

تعیین سطح زیرکشت اراضی برنج با بکارگیری روش یادگیری ماشین و با استفاده همزمان از تصاویر ماهواره‌ای اپتیک و رادار با روزنه مجازی (مطالعه موردی: شهرستان بابل)

علی رمضان‌نژاد^۱، روح الله گودرزی^۲، محمودرضا صاحبی^{۳*}

^۱ دانشجوی ارشد سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
aliramzannezhad1454@gmail.com

^۲ دانشجوی دکتری سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
rgoodarzi@email.kntu.ac.ir

^۳ دانشیار گروه سنجش از دور و فتوگرامتری - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
sahebi@kntu.ac.ir

(دریافت: مهر ۱۴۰۴، تصویب: خرداد ۱۴۰۵)

چکیده

برنج یکی از محصولات کلیدی کشاورزی در ایران و جهان است و پایش دقیق سطح زیرکشت آن، به‌ویژه تفکیک زمین‌های تک‌کشت از دوکشت، نقشی حیاتی در مدیریت منابع آب و برنامه‌ریزی تولید دارد. استان مازندران به‌عنوان قطب تولید برنج کشور، به دلیل پراکندگی مکانی مزارع و شرایط متنوع محیطی، نیازمند روش‌های نوین برای پایش اراضی کشاورزی است. در این پژوهش، چارچوبی نوین مبتنی بر ترکیب شبکه‌های عمیق پیچشی (CNN) و بازگشتی (RNN) توسعه داده شد که در دو سطح به شناسایی اراضی برنج و تفکیک الگوهای تک‌کشت/دوکشت می‌پردازد. در گام نخست، به‌منظور شناسایی اراضی برنج شهرستان بابل، از معماری شبکه‌ی عصبی U-Net استفاده شد. این مدل در سه سناریو آموزش یافت: (۱) تنها با داده‌های راداری سنتینل-۱، (۲) تنها با داده‌های اپتیک سنتینل-۲ و (۳) با ترکیب داده‌های اپتیک و راداری (سنتینل-۲ و سنتینل-۱). نتایج حاصل از آزمایش‌ها نشان داد که مدل مبتنی بر داده‌های اپتیک سنتینل-۲ با صحت کلی ۹۶٪/۳۵ و امتیاز F1 برابر با ۰/۹۵۷ و مدل مبتنی بر داده‌های راداری سنتینل-۱ با صحت کلی ۹۱٪/۷۳ و امتیاز F1 برابر با ۰/۹۰۲ ارزیابی شد. در حالی که انتظار می‌رفت ترکیب داده‌های اپتیک-راداری موجب بهبود نتایج شود، اما در منطقه‌ی مطالعه به‌دلیل شرایط نسبتاً بدون ابر، مزیت اصلی داده‌های SAR چندان نمایان نشد و همین امر در کنار نیاز به پیش‌پردازش پیچیده‌تر این داده‌ها می‌تواند دلیل کاهش نسبی دقت مدل ترکیبی با صحت کلی ۹۴٪/۳۲ و امتیاز F1 برابر با ۰/۹۳ گردید. برای آزمایش قدرت تعمیم‌پذیری مدل سه منطقه انتخاب شد: شهرستان ساری به‌عنوان ناحیه‌ای نزدیک به منطقه اصلی، شهرستان لاهیجان منطقه‌ای با فاصله بیشتر و پوشش گیاهی متفاوت‌تر و جنوب شهر تهران به عنوان ناحیه‌ای فاقد کشت برنج. ارزیابی تعمیم‌پذیری نشان داد که مدل در شهرستان ساری نتایج پایدار و دقیق ارائه می‌کند، در حالی که در لاهیجان دقت کاهش یافته ولی همچنان با صحت کلی بالای ۸۸٪ قابل قبول بود. آزمون مدل در زمین‌های فاقد برنج جنوب تهران نیز نرخ خطای بسیار اندک (۲/۱۴٪) را نشان داد که بیانگر توانایی بالای مدل در تشخیص مناطق غیرشالیزاری است. در گام دوم، برای تفکیک زمین‌های تک‌کشت و دوکشت، شبکه بازگشتی GRU و مدل جنگل تصادفی به‌کار گرفته شد. مدل GRU توانست با صحت کلی ۹۸٪/۴، ضریب کاپا ۰/۹۵۱ و امتیاز F1 برابر ۰/۹۷۴، عملکرد بسیار مطلوبی در تفکیک مزارع تک‌کشت از دوکشت برنج ارائه دهد. بر اساس نتایج، حدود ۳۷۴۰۰ هکتار از اراضی به‌عنوان دوکشت شناسایی شدند، در حالی که آمار رسمی تنها ۲۸۰۰۰ هکتار را گزارش کرده است؛ اختلافی که می‌تواند از عدم قطعیت داده‌های سنجش از دور، خطاهای ناشی از طبقه‌بندی اراضی و همچنین کشت‌های غیررسمی یا عدم آمارگیری دقیق باشد. به‌طور کلی، یافته‌های این پژوهش نشان می‌دهد که ترکیب داده‌های ماهواره‌ای و الگوریتم‌های یادگیری عمیق می‌تواند رویکردی دقیق و کارآمد برای پایش اراضی برنج فراهم آورد.

واژگان کلیدی: سطح زیرکشت برنج، یادگیری عمیق، شبکه عصبی پیچشی، شبکه عصبی بازگشتی، سنتینل-۱، سنتینل-۲

۱- مقدمه

برنج به عنوان یکی از اساسی‌ترین محصولات زراعی، نقش مهمی در تأمین امنیت غذایی جهانی، به‌ویژه در قاره آسیا، ایفا می‌کند [۱،۲]. بر اساس گزارش سازمان غذا و کشاورزی ملل متحد (FAO)^۱ در سال ۲۰۱۸، برنج پس از گندم، دومین محصول استراتژیک پرکشت در جهان محسوب می‌شود و بیش از ۱۲ درصد از زمین‌های کشاورزی جهان به کشت این محصول اختصاص یافته است [۳]. مصرف جهانی برنج طی یک دهه گذشته از حدود ۴۳۷ میلیون تن به ۴۸۶ میلیون تن افزایش یافته و سرانه مصرف جهانی آن در سال ۲۰۱۹ به ازای هر فرد ۵۳/۹ کیلوگرم ثبت شده است [۴]. با این وجود، تولید برنج تحت تأثیر عواملی چون تغییرات اقلیمی، محدودیت منابع آبی، و فقدان تجهیزات پیشرفته کشاورزی در کشورهای در حال توسعه با چالش‌های جدی مواجه است [۵]. این وضعیت لزوم توسعه راهکارهای کارآمد برای پایش و مدیریت اراضی زراعی برنج را به‌منظور ارتقاء پایداری تولید غذایی دوچندان کرده است. بیش از ۹۰ درصد از تولید جهانی برنج در قاره آسیا متمرکز است [۶]، جایی که این محصول نه تنها منبع اصلی تغذیه بلکه رکن بنیادین اقتصاد بسیاری از کشورها محسوب می‌شود. در ایران نیز، برنج جایگاه ویژه‌ای در تأمین امنیت غذایی و اقتصاد کشاورزی دارد. در حال حاضر، ایران در گروه کشورهای با تولید متوسط برنج در جهان قرار دارد [۶] و استان‌های گیلان و مازندران قطب‌های اصلی تولید این محصول به‌شمار می‌روند. شهرستان بابل، به عنوان یکی از قطب‌های اصلی تولید برنج در استان مازندران، به دلیل شرایط اقلیمی مناسب، منابع آب فراوان و خاک حاصلخیز، سهم بسزایی در تولید برنج کشور دارد. با این حال، تغییرات اقلیمی، کاهش منابع آب سطحی و زیرزمینی، و رقابت فزاینده در تخصیص منابع آبی به مصارف شرب و صنعتی، چالش‌های عمده‌ای برای کشاورزان منطقه به وجود آورده است. در چنین شرایطی، آگاهی دقیق از سطح زیرکشت برنج در الگوهای تک‌کاشت و دوکاشت و پایش روندهای زمانی و مکانی این تغییرات، پیش‌نیاز طراحی سیاست‌های بهینه مدیریت منابع آب و خاک محسوب می‌شود [۷]. روش‌های سنتی شناسایی

اراضی کشاورزی، به‌ویژه مزارع برنج، متکی بر عملیات میدانی گسترده و زمان‌بر بوده و معمولاً با هزینه‌های بالا همراه‌اند. در مقابل، تکنیک‌های نوین مبتنی بر سنجش از دور و الگوریتم‌های یادگیری ماشین، امکان پایش دقیق، سریع و مقرون‌به‌صرفه اراضی کشاورزی را فراهم کرده‌اند [۸]. با توجه به اهمیت فزاینده پایش زیرکشت برنج و چالش‌های آن، تاکنون پژوهش‌های متعددی با هدف شناسایی و پایش اراضی زیرکشت برنج، به‌ویژه با بهره‌گیری از داده‌های سنجش از دور، صورت گرفته است. این مطالعات، طیف وسیعی از داده‌های اپتیک، راداری و چندزمانه را به کار گرفته‌اند و روش‌های متنوعی برای شناسایی سطح زیرکشت برنج پیشنهاد داده‌اند. رمدانی و همکاران (۲۰۲۰) چارچوبی خودکار برای نقشه‌برداری مراحل رشد برنج در اندونزی با استفاده از داده‌های چندمنبعی (سنتینل-۲، سنتینل-۱ و مادیس) ارائه کردند. روش کار آن‌ها بر پایه تحلیل سری‌های زمانی و طبقه‌بندی آماری طراحی شد. نوآوری اصلی پژوهش، توسعه روشی خودکار و مقاوم در برابر پوشش ابری برای پایش فنولوژی برنج بود که قابلیت تعمیم به سایر محصولات و مناطق مرطوب را دارد. نتایج نشان داد مدل مبتنی بر سنتینل-۲ بهترین عملکرد را با صحت کلی ۹۰/۶٪ داشت، در حالی که مدل ترکیبی (مادیس + سنتینل-۱) به دلیل رزولوشن پایین مادیس دقت پایین‌تری (۷۸/۳٪) ارائه کرد. بنابراین، اگرچه ترکیب داده‌ها به کاهش اثر ابر کمک نمود، اما ضعف اصلی تحقیق وابستگی به داده‌های با قدرت تفکیک مکانی پایین مادیس نسبت به سنجنده‌های سنتینل بود [۹].

