

# پایش جنگل‌زدایی در ذخیره‌گاه زیست‌کره ارسباران با استفاده از تصاویر چند زمانه ماهواره‌ای مبتنی بر شبکه U-Net بهینه‌شده

امیررضا گروسی<sup>۱</sup>، علی حسینی نوه<sup>۲\*</sup>، هومن لطیفی<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد سنجش‌ازدور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، ایران  
a.garousi@email.kntu.ac.ir

<sup>۲</sup> دانشیار گروه فتوگرامتری و سنجش‌ازدور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، ایران  
hosseininaveh@kntu.ac.ir

<sup>۳</sup> دانشیار گروه فتوگرامتری و سنجش‌ازدور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، ایران  
hooman.latifi@kntu.ac.ir

(دریافت: خرداد ۱۴۰۳، تصویب: مرداد ۱۴۰۳)

## چکیده

جنگل‌زدایی همچنان یکی از نگرانی‌های بزرگ در زمینه تغییرات اقلیمی و حفظ تنوع زیستی است. درعین‌حال، توسعه تکنیک‌های جدید پردازش تصویر و دسترسی گسترده به تصاویر ماهواره‌ای با حد تفکیک مکانی و زمانی بالا، شرایط بی‌نظیری برای پایش جنگل‌زدایی فراهم کرده است. این موضوع به‌ویژه در مناطقی مانند ذخیره‌گاه زیست‌کره ارسباران اهمیت دارد. روش‌های موجود پایش جنگل‌زدایی بر ترکیبی از مشاهده بصری، پروفیل‌های طیفی، آمار و تکنیک‌های یادگیری ماشین مبتنی هستند. با توجه به پیشرفت‌های اخیر در زمینه پردازش تصاویر توسط شبکه‌های عصبی پیچشی (CNN)، هدف این پژوهش ارزیابی عملکرد معماری U-Net بهینه‌شده برای شناسایی پوشش جنگلی به‌منظور پایش جنگل‌زدایی در تصاویر ماهواره‌ای چند زمانه است. در این راستا، یک مدل یادگیری عمیق برای پایش جنگل‌زدایی در ذخیره‌گاه زیست‌کره ارسباران بر اساس طبقه‌بندی تصاویر ماهواره‌ای Landsat بین سال‌های ۲۰۰۰ تا ۲۰۲۲ توسعه داده شد. در این مطالعه، برای تهیه ماسک از شاخص پوشش گیاهی تفاضلی نرمال‌شده (NDVI) استفاده شده و سپس این ماسک‌ها به‌صورت بصری اصلاح شدند. همچنین مدل بهینه‌شده U-Net که ارائه داده شده است، با مدل‌های جنگل تصادفی (Random Forest) و شبکه عصبی مصنوعی (ANN) مقایسه شد. نتایج نشان داد که U-Net بهینه‌شده نسبت به روش‌های مرسوم یادگیری ماشین در طبقه‌بندی تصویر به جنگل یا غیر جنگل برتری دارد که در نتیجه صحت کلی ۹۶٫۵۳٪، کاپا ۹۱٫۵۵٪، امتیاز F1 ۹۴٫۶۸٪ و IoU ۹۰٫۰۴٪ به دست آمد. مدل ارائه‌شده می‌تواند تغییرات جنگل را به‌طور دقیق نشان دهد و مقادیر کاهش یا افزایش مساحت جنگل را تخمین بزند. به‌طور کلی مشاهده شد که مساحت جنگل‌های ارسباران طی دوره ۲۰۰۰-۲۰۲۲ افزایش یافته است. این تحقیق نشان می‌دهد که استفاده از U-Net بهینه‌شده می‌تواند ابزار مؤثری برای پایش و مدیریت پایدار منابع جنگلی باشد.

**واژگان کلیدی:** پایش، جنگل‌زدایی، سنجش‌ازدور، ارسباران، شبکه عصبی پیچشی U-Net

\*نویسنده رابط

## ۱- مقدمه

جنگل‌ها که بخش عمده‌ای از سطح زمین را پوشش می‌دهند، دارای ارزش‌های اقتصادی و اکولوژیکی بسیاری برای همه موجودات زنده مرتبط شامل گیاهان، جانوران و انسان‌ها هستند. حدود ۳۰ درصد از سطح زمین را جنگل‌ها پوشانده‌اند که نقش بسیار مهمی در حفاظت از تنوع زیستی، جذب کربن، حفظ منابع آب، کاهش تغییرات اقلیمی و حفظ تعادل محیط‌زیستی ایفا می‌کنند. جنگل‌ها همچنین فرصت‌های معیشتی و تفریحی را برای مردم فراهم می‌کنند [۱-۳].

با توجه به روند جنگل‌زدایی در دهه‌های اخیر، بررسی تغییرات رخ داده در بخش منابع طبیعی و تبیین علل و میزان این تغییرات و تأثیر آن بر سایر منابع ضروری است [۴]. جنگل‌زدایی تقریباً ۱۰ درصد از گازهای گلخانه‌ای جهان را ایجاد می‌کند و میانگین دمای جهانی را بیش از ۱ درجه سانتی‌گراد از دوران پیش از صنعتی شدن افزایش داده است [۵]. مشکل تخریب محیط‌زیست و جنگل‌زدایی در اثر اقدامات و فعالیت‌های انسانی یکی از مهم‌ترین مسائل جهانی است که بسیاری از کشورها با آن مواجه هستند. این موضوع نه تنها از نظر محیط‌زیستی و تأثیر آن بر سامانه‌های منابع طبیعی، بلکه از نظر اقتصادی نیز حائز اهمیت است؛ بنابراین، پایش جنگل‌زدایی به‌منظور کاهش آن، نقش انکارناپذیری در روند توسعه پایدار دارد.

یکی از رویشگاه‌های جنگلی مهم ایران، ناحیه ریشی ارسباران است که در استان آذربایجان شرقی واقع شده است. به دلیل تأثیرپذیری از اقلیم‌های خزری، قفقازی و مدیترانه‌ای، تنوع گیاهی ارسباران چشمگیر است [۶]. چنین تنوع گونه‌ای و ژنتیکی بالایی، جایگاه ویژه‌ای را به این بوم‌سازگان مهم کشور بخشیده است. فعالیت‌های شدید انسانی در چند قرن گذشته، سیمای ظاهر، ترکیب و ساختار جنگل‌های ارسباران را به شدت تغییر داده است. قطع‌های غیرمجاز درختان جنگل با هدف تهیه چوب برای سوخت و دیگر مصارف روستایی، چرای بیش‌ازحد دام و فشرده‌گی خاک، زادآوری این جنگل‌ها را با تهدید جدی مواجه کرده است [۷].

