحل رسیدگی برنج است. همانطور که در شکل ۱۰ مشاهده می شود، در زمان اول،

مقدار Cab پایین است که نشان دهنده استقرار اولیه گیاه و غالب بودن اثر خاک و آب پس زمینه است. با ورود به مرحله دوم و اوج رشد رویشی، مقدار Cab به طور چشمگیری افزایش یافته و به بیشترین سطح خود می رسد؛ این تغییر همزمان با افزایش NDVI و NDRE مشاهده می شود و بیانگر فعالیت فتوسنتزی بالا و تراکم سبزینه است.




شکل ۱۱- نتایج حاصل از تخمین پارامترهای گیاهی برای زمان دوم

در زمان سوم، با شروع پیری برگ ها، Cab روند کاهشی دارد که ناشی از تجزیه کلروفیل و تغییر رنگ برگ ها به زرد است. در زمان دوم که همزمان با اوج رشد رویشی است، بیشترین مقادیر LAI و Cab به دست آمد و تاج پوشش گیاهی به حالت یکنواخت و مترکم رسید؛ به علاوه، Cw نیز در این مرحله تا حدودی بالا باقی ماند و شاخص های مرتبط با کلروفیل (مانند NDRE و LCI) از نظر بصری بیشترین همبستگی را با نتایج مدل نشان دادند.

در زمان سوم، که مرحله رسیدگی و آغاز پیری گیاه را بازتاب می دهد، کاهش تدریجی LAI، Cab و Cw مشهود بود، در حالی که Cm به دلیل افزایش ماده خشک برگ روندی افزایشی داشت. همچنین، Car در این مرحله نسبت به میانه فصل افزایش نسبی نشان داد که همسو با بالا رفتن مقدار SIPI2 و کاهش NDWI تفسیر می شود. پارامتر N تغییرات ملایم تری نسبت به سایر متغیرها داشت و در طول فصل تنها نوسانات اندکی نشان داد. به طور کلی، نتایج PROSAIL هم از نظر زمانی و هم مکانی با نقشه های شاخص های طیفی سازگاری بالایی داشت و توانست الگوی رشد، شادابی و پیری گیاه برنج را به خوبی بازتاب دهد. در مجموع، این تحلیل پارامتریک نشان می دهد که هر یک از متغیرهای PROSAIL روندی منطبق با مراحل فنولوژیکی گیاه برنج دارند و به ویژه Cab، LAI و Cw بهترین شاخص ها برای تشخیص مراحل رشد و پیری گیاه محسوب می شوند. این امر بیانگر آن است که استفاده از مدل سازی فیزیکی PROSAIL در کنار شاخص های

در زمان اول (T1) و بیشترین خطا در مراحل دوم (T2) و انتهای (T3) فصل مشاهده می‌شود.




شکل ۱۳- نقشه RMSE مدل PROSAIL در سه مقطع زمانی مختلف.

۴- بحث

عملکرد مدل پیشنهادی برای تخمین پارامترهای زیست‌فیزیکی گیاهی با استفاده از داده‌های چندطیفی پهنای در سه بازه زمانی متفاوت مورد بررسی قرار گرفت (شکل‌های ۱۵، ۱۶ و ۱۷). پارامترهای مورد ارزیابی شامل کلروفیل برگ (Cab)، کاروتنوئید (Car)، محتوای مواد معدنی (Cm)، محتوای آب (Cw)، شاخص سطح برگ (LAI) و شاخص نیتروژن (N) بودند که هر یک نقش حیاتی در ارزیابی سلامت و رشد گیاهان دارند. نتایج ارزیابی پارامترها با داده‌های میدانی در شکل ۱۴ ارائه شده‌است.


نتایج حاصل از مدل در هر سه زمان نشان داد که رویکرد مورد استفاده قادر است تخمین‌های مناسبی از این پارامترها ارائه دهد و همبستگی قابل توجهی بین مقادیر پیش‌بینی شده و مقادیر واقعی در زمان‌های مختلف از دوره رشد مشاهده شد (شکل‌های مربوط به زمان اول، دوم و سوم).