کائو و همکاران (۲۰۲۱) مدلی ترکیبی بر پایه داده‌های چندمنبعی و الگوریتم‌های یادگیری ماشین و یادگیری عمیق طراحی کردند. منطقه مورد مطالعه، ۱۳ استان اصلی تولید برنج در چین را شامل می‌شد. سه مدل شامل رگرسیون لاسو^۲، جنگل تصادفی (RF)^۳ و شبکه‌های عصبی LSTM^۴ مورد ارزیابی قرار گرفتند. مدل‌ها بر اساس شاخص‌های آماری مانند R^2 و RMSE ارزیابی شدند. نتایج نشان داد که مدل LSTM بهترین عملکرد را داشت؛ به‌گونه‌ای که مقدار R^2 بین ۰/۷۷ تا ۰/۸۷ برای دوره‌های

^۲ Lasso Regression

^۳ Random forest

^۴ Long Short-Term Memory

^۱ Food and Agriculture Organization

زمانی مختلف حاصل شد. داده‌های ورودی شامل NDVI^۱ برگرفته شده از سنجنده مادیس، دما، بارش، تابش خورشیدی، نوع خاک و آمار عملکرد سالانه بودند. مدل LSTM به دلیل ساختار بازگشتی خود، قادر بود وابستگی‌های زمانی میان سال‌های مختلف را بهتر تشخیص داده و روابط غیرخطی پیچیده‌تری را یاد بگیرد. نوآوری پژوهش در استفاده همزمان از داده‌های مکانی-زمانی با الگوریتم‌های پیشرفته یادگیری عمیق برای برآورد عملکرد برنج در مقیاس ملی بود [۱۰].

سعادت‌سرشت و همکاران (۲۰۲۲) رویکردی نوین برای نقشه‌برداری دقیق انواع برنج در استان مازندران ایران ارائه دادند که مبتنی بر ترکیب داده‌های سری‌زمانی سنتینل-۱ و سنتینل-۲ بود. در این پژوهش، یک چارچوب چندجریانی مبتنی بر شبکه‌های عصبی پیچشی (CNN)^۲ طراحی شد که به طور همزمان ویژگی‌های عمیق را از سری‌های زمانی شاخص NDVI و تصاویر SAR^۳ استخراج کرده و سپس با استفاده از ماژول توجه کانالی (CAM)^۴ و کانولوشن‌های گسترده، توانایی مدل در جداسازی ویژگی‌ها بهبود داده شد. نتایج نشان داد مدل پیشنهادی با صحت کلی ۹۷ درصد و ضریب کاپا ۰/۹۴ عملکردی به مراتب بهتر از روش‌های یادگیری ماشین مانند RF و XGBoost داشت. نوآوری اصلی تحقیق در طراحی معماری چندجریانی با تلفیق ویژگی‌های مکانی-زمانی SAR و NDVI بود. از محدودیت‌های این مطالعه می‌توان به تمرکز صرف بر یک منطقه خاص (مازندران) اشاره کرد [۱۱].

سودیانا و همکاران (۲۰۲۵) با استفاده از تصاویر چندزمانه سنتینل-۲ و لندست-۸ و چهار شاخص گیاهی NDVI، EVI^۵، LSWI^۶ و RGV^۷ روشی ترکیبی برای نقشه‌برداری شالیزارهای برنج در اندونزی ارائه کردند. در این چارچوب، شبکه عصبی پیچشی برای استخراج ویژگی‌های مکانی و فنولوژیک به کار گرفته شد و سپس نتایج به طبقه‌بند جنگل تصادفی برای تصمیم‌گیری نهایی داده شد. ترکیب یادگیری عمیق و RF همراه با استفاده از داده‌های

چندزمانه امکان ردیابی چرخه رشد برنج و بهبود انسجام طبقه‌بندی را فراهم کرد. مدل پیشنهادی در تفکیک اراضی برنج و غیر برنج به صحت کلی ۹۵ درصد و ضریب کاپا ۰/۸۹۳ دست یافت. یکی از نوآوری‌های اصلی پژوهش در ترکیب قدرت یادگیری عمیق CNN با RF که منجر به بهبود معنی‌دار نتایج شد. از محدودیت‌های تحقیق می‌توان به لزوم استفاده از داده‌های مرجع میدانی برای اعتبارسنجی و احتمال کاهش تعمیم‌پذیری در شرایط اقلیمی متفاوت اشاره نمود [۱۲].

بررسی پیشینه تحقیق نشان می‌دهد که مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی پیچشی و بازگشتی (RNN)^۸، در طبقه‌بندی اراضی زیر کشت برنج و شناسایی مراحل فنولوژیکی عملکرد بهتری نسبت به روش‌های یادگیری ماشین سنتی داشته‌اند. با این حال، اغلب مطالعات پیشین یا به‌طور محدود در یک منطقه خاص انجام شده‌اند، یا تنها از یک نوع داده (اپتیک یا راداری) بهره گرفته‌اند و کمتر به ترکیب داده‌های چندمنبعی (سنتینل-۱ و سنتینل-۲) و تعمیم‌پذیری مدل در مناطق مختلف پرداخته‌اند. در این پژوهش، با بهره‌گیری همزمان از داده‌های اپتیک و راداری و ارزیابی مدل در چندین منطقه، تلاشی شده است تا الگویی عمومی‌تر برای پایش کشت برنج ارائه گردد. بنابراین هدف اصلی این مقاله، ارائه یک چارچوب جامع مبتنی بر داده‌های چندمنبعی و الگوریتم‌های یادگیری عمیق (U-Net و GRU) برای شناسایی اراضی برنج و ارزیابی تعمیم‌پذیری آن در سایر مناطق و تمایز بین الگوهای تک‌کاشت و دوکاشت در شهرستان بابل است. تفکیک اراضی برنج تک‌کاشت از دوکاشت موضوعی است که کمتر در پژوهش‌های پیشین به آن توجه شد. این در حالی است که شناسایی دقیق این دو مدل کاشت، می‌تواند نقش کلیدی در برنامه‌ریزی کشاورزی، مدیریت منابع آب و سیاست‌گذاری‌های منطقه‌ای ایفا کند.

۲- منطقه مورد مطالعه و داده‌ها

در این بخش، مشخصات جغرافیایی و اقلیمی منطقه مورد مطالعه به همراه داده‌های به کار رفته برای بررسی الگوهای کشت برنج ارائه می‌شود. هدف از این بخش، فراهم‌سازی درک دقیق از ویژگی‌های منطقه‌ای و نوع

^۱ Normalized Difference Vegetation Index

^۲ Convolutional Neural Networks

^۳ Synthetic aperture radar

^۴ Channel Attention Module

^۵ Enhanced Vegetation Index

^۶ Land Surface Water Index


^۷ Red-Green Vegetation Index

^۸ Recurrent Neural Networks

داده‌های سنجش از دوری است که به منظور ارزیابی عملکرد الگوریتم‌های یادگیری عمیق در طبقه‌بندی اراضی زیر کشت برنج مورد استفاده قرار گرفته‌اند.

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، شهرستان بابل و حومه آن در استان مازندران است که با وسعت تقریبی ۱۵۷۸ کیلومتر مربع در بخش مرکزی این استان قرار دارد. این شهرستان در مختصات UTM^۱، در قاج^۲ ۳۹، بین عرض‌های جغرافیایی ۳۵°۵۷' تا ۳۶°۳۷' شمالی و طول‌های ۲۷°۵۲' تا ۵۲°۴۸' شرقی واقع شده است. موقعیت جغرافیایی آن در نوار ساحلی بین دریای خزر و رشته‌کوه‌های البرز، در فاصله حدود ۱۵ کیلومتری از ساحل قرار داشته و ارتفاع متوسط آن حدود ۲ متر پایین‌تر از سطح دریا است. ویژگی‌های اقلیمی، منابع آبی مناسب و تاریخچه طولانی کشت برنج در این منطقه، بابل را به یکی از نقاط مهم برای بررسی مزارع برنج در کشور تبدیل کرده است.



شکل ۱- موقعیت منطقه مورد مطالعه در ایران (الف)، استان مازندران (ب)، شهرستان بابل روی تصویر ترکیب رنگی واقعی سنجنده سنتینل-۲ اخذ شده در تاریخ ۱۰ ژوئن ۲۰۲۲ (ج)

بر اساس آمارنامه جهاد کشاورزی، در سال زراعی ۱۴۰۲ مجموع اراضی زیر کشت برنج در شهرستان بابل حدود ۴۶۰ کیلومتر مربع بوده است که از این میزان، حدود ۲۸۰ کیلومتر مربع به اراضی دارای کشت دوم و حدود ۱۸۰ کیلومتر مربع به اراضی تک‌کاشت اختصاص یافته است.

افزون بر اراضی زراعی، شهرستان بابل حدود ۷۹۰ کیلومتر مربع جنگل و ۲۴۰ کیلومتر مربع باغ را دربر می‌گیرد که این گستره بخش مهمی از منابع طبیعی و کاربری‌های کشاورزی منطقه را تشکیل می‌دهد. موقعیت جغرافیایی شهرستان بابل در کشور ایران در شکل ۱ نمایش داده شده است.

۲-۲- داده‌های ماهواره سنتینل-۱

ماهواره‌های سنتینل بخشی از برنامه پایش زمین «کپرنیک»^۳ آژانس فضایی اروپا هستند که داده‌های اپتیکی و راداری را برای کاربردهای محیط‌زیستی و کشاورزی فراهم می‌کنند. سنتینل-۱ شامل دو ماهواره سنتینل-1A (در سال ۲۰۱۴) و سنتینل-1B (در سال ۲۰۱۶) با سنجنده راداری باند C و مدار خورشیدآهنگ است که امکان تصویربرداری مکرر هر ۶ تا ۱۲ روز را دارد. این ماهواره به دلیل توانایی تصویربرداری در تمام شرایط جوی، حتی در حضور پوشش ابری و در شب، ابزار ارزشمندی برای پایش کشت‌های غرق‌آبی مانند برنج محسوب می‌شود. ویژگی‌های کلیدی آن شامل دسترسی‌پذیری رایگان، توان تفکیک مکانی ۱۰ متر، تناوب زمانی مناسب و قابلیت اطمینان بالا در شرایط متغیر اقلیمی است. این خصوصیات باعث شده سنتینل-۱ انتخابی ایده‌آل برای شناسایی و پایش مزارع کوچک برنج شمال ایران باشد که اغلب مساحتی کمتر از نیم هکتار دارند. در این تحقیق از پلاریزاسیون VH سنجنده سنتینل-۱، ویژگی‌های راداری BD و BVR در بازه زمانی سال ۲۰۲۲-۲۰۲۳ محاسبه گردید.

۲-۳- داده‌های ماهواره سنتینل-۲

ماهواره سنتینل-۲ از مأموریت‌های کلیدی آژانس فضایی اروپا برای پایش زمین است که با باند طیفی در محدوده مرئی تا مادون‌قرمز، توان تفکیک مکانی ۱۰ تا ۶۰ متر و تناوب زمانی ۵ تا ۱۰ روز، امکان بررسی دقیق تغییرات پوشش زمین، پایش محصولات کشاورزی و مدیریت منابع طبیعی را فراهم می‌سازد. در مطالعات کشت برنج که به‌صورت غرق‌آبی و در قطعات کوچک (حداکثر ۵۰۰۰ مترمربع) انجام می‌شود، قدرت تفکیک ۱۰ متری سنتینل-۲ اهمیت ویژه‌ای دارد و ابزاری ارزشمند برای شناسایی و پایش دقیق مزارع برنج محسوب می‌شود. در این

^۱ Universal Transverse Mercator

^۲ Zone

^۳ copernicus

مطالعه، برای هر ماه از سال ۲۰۲۲، یک تصویر میانه از سامانه گوگل ارث انجین استخراج گردید که در مجموع شامل ۱۲ تصویر نماینده از وضعیت پوشش زمین در طول سال می‌باشد.