سنجش‌ازدور<sup>۱</sup> با استفاده از داده‌های چند زمانی ماهواره‌ای می‌تواند ابزاری بالقوه برای اندازه‌گیری و پایش تغییرات پوشش جنگلی در مقیاس محلی و جهانی باشد چراکه از نظر زمانی مستمر و از نظر اقتصادی مقرون‌به‌صرفه است و همچنین قابلیت خودکارسازی را دارد. با استفاده از روش‌های بینایی ماشین<sup>۲</sup> و تصاویر ماهواره‌ای می‌توان به‌طور خودکار جنگل‌ها را پایش کرد و از دست رفتن پوشش درختان را در مقیاس بسیار بزرگ‌تری شناسایی کرد [۸]. پیشرفت در فناوری‌ها مانند سنجنده‌ها و پهپادها، همراه با الگوریتم‌ها، می‌تواند به شناسایی و پایش تغییرات جنگل و توقف فعالیت‌های غیرقانونی کمک کند. از آنجاکه جنگل‌ها تأثیر مهمی بر زندگی انسان دارند، تجزیه و تحلیل آن‌ها از دیدگاه‌های مختلف مورد مطالعه قرار گرفته است [۱۰، ۱۱] و چندین سکو برای تجزیه و تحلیل جنگل‌ها با استفاده از تصاویر ماهواره‌ای، نظیر Planet [۱۲] و پایش جهانی جنگل<sup>۳</sup> (GFW) [۱۳] ارائه شده است.

طی دهه اخیر یادگیری عمیق<sup>۴</sup> به دلیل توانایی در استخراج ویژگی‌های منحصربه‌فرد از تصاویر، از جمله تصاویر ماهواره‌ای، مورد توجه محققان حوزه سنجش‌ازدور قرار گرفته است. این تکنیک در محیط‌های پیچیده و کاربردهای مختلفی مورد استفاده قرار گرفته است [۱۴] و نتایج جدیدی را در طبقه‌بندی کاربری اراضی و پوشش زمین [۱۵، ۱۶]، تشخیص اشیاء [۱۷] و طبقه‌بندی موضوعی<sup>۵</sup> [۱۸] ارائه داده است. طبقه‌بندی موضوعی تصویر در زمینه‌هایی همچون تصویربرداری پزشکی [۱۹-۲۱] و سنجش‌ازدور [۲۲-۲۴] کاربرد دارد. هدف از طبقه‌بندی، شناسایی اشیاء خاص با اختصاص هر پیکسل تصویر به یکی از کلاس‌های موضوعی از پیش تعیین‌شده است. در مورد مطالعه حاضر طبقه‌بندی مقدمه‌ای بر طبقه‌بندی است؛ یعنی ابتدا تصویر به بخش‌های همگن تقسیم می‌شود (طبقه‌بندی) و سپس هر بخش به یک کلاس خاص اختصاص داده می‌شود (طبقه‌بندی). با این‌حال، جای خالی تحقیقاتی که قابلیت شبکه‌های عصبی پیچشی<sup>۶</sup> برای پایش

۱ Remote sensing

۲ Computer vision

۳ Global Forest Watch

۴ Deep Learning

۵ Semantic segmentation

۶ Convolutional Neural Network

جنگل‌زدایی با استفاده از تصاویر ماهواره‌ای در ایران را مورد بررسی قرار داده باشند، احساس می‌شود. استفاده از شبکه‌های عصبی پیچشی و تصاویر ماهواره‌ای می‌تواند یک زیرساخت بی‌نظیر برای توسعه سامانه‌های پایش تغییر پوشش جنگلی فراهم کند. این موضوع به‌ویژه در مناطقی با پوشش کم جنگل و نرخ بالای جنگل‌زدایی، نظیر جنگل‌های ایران بسیار مهم است.

مطالعات محدودی درباره پایش جنگل‌زدایی با استفاده از سنجش‌ازدور در ایران انجام شده است [۲۵-۲۹]؛ که هیچ‌یک، از شبکه‌های عصبی پیچشی برای این منظور استفاده نکرده‌اند؛ بنابراین، این بخش به معرفی روش‌های شبکه عصبی پیچشی مرتبط با پایش جنگل‌زدایی می‌پردازد و بر روی تحقیقاتی که از شبکه‌های عصبی پیچشی استفاده کرده‌اند تمرکز دارد.

برای تشخیص جنگل‌زدایی در آمازون برزیل، د بم و همکاران [۳۰] دو معماری شبکه عصبی پیچشی U-Net و ResUnet را با استفاده از تصاویر Landsat-8 با حد تفکیک مکانی ۳۰ متری که به دو طبقه جنگل و غیر جنگل طبقه‌بندی شده‌اند، به کار بردند. آن‌ها مشاهده کردند که U-Net و ResUnet نتایج مشابهی ارائه دادند؛ اما ResUnet بهترین نتایج معیارهای ارزیابی را داشت. نویسندگان از این دو معماری مقادیر معیارهای زیر را دریافت کردند: ResUnet: ۰,۹۴۶۵-۰,۹۴۳۲ (امتیاز F1)، ۰,۹۲۵۲-۰,۹۳۵۸ (صحت)، ۰,۹۵۷۴-۰,۹۶۱۶ (بازخوانی<sup>۱</sup>)؛ U-Net: ۰,۹۳۳۹-۰,۹۱۱۲ (امتیاز F1)، ۰,۹۲۲۳-۰,۹۱۷۵ (صحت)، ۰,۹۵۰۸-۰,۹۰۰۳ (بازخوانی). در ادامه، آندراده و همکاران [۳۱] تغییرات جنگل‌زدایی را در یک منطقه از جنگل آمازون با استفاده از معماری DeepLabv3+ انجام دادند و آن را با معماری‌های Early Fusion (EF) و Siamese Convolution Neural (S-CNN) مقایسه کردند. نویسندگان تصاویر Landsat-8 با حد تفکیک مکانی ۳۰ متری را به دو دسته جنگل و غیر جنگل طبقه‌بندی کردند. نتایج نشان داد که معماری DeepLabv3+ به‌طور قابل‌توجهی نسبت به معماری‌های EF و S-CNN در خصوص امتیاز F1 عملکرد بهتری داشت و صحت کلی بهتری را ارائه داد. معماری EF امتیاز F1 از ۰,۴۵ تا ۰,۶۳ داشت، S-CNN از ۰,۴۷ تا ۰,۶۳ و DeepLabv3+ از ۰,۶۴

<sup>۱</sup> Recall

تا ۰,۷۲. در زمینه طبقه‌بندی جنگل (با تمرکز بر روی گیاهان کوچک‌تر) فلود و همکاران [۲۳] از معماری U-Net برای شناسایی درختان و بوته‌های بزرگ در ایالت کوئینزلند استرالیا استفاده کردند. آن‌ها از تصاویر Earth-i با وضوح ۱ متری به‌عنوان داده ورودی استفاده کردند. نویسندگان مشاهده کردند که شبکه آموزش دیده U-Net دقت تقریبی ۹۰٪ را داشت. برای آموزش شبکه، آن‌ها تصویر را به دو طبقه تقسیم کردند: گیاهان چوبی و غیر چوبی. با استفاده از مجموعه داده TanDEM-X بر روی ایالت پنسیلوانیا آمریکا، مازا و همکاران [۳۲] به پایش جنگل (دو کلاس جنگل و غیر جنگل) پرداختند و سه معماری شبکه عصبی پیچشی ResNet, DenseNet و U-Net را مورد مقایسه قرار دادند. نتایج نشان دادند که معماری U-Net عملکرد مؤثرتری در مورد صحت (۰,۸۵۰۶-۰,۸۸۲۷) و امتیاز F1 (۰,۸۶۲۹-۰,۸۲۴۸) داشته است. در ادامه، لی و همکاران [۳۳] زمین‌های تحت تأثیر جنگل‌زدایی ناشی از فعالیت‌های انسان با استفاده از تصاویر ماهواره‌ای با حد تفکیک مکانی بالا و یادگیری عمیق طبقه‌بندی کردند. آن‌ها دو معماری CNN (SegNet و U-Net) را به کار بردند. تصاویر Kompsat-3 با حد تفکیک مکانی ۰,۷ متری را به دو کلاس جنگل و غیر جنگل طبقه‌بندی کردند. نتایج نشان داد که معماری U-Net (۰,۷۴,۸٪) دقیق‌تر از معماری SegNet (۰,۶۳,۳٪) بود. معماری U-Net تقریباً ۱۱,۵٪ دقیق‌تر از معماری SegNet بود.