شکل ۱۴- ارزیابی پارامترهای محاسبه شده با برداشت میدانی

در زمان نخست، مدل بهترین عملکرد خود را به نمایش گذاشت؛ به گونه‌ای که مقدار ضریب تعیین (R^2) برای اغلب

طیفی می‌تواند ابزاری کارآمد برای پایش دقیق تغییرات فیزیولوژیکی و زیستی گیاه در طول فصل رشد باشد. لازم به ذکر است، با توجه به امکان ایجاد بازتاب‌های مشابه توسط ترکیب‌های مختلف پارامترهای (non-PROSAIL uniqueness)، دامنه پارامترها بر اساس داده‌های میدانی و محدوده‌های فیزیولوژیک معتبر محدود شد تا میزان هم‌ریختی پارامترها کاهش یابد و LUT واقع‌گرایانه‌تری تولید شود.




شکل ۱۵- نتایج حاصل از تخمین پارامترهای گیاهی برای زمان سوم

نقشه‌های خطای برازش (RMSE) حاصل از شبیه‌سازی مدل PROSAIL در سه مقطع زمانی (شکل ۱۳) بیانگر عملکرد و تغییرات دقت برآورد در طول فصل رشد گیاه برنج هستند. در زمان اول (T1)، مقادیر RMSE به‌ویژه در بخش‌های پیرامونی مزرعه نسبتاً پایین و همگن بودند که علت آن را می‌توان به پوشش ضعیف گیاه، غلبه اثر پس‌زمینه خاک و وجود آب آزاد در بستر کشت نسبت داد.

این شرایط باعث افزایش انطباق طیف اندازه‌گیری‌شده با طیف شبیه‌سازی‌شده شد. در زمان دوم (T2)، هم‌زمان با افزایش سطح برگ و تراکم تاج‌پوشش، مقادیر RMSE کاهش قابل توجهی یافتند و توزیع خطا در سطح مزرعه یکنواخت‌تر شد. این مرحله که اوج رشد و توسعه فنولوژیکی گیاه است، نشان داد که مدل PROSAIL توانایی مطلوبی در بازتولید رفتار طیفی برنج را در این مقطع دارد. در زمان سوم (T3)، مقادیر RMSE مجدداً افزایش یافتند و ناهمگنی فضایی قابل توجهی در نقشه خطا مشاهده نمی‌شود. این امر احتمالاً ناشی از آغاز فرآیند پیری گیاه، زردشدگی برگ‌ها، کاهش آب برگ و ناهمگونی در الگوهای بازتاب طیفی بود که باعث کاهش دقت برازش مدل شده‌است. بنابراین، تحلیل خطای برازش نشان می‌دهد که دقت مدل PROSAIL تحت تأثیر مراحل فنولوژیکی گیاه قرار دارد؛ به‌طوری‌که بالاترین انطباق طیفی

پارامترها بیش از ۰/۹۸ بود و RMSE نیز در حداقل مقدار خود قرار داشت. این موضوع نشان‌دهنده دقت بالا و قابلیت مدل در تخمین پارامترهای زیست‌فیزیکی تحت شرایط پهنه است. به ویژه پارامترهای کلروفیل برگ و محتوای آب که از حساسیت بالایی برخوردار هستند، با دقت بسیار خوبی شناسایی شدند که می‌تواند به تحلیل دقیق‌تری از وضعیت فیزیولوژیکی گیاهان منجر شود (شکل ۱۴).