۲-۴- داده‌های واقعیت زمینی

در این پژوهش، برای آموزش و اعتبارسنجی مدل‌های طبقه‌بندی از داده‌های میدانی جمع‌آوری شده در شهرستان بابل استفاده شد. این داده‌ها با همکاری مدیریت جهاد کشاورزی و ۹ مرکز خدمات کشاورزی فعال شهرستان گردآوری گردید. در مجموع، اطلاعات مربوط به ۱۹۲ هکتار از مزارع برنج از طریق بازدید میدانی و برداشت نقاط تصادفی ثبت شد که جدول مشخصات آماری اراضی برداشتی در جدول ۱ آمده است.


در هر قطعه، یک نقطه با مختصات جغرافیایی دقیق به‌عنوان نماینده انتخاب و نوع کشت (تک‌کاشت یا دوکاشت) به همراه وجود یا عدم وجود کشت‌های پاییزه نظیر شبدر یا کلزا ثبت گردید. این داده‌ها به‌عنوان مرجع اصلی برچسب‌گذاری برای آموزش شبکه و ارزیابی دقت نتایج مورد استفاده قرار گرفتند. اطلاعات جمع‌آوری شده به‌عنوان داده‌های مرجع برای آموزش و ارزیابی مدل GRU^۱ و RF قرار گرفت. خلاصه‌ای از داده‌های برداشت شده در ادامه ارائه می‌گردد:

جدول ۱- تعداد داده‌های اخذ شده از مراکز جهاد کشاورزی

ردیف	نام مرکز	تعداد نقاط	سطح هکتار
۱	احمدچاله پی	۷	۲۰/۲
۲	بابلکنار	۱۶	۳۰
۳	بندپی شرقی	۲۰	۱۹/۵
۴	بندپی غربی	۲۰	۲۰/۷
۵	بیشه جنوبی	۱۵	۲۰/۱
۶	لاله آباد	۹	۲۰/۲
۷	جلال ارزک	۱۲	۱۴/۵
۸	بیشه شمالی	۴	۳۱
۹	-	۱۷	۱۶

۳- مواد و روش‌ها

در این بخش، مراحل کلی انجام تحقیق با تمرکز بر فرایند پیش‌پردازش داده‌ها، استخراج شاخص‌های طیفی، ویژگی‌های برگرفته شده از رادار و به‌کارگیری الگوریتم‌های یادگیری عمیق برای طبقه‌بندی اراضی زیرکشت برنج ارائه می‌شود. در شکل ۲ چرخه کار پیشنهادی در این پژوهش را مشاهده می‌کنید. بر این اساس در ابتدا، داده‌های سنجنش از دور مورد استفاده تحت پیش‌پردازش‌های اولیه از جمله تصحیحات رادیومتریک، هندسی و حذف نویز قرار گرفتند. سپس با هدف استخراج ویژگی‌های فنولوژیکی گیاه برنج، سه شاخص NDVI، EVI و LSWI از سنجنده اپتیک و ویژگی‌های BD^۲ و BVR^۳ از سنجنده راداری محاسبه و بین ۰ و ۱ نرمال‌سازی شدند. در ادامه، به منظور تفکیک اولیه اراضی برنج از سایر پوشش‌های غیر برنج، از شبکه عصبی پیچشی استفاده شد. پس از آن، به‌منظور جداسازی الگوهای زراعی برنج تک‌کاشت و دوکاشت، از مدل شبکه عصبی بازگشتی نوع GRU بهره گرفته شد. ساختار گام‌به‌گام این فرآیند در زیر بخش‌های آتی به تفصیل تشریح خواهد شد.



شکل ۲- چرخه کار و روش پیشنهادی

۳-۱- پیش‌پردازش

در این پژوهش، به‌منظور آماده‌سازی داده‌ها برای طبقه‌بندی دقیق مزارع برنج، مجموعه‌ای از پیش‌پردازش‌ها

^۲ Backscatter Difference

^۳ Backscatter Variation Rate

^۱ Gated Recurrent Unit

بر روی داده‌های سنتینل-۱ و سنتینل-۲ در محیط پردازش گوگل ارث انجین انجام شد. برای داده‌های راداری سنتینل-۱ که به‌طور ذاتی دارای پدیده اسپکل هستند، از فیلتر اصلاح‌شده لی^۱ با هسته ۷×۷ استفاده گردید. برای داده‌های اپتیک سنتینل-۲، از محصول Surface Reflectance Harmonized استفاده شد که با الگوریتم رسمی Sen2Cor تصحیح اتمسفری شده است. این الگوریتم داده‌های بازتاب بالای جو (TOA^۲) را به بازتاب سطحی (BOA^۳) تبدیل کرده و اثرات ناشی از ذرات معلق، بخار آب و پراکنش مولکولی را حذف می‌کند. برای افزایش دقت بیشتر، از باند کیفی QA60 جهت شناسایی و حذف پیکسل‌های آلوده به ابر (بیت ۱۰) و سیروس^۴ (بیت ۱۱) استفاده شد. پیکسل‌های ناسالم حذف گردیده و تنها داده‌های پاک برای تحلیل باقی ماندند. پس از حذف پیکسل‌های ابری، برای جلوگیری از ایجاد خلأ داده‌ای از روش ترکیب زمانی^۵ در محیط گوگل ارث انجین استفاده شد. در این روش، مجموعه‌ای از تصاویر بدون ابر در یک بازه زمانی ماهانه انتخاب شد و سپس با به‌کارگیری عملگر میانه^۶، مقدار هر پیکسل ابری با مقادیر همان پیکسل در تصاویر بدون ابر همجوار جایگزین شد. تصاویر بدون ابر برای محاسبه شاخص‌های گیاهی کلیدی نظیر NDVI، EVI و LSWI مورد استفاده قرار گرفتند.

۳-۲- شاخص‌های گیاهی

شاخص‌های گیاهی از عملیات جبری بر روی بازتابندگی در طول موج‌های مختلف الکترومغناطیسی محاسبه می‌شوند و به‌عنوان ابزاری کلیدی در پایش پوشش گیاهی و تحلیل روندهای فنولوژیک به کار می‌روند. کلروفیل موجود در برگ‌ها، به‌ویژه در باند قرمز طیف الکترومغناطیس، بخش عمده‌ای از انرژی خورشیدی را برای انجام فرآیند فتوسنتز جذب می‌کند، در حالی‌که ساختار سلولی برگ‌ها در باند مادون‌قرمز نزدیک (NIR^۷) بازتاب بالایی دارد. این تضاد طیفی میان جذب شدید در قرمز و بازتاب قوی در NIR،

مبنای اصلی توسعه شاخص‌های گیاهی است و به‌طور مستقیم با فعالیت فتوسنتزی و میزان سبزیگی پوشش گیاهی ارتباط دارد. بر همین اساس، شاخص‌های گیاهی ابزار قدرتمندی برای پایش سلامت گیاه، تحلیل مراحل فنولوژیک و ارزیابی تراکم پوشش گیاهی در مقیاس‌های مختلف مکانی به شمار می‌آیند و جایگاه ویژه‌ای در مطالعات کشاورزی و مدیریت منابع طبیعی یافته‌اند [۱۳]. در این پژوهش سه شاخص اصلی شامل EVI، NDVI و LSWI انتخاب شدند که هر یک مزایای ویژه‌ای در بررسی مزارع برنج دارند. شاخص NDVI بر اساس اختلاف بازتاب در باند قرمز و مادون‌قرمز نزدیک (NIR) تعریف می‌شود. گیاهان سالم در باند قرمز به دلیل جذب کلروفیل بازتاب اندکی داشته ولی در باند NIR بازتاب بالایی نشان می‌دهند؛ همین تضاد طیفی باعث می‌شود NDVI یکی از مهم‌ترین شاخص‌ها برای شناسایی سبزیگی، تراکم و تغییرات رشد گیاهان باشد. در مطالعات برنج، NDVI به‌طور گسترده برای پایش مراحل مختلف رشد و تخمین سطح زیرکشت استفاده شده است [۱۴].

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

شاخص EVI با اضافه کردن باند آبی در محاسبات، علاوه بر کاهش اثر اشباع NDVI در مناطق دارای پوشش متراکم، اثرات خاک و شرایط اتمسفری را نیز بهتر اصلاح می‌کند. از آنجا که مزارع برنج در دوره رشد تراکم بالایی از پوشش گیاهی ایجاد می‌کنند، استفاده از EVI امکان تفکیک دقیق‌تر مراحل رشد و افزایش دقت در تمایز بین زمین‌های تک‌کاشت و دوکاشت را فراهم می‌کند [۱۵].

$$EVI = \frac{2.5 \times (NIR - RED)}{NIR + 6 \times RED - 7.5 \times BLUE + 1} \quad (2)$$

شاخص LSWI از اختلاف بازتاب باندهای NIR و SWIR^۸ محاسبه می‌شود و به دلیل حساسیت بالا به محتوای آب خاک و پوشش گیاهی، برای شناسایی شرایط غرقابی و رطوبتی بسیار مناسب است. از آنجا که کشت برنج عمدتاً در شرایط غرقاب انجام می‌شود، LSWI قادر است

^۱ Refined Lee

^۲ Top of Atmosphere

^۳ Bottom of Atmosphere

^۴ Cirrus

^۵ Temporal Compositing

^۶ Median Composite

^۷ Near-Infrared

^۸ Short-Wave Infrared

مراحل اولیه رشد و تغییرات رطوبتی زمین را به‌خوبی آشکار کند [۵].

$$LSWI = \frac{NIR - SWIR}{NIR + SWIR} \quad (3)$$

ترکیب این شاخص‌ها در قالب سری‌های زمانی ماهانه تصاویر ماهواره‌ای، ابزاری قدرتمند برای پایش دقیق‌تر و مرحله‌ای اراضی کاشت برنج فراهم می‌سازد.

۳-۳- ویژگی‌های کلیدی استخراج‌شده از داده‌های راداری

از تصاویر سری‌زمانی سنتینل-۱ می‌توان مجموعه‌ای از ویژگی‌های آماری و راداری استخراج کرد که بیانگر تغییرات فیزیکی و سطح زمین هستند. این ویژگی‌ها نقش کلیدی در تفکیک مزارع برنج از سایر کاربری‌های اراضی دارند.