واگنر و همکاران [۳۴] از معماری U-Net برای شناسایی درختان نخل در جنگل آمازون با استفاده از تصاویر GeoEye با حد تفکیک ۰,۵ متری استفاده کردند. نقشه نهایی برای تجزیه و تحلیل توزیع مکانی درختان نخل و ارتباط آن با تداخل انسانی استفاده شد. تصاویر ماهواره‌ای به دو کلاس درخت نخل و غیره طبقه‌بندی شدند. نویسندگان به نتایج خوب معماری U-Net (امتیاز F1 ۰,۷۰ و صحت ۰,۹۵۵) رسیدند و نشان دادند که روش‌های یادگیری عمیق ظرفیت قوی برای پشتیبانی از پایش درختان نخل دارند. واگنر و همکاران [۳۵] در مطالعه‌ای دیگر پوشش جنگل و تغییرات آن و دو گونه درخت، *Cecropia hololeuca* و *Tibouchina pulchra* را پایش کردند. نویسندگان از مجموعه داده WorldView-2 و WorldView-3 با حد تفکیک مکانی به ترتیب ۰,۵ و ۰,۳ متری استفاده کردند و از معماری U-Net بهره بردند.

معیارهای حاصل از مطالعه آن‌ها شامل صحت (۰,۸۰۸) - (۰,۹۹۳)، بازخوانی (۰,۸۰۱-۰,۹۹۵) و امتیاز F1 (۰,۸۰۴) - (۰,۹۹۴) بود.

الزعبی و همکاران [۳۶] مطالعه‌ای برای پایش جنگل‌زدایی در اردن با استفاده از تصاویر Landsat-8 و مدلی بهبودیافته از U-Net انجام دادند و آن را با سایر مدل‌ها مقایسه کردند که صحت روش آن‌ها بیشتر از سایر مدل‌ها (۰,۹۴۸) گزارش شد. جمالی و همکاران [۳۷] معماری جدیدی از TransU-Net با نام TransU-Net++ را برای پایش جنگل‌زدایی معرفی کردند و مدل خود را بر روی تصاویر جنگل‌آمازون آموزش و آزمایش کردند که امتیاز F1 بیشتری (۰,۹۶۸) نسبت به سایر مدل‌ها داشت. شامیلو و همکاران [۳۸] یک رویکرد خودکار برای پایش جنگل‌زدایی در کی‌یف با استفاده از تصاویر ماهواره‌ای Sentinel-2 و Landsat-8 و مدلی تغییریافته از مدل U-Net ارائه دادند. آن‌ها در بخش کدگذار شبکه U-Net معماری Efficientnet B3 را به کار بردند و گزارش دادند که مدل آن‌ها امتیاز F1 (۰,۶۳۰) و IoU (۰,۷۱۴) بالاتری نسبت به مدل پایه U-Net در شناسایی جنگل داشته است.

پیشینه تحقیق انجام‌شده نشان می‌دهد که تاکنون مطالعه‌ای برای پایش جنگل‌زدایی در ایران با استفاده از سنجنش‌زدور ماهواره‌ای و شبکه عصبی پیچشی انجام نشده است. این چالش باعث شد تا در این مطالعه به ارائه یک مدل یادگیری عمیق بر مبنای استخراج ویژگی‌های موضوعی از تصاویر ماهواره‌ای با استفاده از معماری بهینه‌شده U-Net به منظور پایش جنگل‌زدایی در جنگل‌های ارسباران پرداخته شود. برای این منظور از تصاویر ماهواره‌ای Landsat استفاده شده است. به منظور ارزیابی نتایج به‌دست‌آمده توسط U-Net بهینه‌شده، عملکرد آن با روش‌های مرسوم یادگیری ماشین، مانند الگوریتم طبقه‌بندی جنگل تصادفی<sup>۱</sup> و شبکه عصبی مصنوعی<sup>۲</sup> که روش‌های شناخته‌شده و متداول در طبقه‌بندی تصاویر هستند، مقایسه شد. در انتخاب روش‌های مختلف برای ارزیابی عملکرد مدل، جنگل تصادفی و شبکه عصبی مصنوعی به دلیل ویژگی‌ها و مزایای خاص خود انتخاب شده‌اند. جنگل تصادفی به‌عنوان یک روش یادگیری

ماشین مبتنی بر الگوریتم‌های بگینگ و درخت تصمیم‌گیری، به دلیل توانایی‌اش در کاهش واریانس (کاهش حساسیت به داده‌های آموزشی مختلف) و جلوگیری از بیش‌برازش، در بسیاری از مسائل طبقه‌بندی و رگرسیون نتایج بسیار خوبی ارائه می‌دهد [۳۹-۴۱]. از سوی دیگر، شبکه عصبی مصنوعی به دلیل توانایی‌اش در مدل‌سازی روابط پیچیده و غیرخطی و توانمندی در یادگیری ویژگی‌های نهفته در داده‌ها، به‌عنوان یکی از قدرتمندترین طبقه‌بندی‌کننده‌ها شناخته‌شده است [۴۲، ۴۳]. مقایسه این دو روش با شبکه U-Net بهینه‌شده، می‌تواند میزان کارایی و دقت این مدل را نشان دهد.

## ۲- روش انجام

در این بخش، روش تحقیق ارائه می‌شود که شامل مدل یادگیری عمیق، روش جمع‌آوری و آماده‌سازی پایگاه داده جنگل‌های ارسباران، استخراج ویژگی‌های موضوعی عمیق و فرآیند نظارت بر جنگل‌زدایی است.

### ۲-۱- روند کلی فرآیند پایش جنگل‌زدایی

شکل ۱ روند کلی مدل یادگیری عمیقی که بر پایه شبکه U-Net است را برای پایش جنگل‌زدایی در جنگل‌های ارسباران نشان می‌دهد. این مدل بر پایه طبقه‌بندی تصاویر ماهواره‌ای چند زمانه<sup>۳</sup> جمع‌آوری‌شده مابین سال ۲۰۰۰ و ۲۰۲۲ است. ابتدا مجموعه داده‌ای متشکل از تصاویر جنگل‌های ارسباران و تصاویر ماسک واقعیت زمینی متناظر تهیه می‌شود. تصاویر واقعیت زمینی برای یادگیری ویژگی‌های موضوعی مناطق جنگلی و ارزیابی دقت الگوریتم طبقه‌بندی تصویر ضروری هستند. تصاویر ورودی با اعمال تقویت داده<sup>۴</sup>، از جمله وارونه کردن و دوران، پیش‌پردازش می‌شوند که توانایی یادگیری مدل یادگیری عمیق موضوعی را بهبود می‌بخشد.