با گذشت زمان و ورود به بازه‌های زمانی دوم و سوم، کاهش نسبی در دقت تخمین‌ها مشاهده گردید. این کاهش را می‌توان ناشی از عوامل مختلفی دانست، از جمله تغییرات شرایط محیطی، نوسانات نوری و آب و هوایی و همچنین تغییرات فیزیولوژیکی گیاه که باعث پیچیدگی بیشتر در فرایند تخمین می‌شود. به طور مشخص، برای پارامتری مانند کلروفیل برگ (Cab)، مقدار R^2 ثابت بوده و RMSE افزایش یافته است که نشان‌دهنده نیاز به بهبود مدل یا به‌کارگیری داده‌های تکمیلی برای حفظ دقت تخمین‌ها در شرایط غیرایده‌آل است.



شکل ۱۵- نمودار پراکندگی تخمین‌های مدل پیشنهادی در زمان اول برای پارامترهای زیست‌فیزیکی (Cab)، (Car)، (Cm)، (Cw)، (LAI) و (N). هر نقطه نمایانگر مقدار پیش‌بینی شده مدل در مقابل مقدار واقعی اندازه‌گیری شده‌است. خط قطری نشان‌دهنده تطابق کامل پیش‌بینی با مقادیر واقعی است.

نتایج نشان می‌دهد که بازه پارامترهای مورد استفاده در مدل‌سازی PROSAIL بر اساس ویژگی‌های فیزیولوژیکی و فنولوژیکی یک رقم مشخص برنج تعریف شده‌است و به همین دلیل، بازتاب‌دهنده رفتار طیفی و ساختاری همین رقم در شرایط واقعی مزرعه می‌باشد. از این رو دقت برآوردهای مدل عمدتاً برای این محصول، این رقم و شرایط اقلیمی-کشاورزی حاکم بر منطقه مطالعه معتبر است. با توجه به حساسیت بالای شبیه‌سازی و وارون‌سازی PROSAIL نسبت به دامنه انتخابی پارامترها، تعمیم نتایج به سایر محصولات، ارقام

متفاوت برنج یا شرایط مدیریتی و محیطی دیگر باید با احتیاط صورت گیرد و مستلزم ارزیابی‌های تکمیلی در مقیاس‌های مکانی و ژنتیکی گسترده‌تر است.

با این وجود، پوشش مکانی نسبتاً وسیع منطقه مطالعه (حدود ۵۰ هکتار) و جمع‌آوری حدود ۲۰۰ نمونه میدانی در سه مرحله فنولوژیکی، موجب شده‌است که تغییرپذیری طیفی و فیزیولوژیکی مشاهده‌شده دامنه گسترده‌ای از شرایط واقعی مزرعه را شامل شود. بنابراین می‌توان انتظار داشت که نتایج مدل‌سازی PROSAIL در این پژوهش، قابلیت تعمیم مناسبی به سایر مزارع برنج دارای شرایط اقلیمی مشابه و الگوهای مدیریتی نزدیک داشته باشد.

از سوی دیگر، پارامترهایی مانند کاروتنوئید (Car) و محتوای مواد معدنی (Cm) نسبت به تغییرات زمانی مقاوم‌تر ظاهر شدند و نوسانات کمتری در دقت تخمین‌های آن‌ها دیده شد. این مسئله بیانگر پایداری بیشتر این شاخص‌ها در طول زمان و قابلیت استفاده آن‌ها به عنوان معیارهای قابل اتکا در تحلیل‌های بلندمدت است. علاوه بر این، نتایج نشان داد که استفاده از تصاویر چندطیفی پهباد به عنوان داده ورودی، مزایای قابل توجهی از نظر دقت و پوشش مکانی فراهم می‌آورد که در مقایسه با روش‌های سنتی برداشت داده‌های زمینی، مزیت‌های عملی و اقتصادی زیادی دارد.

در نهایت، یافته‌های این مطالعه بر اهمیت به‌روزرسانی مستمر مدل‌ها و استفاده از داده‌های چندزمانه برای افزایش دقت تخمین پارامترهای زیست‌فیزیکی تأکید دارد. این امر می‌تواند به توسعه سامانه‌های هوشمند کشاورزی و بهبود تصمیم‌گیری‌های مدیریتی در حوزه کشاورزی دقیق منجر شود. بنابراین، پژوهش‌های آینده می‌توانند بر تلفیق داده‌های چندمنبع و استفاده از الگوریتم‌های یادگیری عمیق تمرکز کنند تا مدل‌های پیش‌بینی با قابلیت تعمیم‌پذیری بالاتر و مقاومت بیشتر در برابر شرایط مختلف محیطی ارائه شوند.