۳-۳-۱- ویژگی تفاوت پس‌پراکنش (BD)


شاخص اختلاف پس‌پراکنش بیانگر دامنه‌ی تغییرات مقادیر پس‌پراکنش در طول چرخه‌ی رشد برنج است و از تحلیل سری زمانی داده‌های راداری استخراج می‌شود. در ابتدای زمان کشت، به علت غرقاب بودن شالیزار، سطح آب مکانیزم آینه‌گونه دارد و انرژی رادار را بازمی‌تاباند؛ در نتیجه مقادیر σ^0 بسیار پایین بوده و مزارع در تصاویر «تاریک» دیده می‌شوند [۱۶]. با کاشت نشا و رشد ساقه‌های قائم، مسیر ساقه-آب/خاک شکل گرفته و پراکنش دووجهی^۱ فعال می‌شود که افزایش شدید مقادیر σ^0 را به دنبال دارد. در مراحل بعدی، با رشد زیست‌توده و رطوبت تاج گیاه، پراکنش حجمی غالب شده و به‌ویژه در پلاریزیشن VH تغییرات زمانی شالیزارها آشکارتر است. نهایتاً با رسیدگی و برداشت محصول، کاهش رطوبت و از بین رفتن شرایط غرقاب سبب افت مجدد σ^0 می‌شود.

$$BD = \max(\sigma^0(t)) - \min(\sigma^0(t)) \quad (4)$$

که در آن $\sigma^0(t)$ مقادیر پس‌پراکنش در طول سری زمانی رشد گیاه است. به‌طور کلی، مقدار این شاخص در اراضی مختلف در بازه‌ای حدود ۰/۵ تا ۳۲ دسی‌بل تغییر می‌کند.

^۱ double bounce

این توالی در مزارع برنج که در شکل ۳ مشاهده می‌کنید، بسیار بارزتر از سایر کشت‌های غیرغرقابی است و دامنه تغییرات فصلی σ^0 در آن‌ها به‌طور معناداری بزرگ‌تر مشاهده می‌شود. مطالعات پیشین نیز نشان داده‌اند که شاخص BD می‌تواند به‌تنهایی با دقتی بیش از ۹۰ درصد مزارع برنج را از سایر کاربری‌ها تفکیک کند [۱۷]. به همین دلیل، در میان شاخص‌های مختلف راداری، BD در این پژوهش به‌عنوان شاخص اصلی برای شناسایی و پایش شالیزارها انتخاب شد.




۳-۳-۲- ویژگی نرخ تغییر پس‌پراکنش (BVR)

شاخص نرخ تغییر پس‌پراکنش (BVR) به‌عنوان یکی از ویژگی‌های کلیدی استخراج‌شده از سری‌های زمانی راداری، شدت افزایش سیگنال در بازه رشد اولیه تا رسیدن به بیشینه بازتاب (σ_{max}) را کمی‌سازی می‌کند. این شاخص از اختلاف σ_{max} و مقدار پس‌پراکنش در نقطه میانی رشد اولیه (σ_a) تقسیم بر فاصله زمانی آن‌ها محاسبه می‌شود و نمایانگر نرخ رشد بیوماس گیاه است.

$$BVR = \frac{\sigma_{max} - \sigma_a}{T_{max} - T_a} \quad (5)$$

باتوجه به شکل ۴، در مزارع برنج، ابتدای فصل با سطح آب غرقابی و بازتاب آینه‌ای σ^0 بسیار پایین است؛ سپس با کاشت نشا و فعال شدن مکانیزم دووجهی، جهش شدیدی در مقادیر σ^0 رخ می‌دهد [۱۸]. در ادامه، رشد سریع تاج گیاه و رطوبت بالای برگ‌ها موجب افزایش پراکنش حجمی شده و شیب منحنی σ^0 در شالیزارها نسبت به محصولات غیرغرقابی به‌طور معناداری بیشتر می‌شود [۱۷]. به‌طور کلی، مقدار BVR در اراضی مختلف بین حدود ۵- تا ۸ تغییر می‌کند، اما در مزارع برنج این شاخص عمدتاً در بخش

مثبت و بالای این بازه قرار می‌گیرد که نشان‌دهنده‌ی نرخ رشد سریع‌تر است.




شکل ۴- نمایش شماتیک استخراج ویژگی نرخ تغییر پس پراکنش در مزارع برنج

۳-۴- شبکه یادگیری عمیق پیچشی

شبکه‌های عصبی پیچشی از مهم‌ترین معماری‌های یادگیری عمیق برای پردازش داده‌های تصویری هستند که با الهام از سازوکار قشر بینایی انسان طراحی شده‌اند. این شبکه‌ها با استفاده از لایه‌های پیچشی، فیلترهای متحرک را بر بخش‌های مختلف تصویر اعمال کرده و الگوهای محلی مانند لبه‌ها، بافت‌ها و تغییرات شدت بازتاب را شناسایی می‌کنند. در ادامه، لایه‌های تجمیع با کاهش ابعاد داده و برجسته‌سازی ویژگی‌های اصلی، اطلاعات استخراج‌شده را ساده‌تر و مقاوم‌تر می‌سازند [۱۹]. در مرحله پایانی نیز لایه‌های تمام‌متصل، ویژگی‌های استخراج‌شده را ترکیب کرده و برای طبقه‌بندی یا شناسایی الگوها مورد استفاده قرار می‌دهند. بدین ترتیب CNN قادر است به‌صورت خودکار و سلسله‌مراتبی، از ویژگی‌های ساده تا ساختارهای پیچیده را یاد بگیرد. در حوزه سنجش از دور، این ویژگی‌ها موجب شده است CNN به ابزاری قدرتمند برای تحلیل تصاویر چندطیفی محسوب شود و کاربرد گسترده‌ای در طبقه‌بندی کاربری اراضی، شناسایی پوشش‌های گیاهی، آشکارسازی تغییرات و تفکیک محصولات کشاورزی پیدا کند [۲۰]. شبکه CNN به‌ویژه U-Net در مسائل طبقه‌بندی باینری یکی از موفق‌ترین و پرکاربردترین مدل‌ها شناخته می‌شود و در بسیاری از مطالعات دقت بالاتری نسبت به سایر الگوریتم‌ها

ارائه داده است [۲۱]. مدل U-Net استفاده شده در این پژوهش از دو بخش اصلی تشکیل شده است: مسیر پایین‌رو^۱ برای استخراج و فشرده‌سازی ویژگی‌ها و مسیر بالا‌رو^۲ برای بازسازی تصویر و تولید نقشه خروجی. در بخش پایین‌رو، داده‌های ورودی با ابعاد ۲۵۶×۲۵۶، وارد بلاک‌های پیچشی شامل لایه‌های Conv2D، Normalization Batch و تابع فعال‌سازی ReLU شدند. شبکه U-Net از طریق لایه‌های Batch Normalization خود تفاوت مقیاس بین کانال‌ها را یاد می‌گیرد، به شرطی که هر کانال نرمال شده باشد. این ترکیب باعث استخراج ویژگی‌های مکانی-طیفی و افزایش پایداری آموزش گردید. پس از هر بلاک، یک لایه MaxPooling2D به‌کار گرفته شد تا ابعاد مکانی نصف شده و ویژگی‌های فشرده‌تری استخراج شود. تعداد فیلترها در این بخش به‌صورت تدریجی از ۱۶ تا ۲۵۶ افزایش یافت تا شبکه قادر به شناسایی الگوهای پیچیده‌تر گردد. در عمیق‌ترین بخش شبکه، بیشترین سطح انتزاعی ویژگی‌ها استخراج شد. سپس در مسیر بالا‌رو، با استفاده از لایه‌های Conv2DTranspose ابعاد مکانی دوباره افزایش یافت. در هر مرحله، ویژگی‌های بازبایی‌شده با ویژگی‌های متناظر از مسیر پایین‌رو ادغام شدند تا جزئیات مکانی و مرزبندی مزارع حفظ شود. این ادغام باعث بهبود تفکیک دقیق بین پیکسل‌های برنج و سایر کاربری‌ها شد. در انتها، لایه Conv2D با فیلتر ۱×۱ برای کاهش تعداد کانال‌ها به یک نقشه نهایی به‌کار گرفته شد و با اعمال تابع فعال‌سازی سیگموئید^۳، احتمال تعلق هر پیکسل به کلاس برنج یا غیر برنج محاسبه گردید.



شکل ۵- معماری U-net استفاده شده جهت تفکیک اراضی برنج از سایر اراضی

۱ Encoder
۲ Decoder
۳ sigmoid

ساختار کلی معماری شبکه طراحی شده در شکل ۵ مشاهده می‌شود. این طبقه‌بندی در سه سناریو مجزا انجام شد: یک‌بار با آموزش مدل تنها بر اساس داده‌های راداری سنتینل-۱، یک‌بار با آموزش مدل تنها بر اساس داده‌های اپتیک سنتینل-۲ و بار دیگر با استفاده از ترکیب داده‌های اپتیک سنتینل-۲ و راداری سنتینل-۱.


۳-۵- شبکه یادگیری عمیق بازگشتی

شبکه‌های عصبی بازگشتی با ایجاد یک حلقه بازخوردی در ساختار خود این امکان را فراهم می‌کنند که خروجی هر مرحله، همراه با ورودی جدید، به مرحله بعد منتقل شود. به این ترتیب، شبکه علاوه بر داده جاری، حافظه‌ای از داده‌های پیشین نیز در اختیار دارد و می‌تواند الگوهای زمانی را تشخیص دهد [۲۲]. این ویژگی برای داده‌های سری‌زمانی مانند مشاهدات ماهواره‌ای بسیار کاربردی است، زیرا تغییرات متوالی شاخص‌هایی مثل NDVI و LSWI را دنبال کرده و مراحل مختلف رشد گیاه را آشکار می‌سازد. با این حال، در توالی‌های طولانی مقدار گرادیان‌ها ممکن است بسیار کوچک یا بزرگ شود (محوشوندگی یا انفجار گرادیان) که یادگیری روابط بلندمدت را دشوار می‌سازد. برای رفع این مشکل، معماری‌های پیشرفته‌تر مانند LSTM و GRU طراحی شده‌اند که با استفاده از دروازه‌های کنترلی، اطلاعات مهم را در حافظه نگه داشته و داده‌های غیرضروری را حذف می‌کنند و در نتیجه وابستگی‌های زمانی بلندمدت را بهتر مدل می‌سازند [۲۳].

برای طبقه‌بندی مزارع تک‌کاشت و دوکاشت، از معماری بازگشتی مبتنی بر شبکه GRU همراه با مکانیزم توجه استفاده شد. داده‌های ورودی به‌صورت سری‌زمانی و شامل شاخص‌های NDVI، EVI و LSWI طراحی گردید.