در مرحله بعدی، بعد از آموزش مدل، مجموعه‌ای از ویژگی‌های تصویر با ابعاد کم به‌صورت نقشه‌های موضوعی با استفاده از معماری U-Net بهینه‌شده استخراج می‌شوند. در انتها، تصاویر نهایی طبقه‌بندی‌شده تولید می‌شوند.

<sup>۳</sup> Multi-Temporal

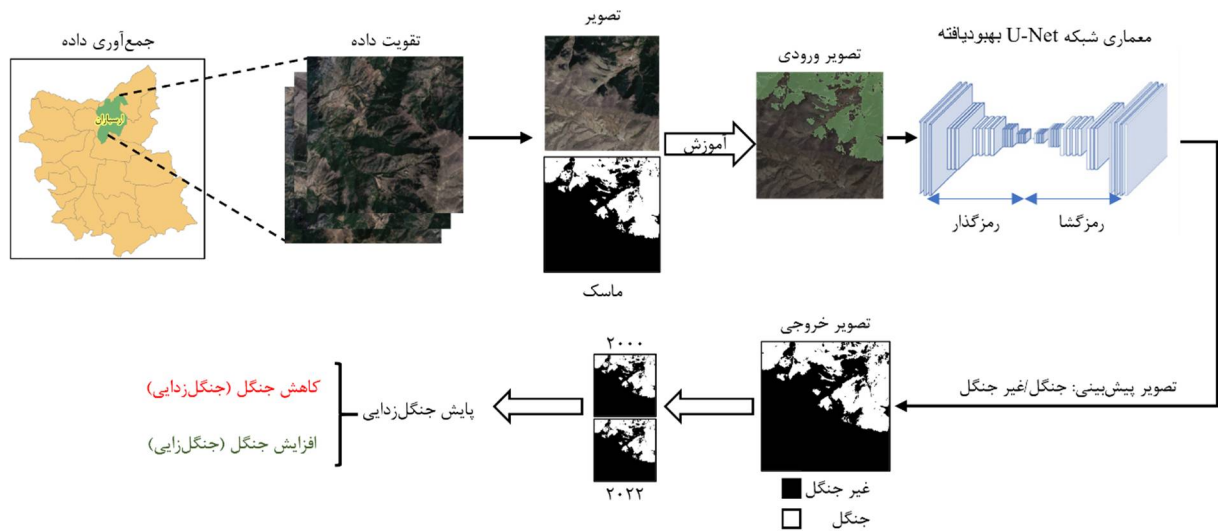
<sup>۴</sup> Data augmentation

<sup>۱</sup> Random Forest

<sup>۲</sup> Artificial Neural Network

در نهایت، تصویر آزمایشی که در یک سال خاص ثبت شده است، به مدل وارد می‌شود تا پوشش جنگل‌ها را شناسایی و تغییرات جنگلی را طبقه‌بندی کند. نرخ شباهت با استفاده از بررسی شباهت پیکسل به پیکسل برای همه تصاویر جنگلی گرفته‌شده محاسبه می‌شود. نتیجه نهایی

جنگل‌زدایی مدل به صورت کاهش مساحت جنگل (جنگل‌زدایی) یا افزایش مساحت جنگل (جنگل‌زایی) گزارش می‌شود. جزئیات چارچوب در بخش‌های بعدی توضیح داده شده‌اند.



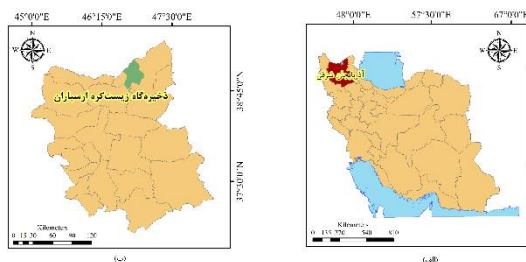
شکل ۱. روند کلی مراحل انجام طرح پیشنهادی

## ۲-۲- مجموعه داده جنگل‌های ارسباران

### ۲-۲-۱- منطقه مورد مطالعه و جمع‌آوری مجموعه داده

منطقه مورد مطالعه، ذخیره‌گاه زیست‌کره ارسباران، واقع در شهر کلیر، استان آذربایجان شرقی است. این منطقه عمدتاً کوهستانی بوده و دارای دماهای سرد در زمستان و دماهای معتدل در تابستان می‌باشد. شکل ۲ نشان‌دهنده منطقه مورد مطالعه است. در این مرحله تصاویر ماهواره‌ای از ناحیه ریشی ارسباران، بخش ذخیره‌گاه زیست‌کره، جمع‌آوری و برای این منظور از ماهواره Landsat-5، برای سال‌های ۲۰۰۰ و ۲۰۱۰ و Landsat-8 و Landsat-9، برای سال ۲۰۲۲، استفاده شده‌است. تمامی تصاویر استفاده شده در این مطالعه از مجموعه<sup>۱</sup> ۲ و سطح<sup>۲</sup> ۲ ماهواره‌های لندست تهیه شده‌اند. این مجموعه و سطح از تصاویر دارای تصحیحات اتمسفری، هندسی و رادیومتریکی

هستند. این تصاویر با کیفیت بالا و تصحیحات دقیق، مبنای مناسبی برای هدف مطالعه حاضر، یعنی پایش جنگل‌زدایی، می‌باشند. باندهای آبی، سبز، قرمز و مادون‌قرمز نزدیک (NIR) نیز از بین باندهای موجود انتخاب شدند.



شکل ۲. شکل الف استان آذربایجان شرقی و شکل ب محدوده جنگل‌های ارسباران

علیرغم استفاده گسترده از تصاویر ماهواره‌ای در تشخیص و نظارت بر جنگل‌زدایی، این روش برای شناسایی تخریب‌های محلی و کوچک، به‌ویژه در تشخیص تخریب جزئی جنگل ناشی از قطع درختان، محدودیت‌هایی دارد [۴۴]. با این حال، تصاویر با حد تفکیک مکانی بالاتر معمولاً پیچیدگی بیشتری را نیز نشان می‌دهند و به تصاویر بیشتری برای پردازش و محاسبه نیاز دارند که برای پایش و

<sup>۱</sup> Collection

<sup>۲</sup> Level

تحلیل جنگل در مقیاس بزرگ مناسب نیستند؛ بنابراین، در این مطالعه از داده‌های چند زمانه با حد تفکیک مکانی متوسط برای آماده‌سازی داده‌های آموزشی، اعتبارسنجی و آزمایشی برای الگوریتم طبقه‌بندی استفاده شد. با این حال، حد تفکیک زمانی نیز باید در ارزیابی پویایی تغییرات جنگل و مشخصات آن در نظر گرفته شود و این امر به‌طور معمول نیاز به دوره‌های مشاهده طولانی‌تر برای پیش‌تغییرات آهسته جنگل دارد. به‌عبارت‌دیگر، تصاویر ماهواره‌ای با حد تفکیک و تناوب زمانی کافی برای تشخیص تخریب پوشش جنگلی موردنیاز هستند [۹، ۴۵]. به همین دلیل در این مطالعه از تصاویر ماهواره Landsat برای تشخیص و طبقه‌بندی استفاده می‌شود. جدول ۱ همچنین تعداد تصاویر اخذشده از ناحیه ریشی ارسباران در ایران را خلاصه می‌کند. در تهیه تصاویر دقت شده است که فاصله زمانی بین تصاویر، در سال‌های مختلف، نزدیک باشد تا از تأثیرات فصلی که می‌تواند بر عملکرد و پیش‌بینی مدل تأثیر بگذارد، جلوگیری شود.