در مجموع الگوهای رابطه‌ای در شکل‌های ۱۵ تا ۱۷ نشان می‌دهد شاخص‌های مبتنی بر لبه قرمز به‌ویژه NDRE و LCI همبستگی قوی‌تری با Cab و LAI، نسبت به شاخص‌های کلاسیک مانند NDVI دارند؛ شیب نزدیک ۱ و عرض از مبدأ کوچک در برآوردهای رگرسیونی گواه نبود سوگیری و پایداری برآوردهاست، و کاهش خطا را همگام با پیشروی فنولوژیک نشان می‌دهد. این نتیجه با حساسیت فیزیکی باندهای لبه قرمز و کاهش اشباع در پوشش‌های انبوه سازگار است [۱۴، ۱۹، ۳۹]. هم‌خوانی نتایج وارون‌سازی PROSAIL

با اندازه‌گیری‌های میدانی و کارایی رویکرد LUT نیز گزارش‌های پیشین را تأیید می‌کند [۳۰، ۵۵، ۵۶].


۵- نتیجه‌گیری

در این پژوهش، کارایی تصاویر چندطیفی پهنپای با قدرت تفکیک مکانی بالا، در چارچوب فتوگرامتری و وارون‌سازی مدل انتقال تابش PROSAIL، برای برآورد پارامترهای بیوفیزیکی و بیوشیمیایی برنج ارزیابی شد. با اتکا به شاخص‌های حساس به لبه قرمز) از جمله NDRE و LCI و اجرای وارون‌سازی مبتنی بر LUT بر روی داده‌های سنجنده Sequoia در سه مقطع فنولوژیک، تخمین‌های حاصل برای LAI، Cab، Cw، Cm و N با دقت پژوهش‌پسند به‌دست آمد و روندهای زمانی-مکانی رشد به‌درستی بازتاب داده شد؛ دقت برآورد در مراحل ابتدایی رشد بالاتر ارزیابی شد و با پیچیده‌تر شدن ساختار سایه‌بان در انتهای دوره، افتی ملایم مشاهده شد. بدین‌ترتیب، اتکای هم‌زمان به هندسه دقیق فتوگرامتری، اطلاعات طیفی چندباند و مدل‌سازی فیزیکی، به‌عنوان یک چارچوب عملیاتی برای نقشه‌برداری مزرعای و پشتیبانی تصمیم در کشاورزی دقیق تأیید شد.

با وجود این، تعمیم‌پذیری نتایج به‌دلیل محدوده مکانی-زمانی محدود نمونه‌برداری و مفروضات ذاتی مدل، نیازمند آزمون‌های گسترده‌تر ارزیابی شد. برای پژوهش‌های آتی، گسترش مطالعه به اقلیم‌ها و نظام‌های زراعی متنوع، افزایش تراکم زمانی تصویربرداری، همسوسازی داده‌های پهنپای با اندازه‌گیری‌های زمینی و بهره‌گیری از رهیافت‌های ترکیبی فیزیکی-یادگیری ماشین به‌منظور کاهش خطا و ارتقای پایداری توصیه می‌شود. بررسی‌های اقتصادی-عملیاتی در مقیاس‌های بزرگ نیز برای سنجش امکان استقرار پایش‌های روتین مبتنی بر پهپاد پیشنهاد می‌شود.



شکل ۱۶- نمودار پراکندگی تخمین‌های مدل پیشنهادی در زمان دوم برای پارامترهای زیست‌فیزیکی (Cm)، (Cab)، (Cw)، (LAI) و (N). هر نقطه نمایانگر مقدار پیش‌بینی شده مدل در مقابل مقدار واقعی اندازه‌گیری شده است. خط قطری نشان‌دهنده تطابق کامل پیش‌بینی با مقادیر واقعی است.