معماری مدل ارائه‌شده از دو بخش اصلی رمزگذار و رمزگشا تشکیل شده است. در بخش رمزگذار، سه لایه GRU به صورت پشت‌سرهم قرار گرفته‌اند. دو لایه نخست GRU با ۶۴ واحد حافظه و $\text{return_sequences=True}$ طراحی شده‌اند تا بتوانند توالی خروجی را در هر گام زمانی به لایه بعدی منتقل کرده و وابستگی‌های کوتاه‌مدت و بلندمدت داده‌های سری زمانی شاخص‌های گیاهی را استخراج کنند. لایه سوم GRU نیز با ۶۴ واحد اما بدون بازگشت توالی ($\text{return_sequences=False}$) عمل می‌کند و بردار زمینه

نهایی را تولید می‌نماید. این بردار با استفاده از لایه RepeatVector به طول توالی ورودی تکرار شده و برای رمزگشا آماده می‌شود. در بخش رمزگشا نیز سه لایه GRU به کار رفته است؛ بین این لایه‌ها، مکانیزم توجه^۱ به مدل امکان می‌دهد تا وزن پویایی به گام‌های زمانی مختلف اختصاص داده و تمرکز بیشتری روی بازه‌های کلیدی داشته باشد. پس از رمزگشا، خروجی بازشکل‌دهی شده و وارد یک لایه پیچشی یک‌بعدی (Conv1D) با ۶۴ فیلتر می‌شود تا الگوهای محلی رشد و افت شاخص‌ها استخراج و تقویت گردد. سپس داده‌ها تخت شده و در یک لایه Dense با تابع فعال‌سازی سیگموئید برای پیش‌بینی دودویی (تک‌کاشت = ۰، دوکاشت = ۱) استفاده می‌شود. برای بهبود آموزش، از نرمال‌سازی دسته‌ای، Dropout و EarlyStopping بهره گرفته شد. مدل نهایی با تابع زیان Binary Crossentropy و بهینه‌ساز Adam با نرخ یادگیری ۰/۰۰۰۱ آموزش دیده است. ساختار کلی معماری شبکه طراحی شده در شکل ۶ نمایش داده شده است.



شکل ۶- معماری پیشنهادی شبکه GRU برای طبقه‌بندی اراضی برنج تک‌کاشت و دوکاشت

۳-۶- الگوریتم جنگل تصادفی

ایجاد یک درخت تصمیم مستلزم تعیین دو مؤلفه اصلی است: معیار انتخاب ویژگی و روش هرس کردن. در این میان، رایج‌ترین معیارهای مورد استفاده در ساخت درخت تصمیم، نسبت افزایش اطلاعات^۲ و شاخص جینی^۳ هستند [۲۴]. الگوریتم جنگل تصادفی از شاخص جینی به عنوان

۱ Attention

۲ Gain Ratio

۳ Gini Index

معیار سنجش ناخالصی یک ویژگی نسبت به کلاس‌های مختلف بهره می‌برد. این شاخص به صورت زیر تعریف می‌شود:

$$\sum_{i \neq j} f(c_j \cdot T) / |T| (f(c_i \cdot T) / |T|) \quad (6)$$

که در آن $f(C_i.T)/|T|$ بیانگر احتمال تعلق یک نمونه تصادفی از مجموعه داده‌های آموزشی T به کلاس C_i است. در جنگل تصادفی، درخت‌ها به طور کامل رشد می‌کنند و هیچ مرحله هرس‌کردنی روی آن‌ها اعمال نمی‌شود. این ویژگی یکی از نقاط قوت اصلی جنگل تصادفی در مقایسه با روش‌های سنتی درخت تصمیم، مانند روش پیشنهادی کوئیلان محسوب می‌شود. در روش کوئیلان، دو پارامتر باید بهینه گردند که شامل موارد زیر است:

- تعداد متغیرهای تصادفی انتخاب‌شده برای هر گره درخت
- تعداد کل درختان تولید شده

در پیاده‌سازی استاندارد جنگل تصادفی به توصیه بریمن و همکاران، تعداد متغیرهای هر گره برابر با جذر تعداد کل ویژگی‌های ورودی، تعداد درختان برابر با ۵۰۰، حداقل تعداد نمونه در هر گره برابر با یک، و تابع ناخالصی نیز به صورت ضریب جینی در نظر گرفته می‌شود [۲۵].


۴- پیاده‌سازی و نتایج

در این فصل، روند پیاده‌سازی مدل‌های یادگیری عمیق مورد استفاده در این تحقیق، شامل شبکه U-net برای تفکیک اراضی زیرکشت برنج از سایر اراضی و شبکه بازگشتی GRU و RF برای تمایز بین الگوهای تک‌کاشت و دوکاشت، تشریح می‌شود. ابتدا فرآیند آموزش مدل‌ها بر اساس داده‌های سنجش از دور و زمینی شرح داده شده و سپس نتایج به‌دست‌آمده از اجرای مدل‌ها، از نظر دقت طبقه‌بندی، ارزیابی عملکرد و تحلیل مکانی بررسی خواهند شد. همچنین در این فصل، شاخص‌های ارزیابی مانند صحت کلی، ضریب کاپا، F1-score و معیار ROC جهت تحلیل کمی عملکرد مدل‌ها ارائه گردیده است. در پایان، نتایج به‌دست‌آمده بررسی و نقاط قوت و ضعف روش پیشنهادی مورد بحث قرار خواهد گرفت. پیش از آغاز فرآیند پیاده‌سازی، لازم است مجموعه‌ای از عملیات پیش‌پردازش بر

روی تصاویر سری‌زمانی و داده‌های آموزشی اعمال شود که جزئیات آن در بخش‌های بعدی تشریح خواهد شد.

۴-۱- طبقه‌بندی اراضی برنج با استفاده از مدل U-Net

در این پژوهش، از مدل U-net برای طبقه‌بندی باینری اراضی برنج و غیر برنج استفاده گردید. در مرحله نخست، ۱۲ تصویر میانه ماهانه مربوط به سال ۲۰۲۲ از سامانه گوگل ارث انجین استخراج شد. از این تصاویر، شاخص‌های طیفی NDVI، EVI و LSWI محاسبه و سپس تمامی لایه‌ها Stack گردیدند. شهرستان بابل به ۲۲۴ قطعه تصویر با ابعاد ۲۵۶×۲۵۶ پیکسل تقسیم شد. از میان آن‌ها، ۶۰ قطعه تصویر به‌صورت تصادفی انتخاب و با استفاده از تصاویر با قدرت تفکیک مکانی بالای گوگل ارث پرو به‌صورت دستی برچسب‌گذاری شدند. در ادامه، این مجموعه به سه بخش شامل ۴۰ قطعه برای آموزش، ۱۰ قطعه برای اعتبارسنجی، و ۱۰ قطعه برای آزمون تقسیم گردید. به‌منظور افزایش تنوع داده‌ها و بهبود عملکرد مدل، روی داده‌های آموزشی عملیات افزایش داده^۱ انجام شد. این عملیات شامل اعمال نویز گوسی^۲ با سطوح ۵٪ و ۱۰٪ و نیز چرخش تصاویر به زوایای ۹۰، ۱۸۰ و ۲۷۰ درجه بود. در نتیجه، تعداد کل قطعه‌های آموزشی از ۴۰ به ۴۸۰ افزایش یافت. در نهایت، ۴۸۰ برش آموزشی و ۱۰ برش اعتبارسنجی به مدل U-Net داده شد.




شکل ۷- نمایش نمودار دقت در فرآیند آموزش با داده‌های سنتینل-۲ و مدل ترکیبی

بر اساس شکل ۷ نتایج آموزش مدل‌ها نشان داد که شبکه مبتنی بر داده‌های سنتینل-۲ پس از حدود ۲۰ دوره به دقت بالای ۹۵٪ رسید و در نهایت در نزدیکی ۹۷٪ پایدار شد. نزدیکی منحنی‌های آموزش و

^۱ Data Augmentation

^۲ gaussian distribution

اعتبارسنجی بیانگر یادگیری مؤثر و تعمیم‌پذیری مناسب مدل بدون بیش‌برازش بود.



شکل ۸- نمایش برشی از شهرستان بابل در فرآیند آموزش با داده‌های سنیتیل-۲ و مدل ترکیبی

در مقابل، مدل ترکیبی سنیتیل-۱ و سنیتیل-۲ با افزودن ویژگی‌های راداری BD و BVR سریع‌تر همگرا شد (کمتر از ۴۰ دوره) و توانست در مراحل اولیه الگوهای مرتبط با شالیزار برنج را شناسایی کند، اما دقت نهایی آن حدود ۹۵٪ باقی ماند و نسبت به مدل صرفاً اپتیکی کمی پایین‌تر بود. به طور کلی، داده‌های راداری سرعت یادگیری را افزایش دادند، اما مدل سنیتیل-۲ به‌تنهایی از نظر دقت نهایی و پایداری عملکرد بهتری نشان داد.


جدول ۲- نتایج طبقه‌بندی اراضی برنج شهرستان بابل

مدل	دقت	دقت	امتیاز F1	AUC
مدل آموزش دیده توسط سنیتیل-۱	۹۱/۷۳	۸۸/۹۰	۰/۹۰۲	۰/۹۷۳
مدل آموزش دیده توسط سنیتیل-۲	۹۶/۳۴	۹۳/۹۰	۰/۹۵۷	۰/۹۹۴
مدل آموزش دیده توسط سنیتیل-۱ و سنیتیل-۲	۹۴/۳۲	۹۱/۱۳	۰/۹۳	۰/۹۹۱

بر اساس برش به نمایش گذاشته شده در شکل ۸ در مدل مبتنی بر سنیتیل-۲، عمده خطاهای طبقه‌بندی در مرز مزارع مشاهده شد که به دلیل وجود پیکسل‌های مختلط میان اراضی برنج و کاربری‌های مجاور مانند خاک برهنه، جاده یا مناطق مسکونی است. این وضعیت باعث ایجاد مقادیر میانی در شاخص‌هایی مانند NDVI و LSWI شده و

تشخیص دقیق مرزها را دشوار می‌سازد. در مقابل، در قطعات بزرگ و یکپارچه، مدل عملکردی بسیار دقیق داشته و توانسته تغییرات فنولوژیک برنج را با ثبات بالا دنبال کند. در مدل ترکیبی سنیتیل-۱ و سنیتیل-۲ نیز خطاها بیشتر در نواحی مرزی و قطعات کوچک‌تر رخ داده‌اند. دلیل این امر آن است که هرچند فیلتر اسپکل کیفیت کلی تصاویر راداری را بهبود داده، اما باعث هموار شدن تغییرات ناگهانی در مرز مزارع شده و جزئیات مکانی از بین رفته است. همچنین، در مزارع منفرد و کوچک، پدیده اسپکل حتی پس از فیلتر همچنان باقی مانده و موجب کاهش دقت شاخص‌های راداری مانند BD و BVR شده است. در مجموع، نتایج نشان می‌دهد که مدل سنیتیل-۲ دقت بالاتری در طبقه‌بندی نهایی دارد، در حالی که مدل ترکیبی با سرعت یادگیری بیشتر همراه بوده اما در مرزها و قطعات پراکنده محدودیت‌هایی نشان داده است. در جدول ۲ نتایج معیارهای ارزیابی برای مدل ترکیبی، مدل آموزش یافته فقط از سنیتیل-۲ و مدل آموزش یافته فقط از سنیتیل-۱ برای ۱۰ برش تست مشاهده می‌کنید.


نتایج جدول ۲ بیانگر آن است که مدل مبتنی بر داده‌های اپتیکی سنیتیل-۲ با صحت کلی ۹۶/۳۵٪، ضریب کاپا ۰/۹۳۹ و امتیاز F1 معادل ۰/۹۵۷ عملکرد بهتری نسبت به مدل استفاده شده از داده‌های راداری سنیتیل-۱ و ترکیبی سنیتیل-۱ و سنیتیل-۲ داشته است. در مقابل، مدل ترکیبی با صحت کلی ۹۴/۳۲٪، دقت پایین‌تری ارائه کرده است. این یافته‌ها نشان می‌دهد که داده‌های اپتیکی سنیتیل-۲ به‌تنهایی کارایی بیشتری در تفکیک اراضی برنج در شهرستان بابل دارند. همچنین داده‌های راداری به‌تنهایی نتوانستن دقت مانند داده اپتیکی و یا ترکیبی تولید کنند.