جدول ۱. تعداد تصاویر تهیه‌شده به تفکیک سال و تاریخ

سال	۲۰۰۰	۲۰۱۰	۲۰۲۲
تاریخ تصاویر:	۲۰ ژانویه	۲ جولای	۱۱ جولای
	۹۰	۱۲۷	۱۰۳
	۲۲ جولای	۳ اوت	۱۹ جولای
مجموع/۶۷۴	۲۱۱	۲۴۵	۲۱۸

### ۲-۲-۲- تصاویر واقعیت زمینی


مجموعه داده واقعیت زمینی، با ایجاد یک لایه از ماسک اطراف مرز جنگل، آماده‌شده است. درحالی‌که بخش‌های غیر جنگلی باقی‌مانده به‌عنوان پس‌زمینه در نظر گرفته‌شده‌اند. این فرآیند نیازمند تعیین دقیق جنگل و درختان برای ساخت بهترین نقشه ماسک است. برای تهیه تصاویر واقعیت زمینی با سرعت و دقت بالا از شاخص پوشش گیاهی تفاضلی نرمال‌شده<sup>۱</sup> (NDVI) استفاده شده است [۴۶]. بعد از تهیه تصویر NDVI، یک حد آستانه برای تفکیک مقادیر تصویر تعیین می‌شود. سپس، مقادیر تصویر NDVI به دو مقدار ۰ و ۱ (یعنی باینری) تبدیل شده و

ماسک نهایی تولید می‌گردد. همچنین این ماسک‌ها به‌صورت بصری بررسی و اصلاح‌شده‌اند. در این بررسی بصری، بخش‌هایی که زمین کشاورزی بودند نیز حذف‌شده‌اند. برای مثال، در شمال غرب شکل ۳ مناطق کشاورزی وجود داشت و در ماسک اصلاح‌شده (شکل ۳-ج) حذف شد. باید به این نکته هم اشاره کرد که برای تهیه ماسک نواحی جنگلی، بر روی نواحی‌ای که به اندازه کافی مترکم بودند تمرکز شده است و درختان پراکنده جزو ماسک قرار نگرفتند. به‌عبارت‌دیگر، بخش‌های جنگلی که در ماسک تهیه‌شده توسط NDVI به‌صورت تک پیکسل یا دو پیکسل بودند حذف شدند. در نهایت، هر تصویر ماهواره‌ای، دارای یک ماسک متناظر است که یک آرایه از مقادیر باینری ۰ و ۱ است که مکان مناطق جنگلی و غیر جنگلی در هر تصویر را نشان می‌دهد. شکل ۳ نمونه‌ای از تصاویر ماهواره‌ای و ماسک واقعیت زمینی متناظر آن‌ها را نمایش می‌دهد که نواحی جنگلی به رنگ سفید و نواحی غیر جنگلی به رنگ مشکی دیده می‌شوند.

### ۲-۲-۳- پیش‌پردازش تصاویر و تقسیم مجموعه داده

پیش‌پردازش تصاویر از طریق تقویت داده در توانمندسازی شبکه‌های عصبی برای یادگیری با استحکام بیشتر در برابر بسیاری از ویژگی‌های ثابت مؤثر بوده است [۴۷]. در این کار، ابتدا اندازه تصاویر ورودی به ابعاد  $4 \times 256 \times 256$  کاهش داده شد، سپس تصاویر تحت دوران  $90^\circ$  درجه و وارون افقی قرار گرفتند که امکان ایجاد تصاویر جدید از تصاویر اصلی را فراهم می‌کند. این عمل انجام شد تا بتوان مدل عمیق را بر روی جنگل یکسان اما از دیدگاه‌های مختلف آموزش و اعتبارسنجی کرد. همچنین، مقادیر تصاویر در محدوده ۰ و ۱ به‌عنوان یک روش معمول پردازش در برنامه‌های بینایی ماشینی نرمال شدند. در نهایت مجموعه داده تهیه‌شده به ۷۰٪ داده آموزشی (۴۵۸ تصویر)، ۱۰٪ داده اعتبارسنجی (۶۵ تصویر) و ۲۰٪ داده آزمایشی (۱۵۴ تصویر) که در مراحل آموزش و اعتبارسنجی استفاده نشدند) تقسیم شدند. تصاویر واقعیت زمینی هم به همین ترتیب دسته‌بندی شدند.

<sup>۱</sup> Normalized Difference Vegetation Index (NDVI)



شکل ۳. (الف) تصویر رنگ طبیعی؛ (ب) ماسک واقعیت زمینی متناظر تهیه شده با استفاده از NDVI و (ج) ماسک اصلاح شده

## ۲-۳- معماری یادگیری عمیق

این بخش معماری یادگیری عمیق مورد استفاده برای آموزش مدل را معرفی می کند.

### ۲-۳-۱- مدل U-Net

U-Net یکی از مدل های رایج استفاده شده در کاربردهای مختلف است که بر قطعه بندی موضوعی تکیه دارد و به طور کارآمد برای قطعه بندی تصاویر پزشکی معرفی شده است [۴۸].

این مدل به طور اصلی بر اساس دو عنصر کدگذار<sup>۱</sup> و کدگشا<sup>۲</sup> تمرکز دارد، شکل ۴ (شکل پایین). کدگذار معمولاً یک شبکه عصبی عمیق از پیش آموزش داده شده است. برای به دست آوردن ویژگی های کلیدی در سطوح مختلف، کدگذار از تکراری از دو لایه پیچشی  $3 \times 3$  به دنبال تابع فعال سازی<sup>۳</sup> ReLU و کاهش اندازه<sup>۴</sup> با استفاده از max-pool  $2 \times 2$  با گام ۲ تشکیل شده است. برای هر دور کاهش اندازه، تعداد کانال های ویژگی دو برابر می شود. از طرف دیگر، کدگشا از لایه های افزایش اندازه<sup>۵</sup> و لایه های ادغام با عملیات پیچش معمولی تشکیل شده است. هدف، ارائه ویژگی های تمیز دهنده که توسط کدگذار در فضای پیکسل یاد گرفته شده است، به منظور دستیابی به نمایشی با دقت بالاتر است.