شکل ۱۷- نمودار پراکندگی تخمین‌های مدل پیشنهادی در زمان سوم برای پارامترهای زیست‌فیزیکی (Cm)، (Cab)، (Cw)، (LAI) و (N). هر نقطه نمایانگر مقدار پیش‌بینی شده مدل در مقابل مقدار واقعی اندازه‌گیری شده است. خط قطری نشان‌دهنده تطابق کامل پیش‌بینی با مقادیر واقعی است.

ثبات رادیومتریکی سامانه Sequoia نیز کیفیت روابط مشاهده‌شده را پشتیبانی می‌کند. افزون بر این، هم‌سویی با

منابع

1. Khanal, S., et al., *Remote sensing in agriculture—accomplishments, limitations, and opportunities*. Remote sensing, 2020. 12(22): p. 3783.
2. Gitelson, A.A., *15 remote sensing estimation of crop biophysical characteristics at various scales*. Hyperspectral Remote Sens. Veget., 2016. 20: p. 329.
3. Aasen, H., et al., *Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: a review of sensor technology, measurement procedures, and data correction workflows*. Remote Sensing, 2018. 10(7): p. 1091.
4. Manfreda, S., et al., *On the use of unmanned aerial systems for environmental monitoring*. Remote sensing, 2018. 10(4): p. 641.

5. Adão, T., et al., *Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry*. Remote sensing, 2017. **9**(11): p. 1110.
6. Kumar, S., et al., *Remote sensing for agriculture and resource management*, in *Natural Resources Conservation and Advances for Sustainability*. 2022, Elsevier. p. 91-135.
7. Roy, D.P., et al., *Landsat-8: Science and product vision for terrestrial global change research*. Remote sensing of Environment, 2014. **145**: p. 154-172.
8. Fisher, A.G., et al., *Remote sensing of trophic cascades: multi-temporal landsat imagery reveals vegetation change driven by the removal of an apex predator*. Landscape Ecology, 2021. **36**: p. 1341-1358.
9. Mohanasundaram, S., et al., *Reconstructing NDVI and land surface temperature for cloud cover pixels of Landsat-8 images for assessing vegetation health index in the Northeast region of Thailand*. Environmental monitoring and assessment, 2023. **195**(1): p. 211.
10. Kang, Y., et al., *A data-driven approach to estimate leaf area index for Landsat images over the contiguous US*. Remote Sensing of Environment, 2021. **258**: p. 112383.
11. Huang, S., et al., *A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing*. Journal of Forestry Research, 2021. **32**(1): p. 1-6.
12. Kanning, M., et al., *High-resolution UAV-based hyperspectral imagery for LAI and chlorophyll estimations from wheat for yield prediction*. Remote Sensing, 2018. **10**(12): p. 2000.
13. Pan, Z., et al., *Developing an Uncrewed Aerial Vehicle (UAV)-Based Prediction Model for the Rice Harvest Index Using Machine Learning*. Agriculture, 2025. **15**(9): p. 971.
14. Clevers, J.G.P.W. and A.A. Gitelson, *Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3*. International Journal of Applied Earth Observation and Geoinformation, 2013. **23**: p. 344-351.
15. Drusch, M., et al., *Sentinel-2: ESA's optical high-resolution mission for GMES operational services*. Remote sensing of Environment, 2012. **120**: p. 25-36.
16. Liang, S., *Quantitative remote sensing of land surfaces*. 2005: John Wiley & Sons.
17. Hunt Jr, E.R. and C.S. Daughtry, *What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture?* International journal of remote sensing, 2018. **39**(15-16): p. 5345-5376.
18. Loudjani, P., *Precision Agriculture: An Opportunity for EU-Farmers—Potential Support with the CAP 2014-2020*. 2014.
19. Haboudane, D., et al., *Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture*. Remote sensing of environment, 2004. **90**(3): p. 337-352.
20. Deng, L., et al., *UAV-based multispectral remote sensing for precision agriculture: A comparison between different cameras*. ISPRS journal of photogrammetry and remote sensing, 2018. **146**: p. 124-136.
21. Kopačková-Strnadová, V., et al., *Canopy top, height and photosynthetic pigment estimation using parrot sequoia multispectral imagery and the unmanned aerial vehicle (UAV)*. Remote Sensing, 2021. **13**(4): p. 705.
22. Peng, Y., et al., *Remote estimation of gross primary production in maize and support for a new paradigm based on total crop chlorophyll content*. Remote Sensing of Environment, 2011. **115**(4): p. 978-989.
23. Ustin, S.L., et al., *Retrieval of foliar information about plant pigment systems from high resolution spectroscopy*. Remote Sensing of Environment, 2009. **113**: p. S67-S77.
24. Elia, A. and G. Conversa, *Agronomic and physiological responses of a tomato crop to nitrogen input*. European Journal of Agronomy, 2012. **40**: p. 64-74.
25. Verrelst, J., et al., *SCOPE-based emulators for fast generation of synthetic canopy reflectance and sun-induced fluorescence spectra*. Remote Sensing, 2017. **9**(9): p. 927.
26. Mohammadi, A., J.F. Costelloe, and D. Ryu, *Application of time series of remotely sensed normalized difference water, vegetation and moisture indices in characterizing flood dynamics of large-scale arid zone floodplains*. Remote sensing of environment, 2017. **190**: p. 70-82.
27. Zheng, H., et al., *Combining unmanned aerial vehicle (UAV)-based multispectral imagery and ground-based hyperspectral*