شکل ۹- نمودار ROC برای مدل آموزش دیده از داده‌های سنیتیل-۲ و سنیتیل-۱ و مدل ترکیبی در شهرستان بابل

شکل ۹ منحنی ROC مربوط به دو مدل آموزش دیده با داده‌های سنیتیل-۲ و داده‌های ترکیبی سنیتیل-۱ و

سنتینل-۲ را که دقت بالاتری ارائه می‌دهند، نشان می‌دهد. همان‌طور که مشاهده می‌شود، هر دو مدل عملکرد بسیار مطلوبی داشته‌اند؛ به‌طوری که مقدار AUC برای مدل ترکیبی برابر با ۰/۹۹۱ و برای مدل مبتنی بر سنتینل-۲ برابر با ۰/۹۹۴ به‌دست آمده است. نزدیکی منحنی‌ها به گوشه بالا-چپ بیانگر نرخ پایین خطاهای مثبت کاذب و قدرت تفکیک بسیار بالا در جداسازی اراضی برنج از سایر کاربری‌هاست. مقایسه کلی دو مدل نشان می‌دهد که اختلاف مقادیر AUC ناچیز است و هر دو مدل از دقت و قابلیت اطمینان بسیار بالایی برخوردارند.



شکل ۱۰- نقشه نهایی طبقه‌بندی اراضی شهرستان بابل به دو کلاس برنج و غیر برنج در سال ۲۰۲۲، حاصل از مدل آموزش‌دیده با داده‌های سنتینل-۲

در این پژوهش، با تجمع ۲۲۴ برش طبقه‌بندی‌شده، نقشه‌ی نهایی اراضی برنج و غیر برنج تولید شد (شکل ۱۰). برآورد مساحت اراضی زیر کشت برنج در سال ۲۰۲۲ توسط مدل سنتینل-۲ برابر با ۴۸۴۶۰ هکتار و توسط مدل ترکیبی سنتینل-۱ و سنتینل-۲ برابر با ۴۹۱۷۰ هکتار به‌دست آمد. این مقادیر در مقایسه با آمار رسمی جهاد کشاورزی (۴۶۰۰۰ هکتار) به‌ترتیب دارای اختلاف ۲۴۶۰ و ۳۱۷۰ هکتار بودند. بخشی از این اختلاف به خطاهای طبقه‌بندی تصاویر و بخشی دیگر به محدودیت‌های آمار رسمی (با نوسان تقریبی ۵۰۰ هکتار) مربوط است. این

اختلاف کم نشان‌دهنده‌ی کارایی بالای داده‌های سنتینل در پایش سطح زیرکشت برنج و نقش مکمل آن‌ها در کنار آمارهای رسمی است.

۲-۴- بررسی قدرت تعمیم‌پذیری مدل


پس از آموزش مدل، به‌منظور ارزیابی قدرت تعمیم‌پذیری آن، شبکه آموزش‌یافته بر روی داده‌های مناطق مختلف با فواصل تا منطقه مورد مطالعه آزمایش گردید. ابتدا در شهرستان ساری (واقع در فاصله ۴۰ کیلومتری از شهرستان بابل)، سپس در شهرستان لاهیجان (با فاصله ۳۰۰ کیلومتری) و در نهایت بر روی زمین‌های کشاورزی جنوب تهران آزمایش شد.

۲-۴-۱- شهرستان ساری

به‌منظور ارزیابی قابلیت تعمیم‌پذیری مدل، شهرستان ساری به‌عنوان منطقه‌ی آزمون انتخاب گردید. این شهرستان در فاصله‌ی حدود ۴۰ کیلومتری از بابل واقع شده و پوشش گیاهی مشابهی با آن دارد. برای این ارزیابی، ۱۰ برش تصویری از اراضی کشاورزی ساری به صورت تصادفی انتخاب و با استفاده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا در محیط گوگل ارث پرو برچسب‌گذاری شد. سپس مدل آموزش‌دیده، بدون هیچ‌گونه بازآموزی مجدد، بر روی این داده‌ها اعمال گردید تا میزان توانایی آن در تعمیم به مناطق جدید مورد سنجش قرار گیرد.

جدول ۳- نتایج طبقه‌بندی اراضی برنج شهرستان ساری

مدل	معیار کمی	معیار کیفی	امتیاز F1	AUC
مدل آموزش‌دیده توسط سنجنده سنتینل-۱	۸۷/۱۵	۰/۸۲۴	۰/۸۶۳	۹۴/۷۴
مدل آموزش‌دیده توسط سنجنده سنتینل-۲	۹۲/۸۲	۰/۸۶۱	۰/۹۴۲	۰/۹۷۹
مدل آموزش‌دیده توسط سنجنده سنتینل-۱ و سنتینل-۲	۹۱/۱۴	۰/۸۲۴	۰/۹۰۸	۰/۹۷۲




شکل ۱۲- نقشه نهایی طبقه‌بندی اراضی شهرستان ساری به دو کلاس برنج و غیر برنج در سال ۲۰۲۲، حاصل از مدل آموزش‌دیده با داده‌های سنتینل-۲

۴-۲-۲- شهرستان لاهیجان

به‌منظور سنجش دقیق قابلیت تعمیم‌پذیری مدل، شهرستان لاهیجان به‌عنوان یکی دیگر از مناطق آزمون انتخاب شد. این شهرستان در فاصله ۳۰۰ کیلومتری از شهرستان بابل واقع شده و یکی از کانون‌های اصلی کشت برنج در شمال کشور به شمار می‌آید. برای ارزیابی، ۵ برش تصویری از اراضی کشاورزی لاهیجان به‌صورت تصادفی انتخاب و با استفاده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا در محیط گوگل ارث پرو برچسب‌گذاری گردید. سپس مدل آموزش‌دیده، بدون هیچ‌گونه بازآموزی مجدد، بر روی این داده‌ها اعمال شد تا توانایی آن در شناسایی و تفکیک اراضی برنج در منطقه‌ای متفاوت از داده‌های آموزش، مورد بررسی قرار گیرد. در جدول ۴، نتایج طبقه‌بندی بر اساس مدل آموزش‌یافته با داده‌های سنجنده سنتینل-۱، سنتینل-۲ و مدل ترکیبی سنتینل-۱ و سنتینل-۲ ارائه شده است که شامل مقادیر صحت کلی، ضریب کاپا و امتیاز F1 برای ارزیابی عملکرد دو مدل می‌باشد. نتایج جدول نشان می‌دهد که عملکرد مدل در شهرستان لاهیجان نسبت به بابل و ساری کاهش محسوسی داشته است؛ به‌گونه‌ای که میانگین صحت کلی حدود ۷-۸ درصد کمتر از بابل (۹۶٪) و ۴-۵ درصد پایین‌تر از ساری (۹۳٪) گزارش شده است.

بر اساس جدول ۳، دو مدل مبتنی بر سنجنده سنتینل-۲ و مدل ترکیبی، تعمیم‌پذیری مناسبی در شهرستان ساری دارند و در حالی که مدل صرفاً مبتنی بر داده راداری از دقت پایین‌تری نسبت به سایر مدل‌ها برخوردار است. بررسی نتایج ارائه‌شده در جدول ۲ نشان می‌دهد که مدل مبتنی بر داده‌های اپتیکی سنتینل-۲ در شهرستان ساری عملکرد بهتری نسبت به مدل سنتینل-۱ و ترکیبی سنتینل-۱ و سنتینل-۲ داشته است. صحت کلی این مدل با مقدار ۹۲/۸۲٪، ضریب کاپا ۰/۸۶۱ و امتیاز F1 برابر با ۰/۹۴۲، بالاتر از مقادیر متناظر در مدل راداری و ترکیبی بوده است. این برتری بیانگر آن است که داده‌های اپتیکی سنتینل-۲ به‌تنهایی توانسته‌اند اطلاعات مفیدی برای شناسایی دقیق اراضی برنج فراهم آورند. بر اساس شکل ۴ که روند تغییرات دقت آموزش و اعتبارسنجی را نشان می‌دهند، مشاهده می‌شود که مدل مبتنی بر سنتینل-۲ با سرعت همگرایی بالاتر و پایداری بیشتری در طول فرایند آموزش همراه بوده است. از این‌رو، پیش از انجام طبقه‌بندی نیز انتظار می‌رفت که داده‌های اپتیکی سنتینل-۲ عملکرد بهتری در تعمیم‌پذیری نشان دهند.

همچنین در شکل ۱۱ منحنی ROC برای دو مدل در شهرستان ساری مشاهده می‌کنید.



شکل ۱۱- نمودار ROC برای مدل آموزش‌دیده از داده‌های سنجنده سنتینل-۲ و مدل ترکیبی در شهرستان ساری


نتایج نمودار ROC نشان می‌دهد که هر دو مدل از قدرت تفکیک بسیار بالایی در تشخیص مزارع برنج برخوردارند و مدل آموزش‌دیده با داده‌های سنتینل-۲ با AUC برابر با ۰/۹۷۹ و مدل ترکیبی با AUC ۰/۹۷۲ اختلاف معناداری با یکدیگر ندارد. در نهایت در شکل ۱۲ نقشه طبقه‌بندی اراضی برنج از سایر اراضی شهرستان ساری به نمایش درآمده است.

جدول ۴- نتایج طبقه‌بندی اراضی برنج شهرستان لاهیجان

مدل	صحت کلی	فهرت کاپا	امتیاز F1	AUC
مدل آموزش دیده توسط سنجنده سنتینل-۱	۷۹/۳۲	۷۳/۲۲	۷۸/۹۱	۰/۹۱۶
مدل آموزش دیده توسط سنجنده سنتینل-۲	۸۸/۷۷	۰/۸۱۷	۰/۸۷۱	۰/۹۵۴
مدل آموزش دیده توسط سنجنده سنتینل-۱ و سنتینل-۲	۸۵/۳۵	۰/۷۸۳	۰/۸۲۳	۰/۹۴۴

همچنین مدل که با استفاده از داده‌های سنتینل-۱ آموزش یافت نسبت به بقیه مدل‌ها از افت دقت بیشتری برخوردار شد. این افت دقت در مدل‌ها را می‌توان به چند عامل نسبت داد. نخست، تفاوت در شرایط محیطی مانند پوشش گیاهی، خاک، رطوبت و تابش خورشید است که بر بازتاب‌های طیفی برنج اثر می‌گذارند و مدل آموزش دیده در بابل قادر به تعمیم کامل به این شرایط نبوده است. دوم، اختلاف در مراحل فنولوژیکی و شیوه‌های کشت بین مناطق می‌تواند موجب تغییر الگوهای طیفی شود و در نتیجه دقت مدل را کاهش دهد. همچنین، وجود محصولات یا پوشش‌های مشابه نظیر گیاهان آبدوست و مراحل اولیه رشد چای در لاهیجان باعث بروز اشتباه در طبقه‌بندی و افزایش خطای مدل گردیده است.