علاوه بر این، اتصالات پرش<sup>۶</sup> در کدگشا باعث جریان بهتر گرادین ها و تهیه اطلاعات از تصاویر می شود. ویژگی های موضوعی استخراج شده از لایه های بالا توانایی تشخیص تمایز را افزایش می دهند، در حالی که ویژگی های آمده از لایه های عمیق، موتور قطعه بندی را پشتیبانی می کنند. یک sigmoid به صورت پیکسل پایه روی آخرین نقشه ویژگی با تابع ضرر<sup>۷</sup> binary\_crossentropy ترکیب می شود تا تابع انرژی را که برچسب پیکسل تصویر را پیش بینی می کند، محاسبه کند.

یک تغییر مهم در کدگذار اصلی U-Net که توسط رونبرگ و همکاران [۴۸] معرفی شده بود، اعمال شده است تا نقشه های ویژگی با ابعاد پایین تر به دست آید، همان طور که در شکل ۴ (شکل بالا) نشان داده شده است. در کدگذار، اندازه تصویر به تدریج کاهش می یابد در حالی که عمق آن به تدریج افزایش می یابد. پس از عبور تصویر ماهواره ای ورودی از دو لایه پیچش و اعمال max-pooling برای کاهش اندازه تصویر، تعداد لایه ها با دو برابر کردن تعداد فیلترها در هر بلوک پیچش افزایش می یابد. کدگذار از  $32 \times 32$  فیلتر با اندازه تصویر  $256 \times 256$  در هر لایه پیچش شروع می شود و سپس تعداد فیلترها به  $64 \times 64$  افزایش می یابد و اندازه تصویر به  $128 \times 128$  برای بلوک پیچش دوم کاهش می یابد. در بلوک پیچش سوم، تعداد فیلترها برای هر لایه  $128 \times 128$  است با اندازه تصویر  $64 \times 64$ ، اما در لایه چهارم به  $32 \times 32$  با  $256 \times 256$  فیلتر کاهش می یابد. این فرآیند ادامه دارد تا به تصویر با اندازه  $16 \times 16$  و  $512$  فیلتر برسیم. این فرآیندها به عنوان یک فرآیند استخراج ویژگی عمل

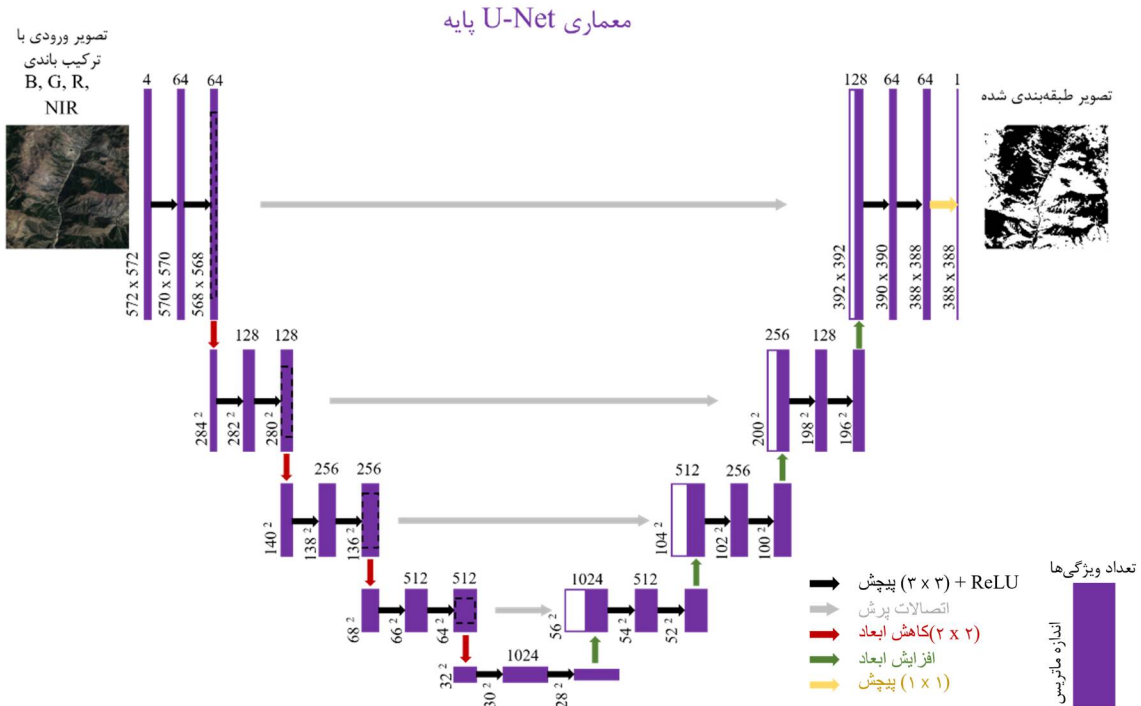
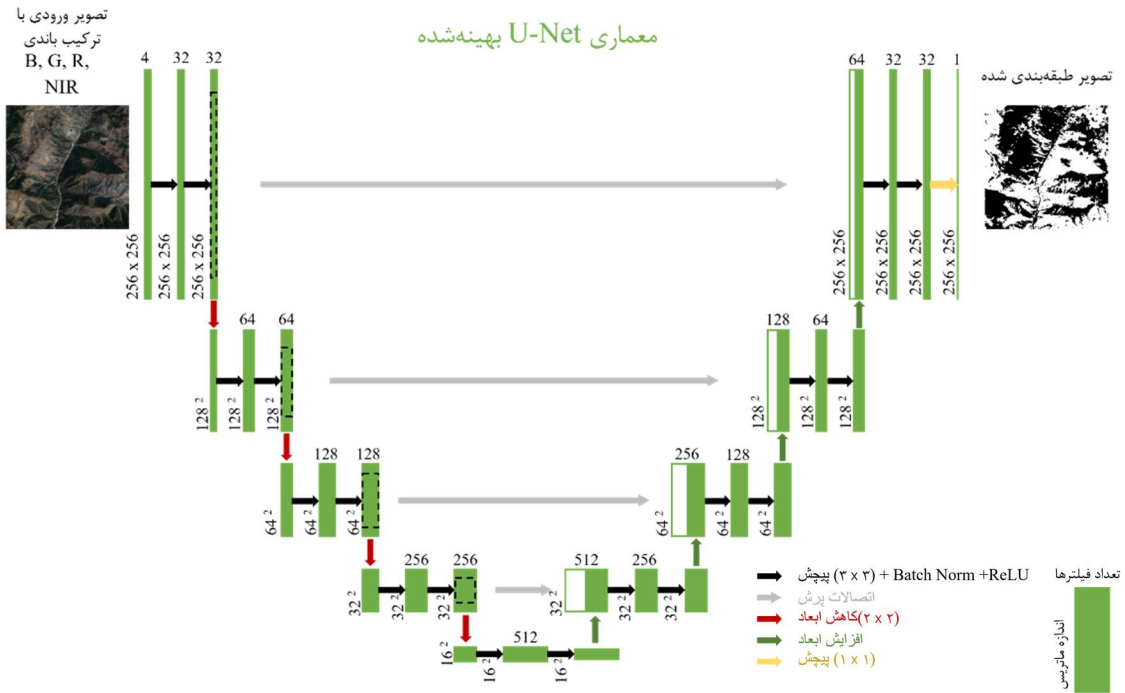
- ۱ Encoder
- ۲ Decoder
- ۳ Activation function
- ۴ Downsampling
- ۵ Upsampling

۶ Skip connection

۷ Loss function

می‌شود و با ۳۲ فیلتر برای هر لایه پیچش پایان می‌یابد. مجموعه نقشه‌های موضوعی حاصل، در لایه‌های بالا، با استفاده از Sigmoid، برای تعیین کلاس پیکسل، یعنی جنگل یا غیر جنگل، استفاده می‌شود.