- data for plant nitrogen concentration estimation in rice*. *Frontiers in plant science*, 2018. **9**: p. 936.
28. Awais, M., et al., *UAV-based remote sensing in plant stress image using high-resolution thermal sensor for digital agriculture practices: A meta-review*. *International Journal of Environmental Science and Technology*, 2022: p. 1-18.
 29. Hu, Z., et al., *Estimating Stratified Biomass in Cotton Fields Using UAV Multispectral Remote Sensing and Machine Learning*. *Drones*, 2025. **9**(3): p. 186.
 30. Jacquemoud, S. and F. Baret, *PROSPECT: A model of leaf optical properties spectra*. *Remote sensing of environment*, 1990. **34**(2): p. 75-91.
 31. Verhoef, W., *Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model*. *Remote sensing of environment*, 1984. **16**(2): p. 125-141.
 32. Rivera, J.P., et al., *Multiple cost functions and regularization options for improved retrieval of leaf chlorophyll content and LAI through inversion of the PROSAIL model*. *Remote Sensing*, 2013. **5**(7): p. 3280-3304.
 33. Verrelst, J., et al., *Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties—A review*. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015. **108**: p. 273-290.
 34. Li, W., et al., *Mapping crop leaf area index and canopy chlorophyll content using UAV multispectral imagery: Impacts of illuminations and distribution of input variables*. *Remote sensing*, 2023. **15**(6): p. 1539.
 35. Sharma, H., H. Sidhu, and A. Bhowmik, *Remote Sensing Using Unmanned Aerial Vehicles for Water Stress Detection: A Review Focusing on Specialty Crops*. *Drones*, 2025. **9**(4): p. 241.
 36. Zarco-Tejada, P.J., et al., *Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy*. *Remote sensing of environment*, 2005. **99**(3): p. 271-287.
 37. Ji, J., et al., *Synchronous retrieval of wheat Cab and LAI from UAV remote sensing: application of the optimized estimation inversion framework*. *Agronomy*, 2024. **14**(2): p. 359.
 38. Marschner, H., *Marschner's mineral nutrition of higher plants*. 2012: Academic press.
 39. Delegido, J., et al., *A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems*. *European Journal of Agronomy*, 2013. **46**: p. 42-52.
 40. Clevers, J.G. and A.A. Gitelson, *Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and-3*. *International Journal of Applied Earth Observation and Geoinformation*, 2013. **23**: p. 344-351.
 41. Kurbanov, R. and N. Zakharova. *Justification and selection of vegetation indices to determine the early soybeans readiness for harvesting*. in *E3S Web of Conferences*. 2021. EDP Sciences.
 42. Chen, X., et al., *Estimation of winter wheat plant nitrogen concentration from UAV hyperspectral remote sensing combined with machine learning methods*. *Remote Sensing*, 2023. **15**(11): p. 2831.
 43. Huete, A.R., *A soil-adjusted vegetation index (SAVI)*. *Remote sensing of environment*, 1988. **25**(3): p. 295-309.
 44. Fensholt, R., I. Sandholt, and M.S. Rasmussen, *Evaluation of MODIS LAI, fAPAR and the relation between fAPAR and NDVI in a semi-arid environment using in situ measurements*. *Remote sensing of Environment*, 2004. **91**(3-4): p. 490-507.
 45. Johnson, L.F., *Temporal stability of an NDVI-LAI relationship in a Napa Valley vineyard*. *Australian Journal of grape and wine research*, 2003. **9**(2): p. 96-101.
 46. Steltzer, H. and J.M. Welker, *Modeling the effect of photosynthetic vegetation properties on the NDVI-LAI relationship*. *Ecology*, 2006. **87**(11): p. 2765-2772.
 47. Xiaoqin, W., et al., *Extraction of vegetation information from visible unmanned aerial vehicle images*. *Transactions of the Chinese Society of Agricultural Engineering*, 2015. **31**(5).
 48. Xue, J. and B. Su, *Significant remote sensing vegetation indices: A review of developments and applications*. *Journal of sensors*, 2017. **2017**(1): p. 1353691.
 49. Rouse Jr, J., et al. *Paper a 20*. in *Third earth resources technology satellite-1 symposium: The proceedings of a symposium held by Goddard space flight center at Washington, DC on*. 1973.
 50. Zhai, W., et al., *Exploring multisource feature fusion and stacking ensemble learning for accurate estimation of maize*