همچنین در شکل ۱۳ منحنی ROC برای دو مدل در شهرستان لاهیجان مشاهده می‌کنید.



شکل ۱۳- نمودار ROC برای مدل آموزش دیده از داده‌های سنجنده سنتینل-۲ و مدل ترکیبی در شهرستان لاهیجان

نکته مهم آن است که با وجود کاهش شاخص‌های صحت کلی، کاپا و F1 در مقایسه با بابل و ساری، مقدار AUC همچنان بالا باقی مانده است. علت این امر به ماهیت محاسبه‌ی ROC برمی‌گردد که پیش از آستانه‌گذاری و در

بازهی کامل آستانه‌ها (۰ تا ۱) عملکرد مدل را ارزیابی می‌کند.



شکل ۱۴- نقشه نهایی طبقه‌بندی اراضی شهرستان لاهیجان به دو کلاس برنج و غیر برنج در سال ۲۰۲۲، حاصل از مدل آموزش دیده با داده‌های سنتینل-۲

بنابراین حتی اگر در آستانه‌ی انتخابی برای تولید نقشه دقت کاهش یافته باشد، مدل در تشخیص نسبی و رتبه‌بندی احتمال تعلق پیکسل‌ها به کلاس‌ها همچنان کارایی بالایی دارد. در نهایت در شکل ۱۴ نقشه طبقه‌بندی اراضی برنج از سایر اراضی شهرستان لاهیجان به نمایش درآمده است.


۴-۲-۳- جنوب شهر تهران

به‌منظور ارزیابی پایداری و قابلیت تعمیم‌پذیری مدل در شرایط خارج از محدوده آموزش، عملکرد آن در اراضی کشاورزی جنوب شهر تهران بررسی شد. در این منطقه عمدتاً محصولات صیفی و سبزیجات کشت می‌شوند و هیچ‌گونه زمینی به برنج اختصاص ندارد. بدین ترتیب، هر گونه شناسایی نادرست این اراضی به‌عنوان برنج به‌منزله‌ی خطای طبقه‌بندی تلقی می‌شود. نتایج حاصل از مدل برتر (آموزش‌دیده با داده‌های سنجنده سنتینل-۲) نشان داد که تنها ۲/۱۴ درصد از پیکسل‌ها به‌اشتباه در کلاس برنج قرار گرفته‌اند. این میزان خطا اندک بوده و نشان می‌دهد که

مدل از توانایی بالایی در شناسایی صحیح مناطق فاقد برنج و جلوگیری از مثبت‌های کاذب برخوردار است.

بررسی علل این خطای محدود حاکی از چند نکته اساسی است: نخست، برخی اراضی غیر برنجی به‌ویژه زمین‌های آبیاری‌شده به روش غرقابی یا دارای رطوبت بالا، از نظر ویژگی‌های طیفی و بافتی شباهت زیادی به مزارع برنج دارند و ممکن است موجب سردرگمی مدل شوند. دوم، محدودیت‌های ذاتی داده‌های ماهواره‌ای از جمله شرایط جوی، خطاهای بازتابی و تفکیک مکانی نسبتاً پایین می‌توانند سبب هم‌پوشانی بین کلاس‌ها و کاهش دقت شوند. سوم، کمبود تنوع در داده‌های آموزشی مربوط به کلاس‌های غیر برنج ممکن است موجب کاهش توانایی مدل در تشخیص الگوهای ناآشنا در مناطق جدید گردد.


به‌طور کلی، این آزمایش نشان داد که مدل توسعه‌یافته، ضمن برخورداری از دقت بالا در محدوده آموزش، در مواجهه با مناطق فاقد برنج نیز توانایی تعمیم‌پذیری مناسبی دارد و می‌تواند ابزار مؤثری برای پایش و مدیریت کاربری اراضی در مقیاس منطقه‌ای محسوب شود. در شکل ۱۵ نقشه طبقه‌بندی در جنوب شهرستان تهران به نمایش گذاشته شده‌است.



شکل ۱۵- نقشه نهایی طبقه‌بندی اراضی جنوب شهر تهران به دو کلاس برنج و غیر برنج در سال ۲۰۲۲، حاصل از مدل آموزش‌دیده با داده‌های سنتینل-۲

۴-۳- تفکیک زمین‌های کشت اول از کشت دوم


برای تفکیک اراضی تک‌کاشت و دوکاشت محصول برنج، از سری‌زمانی شاخص پوشش گیاهی NDVI در طول یک سال زراعی استفاده شد. در گام نخست، اراضی مورد مطالعه بر اساس داده‌های واقعیت زمینی و بازدیدهای میدانی به دو گروه تک‌کاشت و دوکاشت تفکیک شدند. سپس برای هر گروه، سری‌زمانی NDVI به‌طور جداگانه استخراج گردید تا الگوهای فنولوژیکی مربوط به هر نوع کشت بازنمایی شود. ویژگی کلیدی این منحنی‌ها، رفتار NDVI در بازه زمانی اواسط مرداد تا اوایل آبان است؛ چرا که در این دوره، اراضی دوکاشت معمولاً دومین اوج NDVI را نشان می‌دهند، به دلیل آنکه محصول کشت دوم در این بازه به مرحله رشد نهایی می‌رسد. در مقابل، اراضی تک‌کاشت پس از برداشت محصول اول با کاهش محسوس پوشش گیاهی مواجه شده و افت قابل توجهی در مقادیر NDVI تجربه می‌کنند. این تفاوت در رفتار فنولوژیکی NDVI برای دو نوع کشت در شکل ۱۶ نشان داده شده است.



شکل ۱۶- سری‌زمانی شاخص NDVI برای اراضی برنج در سال زراعی؛ (الف) اراضی تک‌کاشت، (ب) اراضی دوکاشت.

برای آماده‌سازی داده‌های لازم جهت آموزش مدل تفکیک برنج تک‌کشت و دوکشت، ابتدا نقشه‌ی طبقه‌بندی‌شده برنج و غیر برنج تهیه شده و نواحی غیرمرتبط از طریق اعمال ماسک حذف شدند. سپس مختصات نقاط برداشت زمینی در محیط گوگل ارث وارد و به‌صورت فایل KML ذخیره گردید. این فایل در نرم‌افزار ArcMap به فرمت .shp تبدیل شد و در ادامه، در محیط ENVI فراخوانی

سپتامبر و اکتبر (مرداد، شهریور و مهر) اختلاف معنی‌داری میان این دو نوع کشت نشان می‌دهد.



شکل ۱۷- نقشه نهایی طبقه‌بندی اراضی تک‌کاشت از دوکاشت در سال ۲۰۲۲، حاصل از مدل GRU

در این بازه زمانی، برنج کشت دوم در مرحله رشد قرار دارد، در حالی که برنج تک‌کشت برداشت شده و زمین‌ها مقادیر پایینی از شاخص‌های گیاهی را ثبت می‌کنند. این اختلاف زمانی امکان جداسازی دقیق‌تر دو کلاس را فراهم کرده است. دومین عامل به محدودیت حجم داده‌های آموزشی برمی‌گردد. هرچند حدود ۱۹۲ هکتار داده زمینی گردآوری شد که مقدار قابل توجهی است، اما با تقسیم آن‌ها بین مجموعه‌های آموزشی و آزمایشی، سهم داده‌های آزمایشی کاهش یافته است. با توجه به نیاز بالای شبکه‌های یادگیری عمیق به داده‌های گسترده، این محدودیت می‌تواند بر نتایج اثرگذار باشد و انتظار می‌رود با افزایش حجم داده‌های آزمایشی در پژوهش‌های آینده، عملکرد مدل بهبود یابد.

بر اساس نتایج به‌دست‌آمده از طبقه‌بندی نهایی، از مجموع اراضی برنج شهرستان بابل، ۳۷۴۰۰ هکتار به‌عنوان زمین‌های دوکشت برنج و ۱۱۰۶۰ هکتار به‌عنوان زمین‌های تک‌کشت برنج شناسایی شدند. این در حالی است که مطابق با آمار رسمی اعلام‌شده از سوی جهاد کشاورزی، مساحت اراضی برنج دوکاشت در این شهرستان ۲۸۰۰۰ هکتار عنوان شده است.

گردید تا فایل ROI^۱ برای مراحل بعدی پردازش آماده‌سازی شود. با توجه به اینکه تفاوت اصلی بین زمین‌های تک‌کشت و دوکشت در الگوی تغییر شاخص‌های گیاهی در بازه‌ی اواخر تابستان تا پاییز نمود می‌یابد، شاخص‌های NDVI، EVI و LSWI به‌طور خاص برای ماه‌های آگوست، سپتامبر و اکتبر استخراج شدند. این سه شاخص در سه ماه مذکور به‌عنوان ورودی مدل GRU و RF قرار گرفتند. انتخاب معماری GRU به هدف طراحی یک چارچوب یکپارچه یادگیری عمیق باز می‌گردد که در آن، دو معماری مجزای U-Net و GRU به‌ترتیب وظیفه تفکیک اراضی برنج از سایر کاربری‌ها و شناسایی الگوی تک یا دوکاشت را در قالبی واحد و منسجم انجام می‌دهند.

برای تقسیم داده‌ها، ۸۰٪ از نمونه‌ها به‌صورت تصادفی به‌عنوان داده‌های آموزشی و ۲۰٪ به‌عنوان داده‌های آزمایشی اختصاص یافتند. دقت‌های طبقه‌بندی‌کننده GRU و RF در جدول ۵ ارائه شده است.

جدول ۵- نتایج طبقه‌بندی اراضی تک‌کاشت و دوکاشت برنج

شهرستان بابل بر اساس مدل GRU و RF

مدل	صحت کلی	ضریب کاپا	امتیاز F1	AUC
GRU	۹۸/۴۰	۰/۹۵۱	۰/۹۶۷	۰/۹۹۵
RF	۹۷/۲۲	۰/۹۳۶	۰/۹۶۳	۰/۹۹۴

نتایج جدول ۵ نشان می‌دهد که مدل GRU عملکرد بهتری نسبت به مدل RF دارد، اما این اختلاف از نظر آماری معنادار نیست و هر دو مدل با صحت کلی بالای ۹۷ درصد، عملکرد قابل قبولی ارائه می‌دهند. همچنین، در شکل ۱۷ نتیجه طبقه‌بندی شهرستان بابل به اراضی تک‌کاشت و دوکاشت برنج بر اساس مدل GRU به نمایش گذاشته شده است.