می‌کنند؛ بنابراین، هدف اینجا کاهش ابعاد و افزایش عمق، یعنی تعداد لایه‌ها است. در سمت کدگشا، مجموعه‌ای از بلوک‌های پیچش با دو لایه پیچش در هر کدام وجود دارد. تعداد فیلترها برای هر بلوک پیچش متوالی معادل نصف فیلترهای بلوک پیچش قبلی است که با ۵۱۲ فیلتر شروع



شکل ۴. معماری U-Net بهینه‌شده (شکل بالا) و معماری U-Net پایه ارائه‌شده در [۴۸] (شکل پایین)



## ۲-۴- استخراج ویژگی

در فرآیند استخراج ویژگی، از خروجی لایه‌های تبدیل پیچش آخر مدل استفاده شد. تصویر ورودی با ابعاد  $256 \times 256 \times 4$  وارد شد و داده‌های پیکسلی به آرایه عددی تبدیل و برای تشکیل ویژگی‌های تصویر اولیه نرمال‌سازی شدند. فرآیند طبقه‌بندی، هر پیکسل در تصویر داده‌شده را با پیش‌بینی برچسب آن (جنگل یا غیر جنگل) طبقه‌بندی می‌کند. این کار به‌عنوان پیش‌بینی شناخته می‌شود زیرا برای هر پیکسل در تصویر اعمال می‌شود. به‌طور خاص، مدل عمیق با یک تصویر  $4 \times 256 \times 256$  طیفی با ابعاد  $4 \times 256 \times 256$  تغذیه و یک نقشه طبقه‌بندی تولید می‌شود که هر پیکسل دارای یک برچسب کلاس است. شایان‌ذکر است که نمونه‌های یک کلاس مشخص به‌عنوان اجزا جداگانه تلقی نمی‌شوند [۴۹]، به‌عبارت‌دیگر، اگر دو جنگل در تصویر ورودی ظاهر شوند، نقشه طبقه‌بندی آن‌ها را به‌عنوان کلاس جداگانه تشخیص نمی‌دهد. این روش برای همه تصاویر آموزشی و اعتبارسنجی به‌منظور یادگیری بهترین ویژگی‌های تمیز دهنده تصاویر چند زمانه ماهواره‌ای اعمال می‌شود.

## ۲-۵- فرآیند پایش جنگل‌زدایی

فرآیند نظارت بر جنگل‌زدایی با تغذیه مدل عمیق آموزش‌دیده نهایی با مجموعه‌ای از تصاویر آزمایشی به اتمام می‌رسد. شکل ۵ روش کلی انجام‌شده را نشان می‌دهد که به مدل عمیق اجازه می‌دهد تا برای هر دو تصویر آزمایشی از سال‌های مختلف میزان جنگل‌زدایی یا جنگل‌زایی را مشخص کند. برای دریافت نرخ تغییر در جنگل‌های ارسباران در سال‌های مختلف، تصاویر مربوط به آن انتخاب و نرخ شباهت در این تصاویر محاسبه می‌شود و تصمیم گرفته می‌شود که تغییر کاهش مساحت جنگل (جنگل‌زدایی) یا افزایش مساحت جنگل (جنگل‌زایی) چگونه است. این رویه بر روی جنگل‌های ارسباران در مدت‌زمان ۲۲ سال انجام خواهد شد.

از کتابخانه ImageChops Pillow (PIL Fork) [۵۰] برای محاسبه نرخ شباهت/تفاوت بین نقشه‌های طبقه‌بندی‌شده یک منطقه خاص از جنگل در سال‌های مختلف استفاده خواهد شد. این کتابخانه اختلاف بین دو تصویر طبقه‌بندی‌شده را محاسبه می‌کند. از آنجایی که

مقادیر تصاویر طبقه‌بندی‌شده ۰ و ۱ است، نقشه تغییرات حاصل‌شده دارای مقادیر ۰-۱ و ۱ است. این کتابخانه مقادیر ۰-۱ و ۱ را که به ترتیب بیانگر کاهش مساحت جنگل و افزایش مساحت جنگل هستند را محاسبه می‌کند و بر اساس تعداد پیکسل کل نقشه، درصد افزایش یا کاهش مساحت جنگل را اعلام می‌کند. اگر اختلاف شباهت در سال مشاهداتی بعدی افزایش یابد، این به‌عنوان رشد جنگل (gain) در نظر گرفته می‌شود؛ در غیر این صورت، به‌عنوان جنگل‌زدایی (loss) در نظر گرفته می‌شود.

## ۲-۶- معیارهای ارزیابی

در این بخش با به‌کارگیری داده‌های واقعیت زمینی تهیه‌شده و خروجی تصویر قطعه‌بندی پیش‌بینی‌شده شبکه و با استفاده از معیارهای ارزیابی که در ادامه توضیح داده خواهد شد، ارزیابی نتایج حاصل می‌گردد.

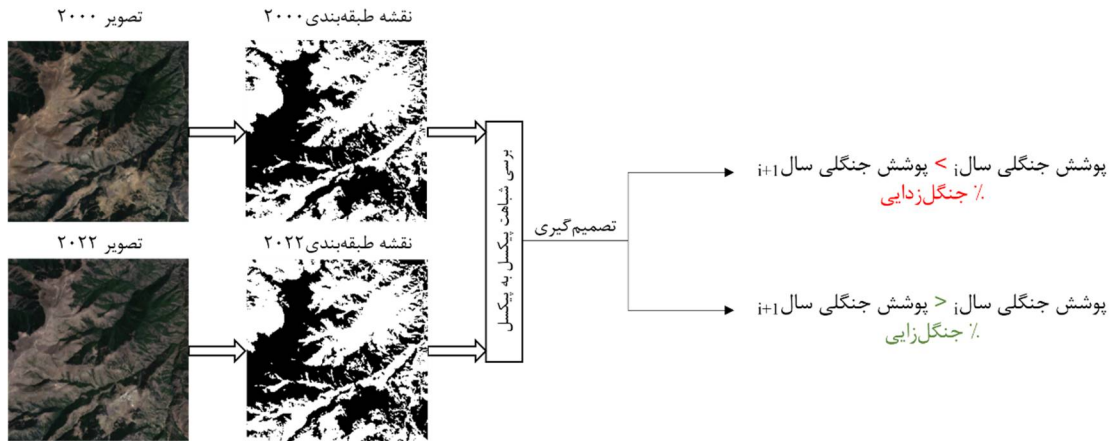
- False Positive (FP) نشان‌دهنده یک نتیجه است که مدل به‌اشتباه کلاس مثبت (جنگل) را پیش‌بینی می‌کند؛ False Negative (FN) نتیجه‌ای است که مدل به‌اشتباه کلاس منفی (غیر جنگل) را پیش‌بینی می‌کند؛ True Positive (TP) نتیجه‌ای است که مدل به‌درستی کلاس مثبت (جنگل) را پیش‌بینی می‌کند؛ True Negative (TN) نتیجه‌ای است که مدل به‌درستی کلاس منفی (غیر جنگل) را پیش‌بینی می‌کند.