chlorophyll content using unmanned aerial vehicle remote sensing. Remote Sensing, 2023. **15**(13): p. 3454.

51. Zarco-Tejada, P.J., V. González-Dugo, and J.A. Berni, *Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera*. Remote sensing of environment, 2012. **117**: p. 322-337.
52. Gitelson, A.A., et al., *Remote estimation of canopy chlorophyll content in crops*. Geophysical research letters, 2005. **32**(8).
53. Bhadra, S., et al., *PROSAIL-Net: A transfer learning-based dual stream neural network to estimate leaf chlorophyll and leaf angle of crops from UAV hyperspectral images*. ISPRS Journal of Photogrammetry and Remote Sensing, 2024. **210**: p. 1-24.
54. Verrelst, J., et al., *Spectral band selection for vegetation properties retrieval using Gaussian processes regression*. International Journal of Applied Earth Observation and Geoinformation, 2016. **52**: p. 554-567.
55. Locherer, M., Hank, T., Danner, M., and Mauser, W., *Retrieval of seasonal leaf area index from simulated EnMAP data through optimized LUT-based inversion of the PROSAIL model*. Remote Sensing, 2015. **7**(8): p. 10321-10346.
56. Sinha, S.K., Padalia, H., Dasgupta, A., Verrelst, J., and Rivera, J.P., *Estimation of leaf area index using PROSAIL-based LUT inversion, MLRA-GPR and empirical models: Case study of tropical deciduous forest plantation, North India*. International Journal of Applied Earth Observation and Geoinformation, 2020. **86**: p. 102027.
57. Yavari, S.M., Azizi, Z., Kiadaliri, H., and Aghamohamadi, H., *Reducing the effect of the forest canopy to measure distances between trees using UAV images*. Smart Agricultural Technol., 2023. **6**: Article 100351.