دو عامل اصلی را می‌توان دلیل دستیابی به این دقت بالا دانست. نخست، تفکیک‌پذیری قابل توجه بین زمین‌های تک‌کشت و دوکشت برنج است. همان‌گونه که در شکل ۱۶- مشاهده می‌شود، شاخص NDVI در ماه‌های آگوست،

^۱ Region of Interest

این اختلاف می‌تواند ناشی از چند عامل مختلف باشد. یکی از مهم‌ترین دلایل، تفاوت در منبع و روش جمع‌آوری داده‌ها است. آمار رسمی معمولاً مبتنی بر گزارش‌های میدانی، ثبت‌های اداری و اظهارات کشاورزان است، که ممکن است به دلایلی از جمله عدم دریافت مجوز رسمی برای کشت دوم یا ملاحظات قانونی، به‌طور کامل ثبت نشده باشند. به‌عنوان مثال، در مناطقی که با محدودیت منابع آبی مواجه هستند، کشت دوم برنج از سوی نهادهای مسئول ممنوع شده می‌باشد. با این حال، برخی کشاورزان به دلیل جذابیت‌های اقتصادی، ممکن است اقدام به کشت دوم کنند بدون آنکه در آمار رسمی منعکس شود؛ به طوری که کارشناسان جهاد کشاورزی نیز اذعان دارند در کمتر زمینی تنها به کشت تک‌کاشت برنج اکتفا می‌شود.

در مقابل، مدل‌های مبتنی بر سنجش از دور صرفاً بر اساس شواهد طیفی و نشانه‌های واقعی پوشش گیاهی در تصاویر ماهواره‌ای عمل می‌کنند و می‌توانند واقعیت سطح زیر کشت را فارغ از محدودیت‌های اداری نشان دهند. به همین دلیل، برآورد مدل ممکن است گسترده‌تر از آمار رسمی به نظر برسد. این موضوع نشان می‌دهد که تلفیق داده‌های زمینی و سنجش از دور، می‌تواند دید دقیق‌تر و جامع‌تری از وضعیت کشاورزی ارائه دهد.

۵- نتیجه‌گیری و پیشنهادات

در این پژوهش با استفاده از تصاویر ماهواره‌ای سنتینل و الگوریتم‌های یادگیری عمیق، چارچوبی برای پایش مزارع برنج ارائه شد. مدل U-Net نشان داد که داده‌های سنتینل-۲ عملکرد مناسبی دارند. در حالی که انتظار می‌رفت ترکیب داده‌های اپتیک-راداری موجب بهبود نتایج شود، اما در منطقه‌ی مطالعه به‌دلیل شرایط نسبتاً بدون ابر، مزیت اصلی داده‌های SAR چندان نمایان نشد و همین امر در کنار نیاز به پیش‌پردازش پیچیده‌تر این داده‌ها می‌تواند دلیل کاهش نسبی دقت مدل ترکیبی باشد. آزمون تعمیم‌پذیری نیز بیانگر

مراجع

پایداری مدل در مناطق مشابه (ساری) و عملکرد قابل قبول در شرایط متفاوت (لاهیجان) بود؛ همچنین در مناطق فاقد برنج (جنوب تهران) خطای طبقه‌بندی بسیار پایین ثبت شد. برای تشخیص تک‌کاشت و دوکاشت از دو مدل GRU و RF و همچنین شاخص‌های فنولوژیکی سری‌های زمانی NDVI استفاده شد که دقتی بسیار بالا به دست داد. نتایج نشان داد ۳۷۴۰۰ هکتار از اراضی بابل دوکاشت و ۱۱۰۶۰ هکتار تک‌کاشت هستند، در حالی که آمار رسمی تنها ۲۸۰۰۰ هکتار دوکاشت را گزارش کرده بود. این اختلاف بیانگر وجود کشت‌های دوم غیررسمی است که در آمار رسمی منعکس نشده‌اند.

برای توسعه پژوهش حاضر، چند مسیر اصلی پیشنهاد می‌شود: نخست، افزایش داده‌های میدانی و نمونه‌های آموزشی به منظور بهبود دقت و پایداری مدل‌ها در شرایط مختلف. دوم، تعمیم مدل به مناطق جغرافیایی متنوع‌تر با شرایط اقلیمی و الگوهای کشت متفاوت، که می‌تواند زمینه‌ساز ایجاد یک سامانه پایش ملی برنج شود. سوم، استفاده از سری‌های زمانی با وضوح بالاتر برای آشکارسازی دقیق‌تر الگوهای فنولوژیکی و تشخیص مطمئن‌تر کشت دوم. چهارم، به‌کارگیری الگوریتم‌های نوین یادگیری عمیق و مدل‌های تلفیقی شامل ترنسفورمرها و روش‌های یادگیری انتقالی یا نیمه‌نظارتی برای افزایش دقت و کاهش وابستگی به داده‌های برچسب‌خورده.

سپاسگزاری

در پایان، از سازمان جهاد کشاورزی شهرستان بابل به‌منظور تأمین داده‌های زمینی، از پژوهشکده سنجش از دور و آزمایشگاه طبقه‌بندی تصاویر دانشکده مهندسی نقشه‌برداری دانشگاه صنعتی خواجه نصیرالدین طوسی به‌دلیل پشتیبانی علمی و فنی، و از آژانس فضایی اروپا (European Space Agency) بابت فراهم‌سازی تصاویر ماهواره‌ای سنتینل صمیمانه قدردانی می‌شود.

1- Elert, E. Rice by the numbers: A good grain. *Nature* 514, S50–S51 (2014). <https://doi.org/10.1038/514S50a>

2- Basnet, B. M. S. (2012a). Rice: Water, Food Security and Climate Change in Nepal. *Hydro Nepal: Journal of Water, Energy and Environment*, 78–80. <https://doi.org/10.3126/hn.v11i1.7217>

3- FAO Rice Market Monitor (RMM), April 2018, VOLUME XXI ISSUE No. 1

- 4- Chang, L., Chen, Y.-T., Wang, J.-H., & Chang, Y.-L. (2020). Rice-Field Mapping with Sentinel-1A SAR Time-Series Data. *Remote Sensing*, 13(1), 103. <https://doi.org/10.3390/rs13010103>
- 5- Ferreira, S. S. D., Sanchez, J. M., & Gonçalves, J. M. (2023). A Remote-Sensing-Assisted Estimation of Water Use in Rice Paddy Fields: A Study on Lis Valley, Portugal. *Agronomy*. <https://doi.org/10.3390/agronomy13051357>
- 6- Saadat, M., Hasanlou, M., & Homayouni, S. (2019). RICE CROP MAPPING USING SENTINEL-1 TIME SERIES IMAGES (CASE STUDY: MAZANDARAN, IRAN). *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-4/W18, 897–904. <https://doi.org/10.5194/isprs-archives-xlii-4-w18-897-2019>
- 7- Remote sensing for agriculture and resource management. (2022). <https://doi.org/10.1016/b978-0-12-822976-7.00012-0>
- 8- Haj Hussain, M., Abuhani, D. A., Khan, J., ElMohandes, M., Zuolkernan, I., & Ali, T. (2023). A light-weight cropland mapping model using satellite imagery. <https://doi.org/10.3390/s23156729>
- 9- Ramadhani, F., Pullanagari, R., Kereszturi, G., & Procter, J. (2020). Automatic Mapping of Rice Growth Stages Using the Integration of SENTINEL-2, MOD13Q1, and SENTINEL-1. *Remote Sensing*, 12(21), 3613. <https://doi.org/10.3390/rs12213613>
- 10- Cao, J., Zhang, Z., Tao, F., Zhang, L., Luo, Y., Zhang, J., Han, J., & Xie, J. (2021). Integrating Multi-Source Data for Rice Yield Prediction across China using Machine Learning and Deep Learning Approaches. *Agricultural and Forest Meteorology*, 297, 108275. <https://doi.org/10.1016/j.agrformet.2020.108275>
- 11- Saadat, M., et al. (2022). Multi-stream deep convolutional networks for accurate paddy rice mapping using Sentinel-1 and Sentinel-2 time-series data in Mazandaran Province, Iran. *Agriculture*, 12(2083), 1–20. <https://doi.org/10.3390/agriculture12202083>
- 12- Sudiana, D., Abdurahman, M., Wirahman, A. D., & Farda, N. M. (2025). CNN-Random Forest hybrid method for phenology-based paddy rice mapping using Sentinel-2 and Landsat-8 satellite images. *Computers*, 14(336), 1–15. <https://doi.org/10.3390/computers14080336>
- 13- Marques, A. C., Luís, I. C., Coelho, A. R., Pessoa, C., Daccak, D., Simões, M., Almeida, A. S., Scotti Campos, P., Ramalho, J. C., Semedo, J. M., Kullberg, J. C., Brito, M., Pessoa, M. F., Reboredo, F., Marques, P. A. A. P., Silva, M. M., Legoinha, P., Oliveira, K., Pais, I. P., & Lidon, F. C. (2022, January)
- 14- Tucker, C. J., & Sellers, P. J. (1986). Satellite remote sensing of primary production. *International Journal of Remote Sensing*, 7(11), 1395–1416. <https://doi.org/10.1080/01431168608948944>
- 15- Comparing satellites and vegetation indices for cover crop biomass estimation. (2022). *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2022.106900>
- 16- Arii, M., & Yamada, H. (2017). Rice paddy monitoring by L-band MIMP SAR approach. *International Geoscience and Remote Sensing Symposium*. <https://doi.org/10.1109/IGARSS.2017.8127486>
- 17- Chang, L., Chen, Y.-T., Wang, J.-H., & Chang, Y.-L. (2020). Rice-Field Mapping with Sentinel-1A SAR Time-Series Data. *Remote Sensing*, 13(1), 103. <https://doi.org/10.3390/rs13010103>
- 18- Shao, Y., Liao, J., & Wang, C. (2002). Analysis of temporal radar backscatter of rice: A comparison of SAR observations with modeling results. *Canadian Journal of Remote Sensing*. <https://doi.org/10.5589/M02-019>
- 19- Lalitha, V., & Latha, B. N. (2022). A review on remote sensing imagery augmentation using deep learning. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2022.03.341>
- 20- Searching for CNN Architectures for Remote Sensing Scene Classification. (2022). *IEEE Transactions on Geoscience and Remote Sensing*. <https://doi.org/10.1109/tgrs.2021.3097938>
- 21- Fu, T., et al. (2023). UNet: A Deep Learning Model for Rice Extraction in Rio Grande do Sul. *Remote Sensing*, 15(16), 4021.
- 22- Qin, J., Hu, T., Yuan, J., Liu, Q., Wang, W., Liu, J., Guo, L., & Song, G.-Z. (2023). Deep-Learning-Based Rice Phenological Stage Recognition. *Remote Sensing*. <https://doi.org/10.3390/rs15112891>
- 23- Crisóstomo de Castro Filho, H., Abílio de Carvalho Júnior, O., Ferreira de Carvalho, O. L., Pozzobon de Bem, P., dos Santos de Moura, R., Olino de Albuquerque, A., Rosa Silva, C., Guimarães Ferreira, P. H., Fontes Guimarães, R., & Trancoso Gomes, R. A. (2020). Rice Crop Detection Using LSTM, Bi-LSTM, and Machine Learning Models from Sentinel-1 Time Series. *Remote Sensing*, 12(16), 2655. <https://doi.org/10.3390/rs12162655>
24. Quinlan, J. R. (1994). Book Review: C4. 5: Programs for Machine Learning. In *Machine Learning* (Vol. 240).
25. Breiman, L. (2001). ST4_Method_Random_Forest. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1017/CBO9781107415324.004>