- صحت: این معیار نشان‌دهنده نسبت تعداد نمونه‌هایی است که به‌درستی طبقه‌بندی‌شده‌اند (چه مثبت و چه منفی) به کل تعداد نمونه‌ها. صحت به‌عنوان یک معیار مهم در ارزیابی عملکرد مدل‌های طبقه‌بندی استفاده می‌شود و نشان می‌دهد که چه درصدی از پیش‌بینی‌های مدل صحیح بوده‌اند و طبق فرمول ۱ محاسبه می‌شود:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

ضریب کاپا: ضریب کاپا میزان توافق بین طبقه‌بندی واقعی و طبقه‌بندی پیش‌بینی‌شده را اندازه‌گیری می‌کند. این معیار نسبت به شاخص‌های تصادفی تنظیم‌شده است و طبق فرمول ۲ محاسبه می‌شود:

$$K = \frac{pr(a) - pr(e)}{1 - pr(e)} \quad (2)$$



شکل ۵. تصویری ورودی (سمت چپ) و نقشه طبقه‌بندی (سمت راست) که منجر به تصمیم‌گیری کاهش یا افزایش مساحت جنگل می‌شود

### ۳- نتایج

#### ۳-۱- تنظیمات تجربی

مدل با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه‌های Keras پیاده‌سازی و مراحل آموزش، اعتبارسنجی و آزمایش در Google Colab انجام شده است. Google Colab، کارت‌های گرافیک قدرتمندی برای تسریع فرآیند آموزش و اعتبارسنجی در اختیار قرار می‌دهد. تنظیمات ابرپارامترها ضروری است زیرا آن‌ها تأثیر زیادی بر دقت کلی هر مدل آموزش دیده دارند. در این پژوهش، مرحله آموزش با نرخ یادگیری اولیه ۰,۰۰۱، بهینه‌ساز Adam و اندازه بچ ۲۰ آغاز شده و مدت‌زمان آموزش ۲۴,۱۸ دقیقه بود. همچنین، تابع ضرر استفاده شده در این مدل binary\_crossentropy بود. این تابع ضرر برای مسائل طبقه‌بندی باینری (دو کلاس) استفاده می‌شود و تابع فعال‌سازی Sigmoid برای محاسبه دقت پیکسل‌ها به کار می‌رود. هرچند که مدل طبقه‌بندی عمیق بعد از ۳۵ اپک عملکرد پایداری ارائه داد، ولی شبکه با ۱۰۰ اپک آموزش دید تا اطمینان حاصل شود که مدل به‌طور کامل همگرا شده و تمامی ویژگی‌های پیچیده تصاویر را به‌خوبی آموزش دیده است. نتایج نهایی نشان داد که مدل پس از ۱۰۰ اپک به‌دقت بالاتری دست‌یافت و توانست با دقت بیشتری نواحی جنگلی و غیر جنگلی را در تصاویر تشخیص دهد.

که در آن  $pr(e)$  شانس پیش‌بینی درست<sup>۱</sup> است و به‌صورت  $pr(a) = \sum_{i=1}^c \left( \frac{n_a \times n_b}{n^2} \right)$  پیش‌بینی درست<sup>۲</sup> است و به‌صورت  $\frac{\sum_{i=1}^c n_i}{n}$  محاسبه می‌شود. در این دو فرمول  $n_a$  تعداد پیکسل‌هایی است که به کلاس  $a$  تعلق گرفته‌است،  $n_b$  تعداد پیکسل‌هایی است که به کلاس  $b$  تعلق گرفته‌است،  $n_i$  تعداد پیکسل‌هایی است که درست طبقه‌بندی شده‌اند،  $n$  تعداد کل پیکسل‌ها و  $c$  تعداد کلاس‌ها است.

• F1 score: امتیاز F1 میانگین هارمونیک دقت<sup>۳</sup> و بازخوانی است و برای ارزیابی عملکرد مدل در حضور داده‌های نامتوازن مناسب است و طبق فرمول ۳ محاسبه می‌شود:

$$F1 = \frac{Precision \times Recall}{Precision + Recall} \times 2 \quad (3)$$

که در آن دقت به‌صورت  $\frac{TP}{TP+FP}$  و بازخوانی به‌صورت  $\frac{TP}{T+FN}$  محاسبه می‌شود.

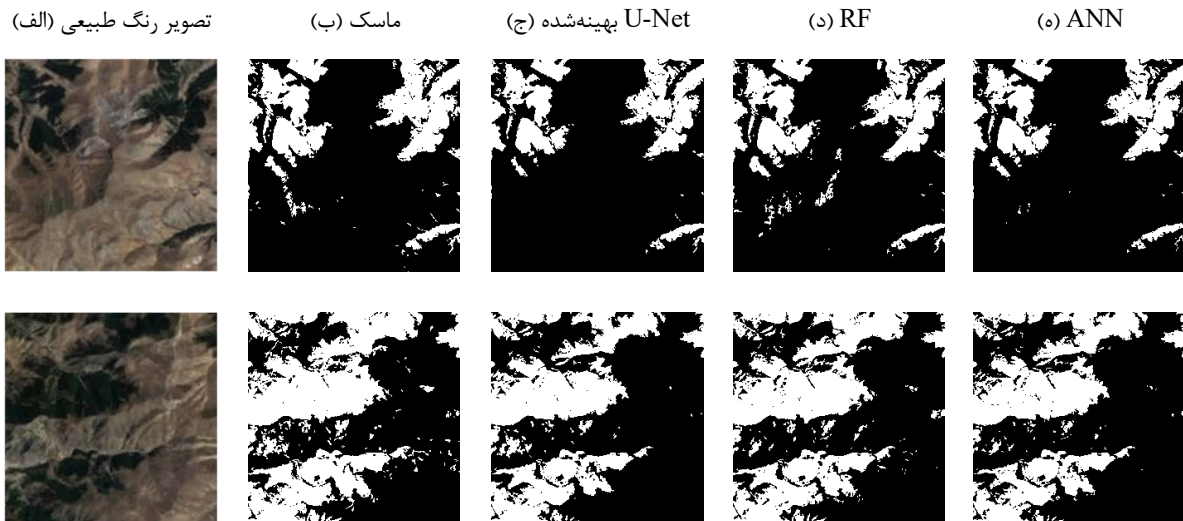
• IoU: معیار عملکردی است که در روش‌های طبقه‌بندی تصویر به کار می‌رود. شاخص IoU مساحت تلاقی بین تصویر واقعیت زمینی و تصویر طبقه‌بندی پیش‌بینی‌شده را به مساحت اتحاد بین آن‌ها تقسیم می‌کند و طبق فرمول ۴ محاسبه می‌شود:

$$IoU = \frac{TP}{TP + FP + FN} \quad (4)$$

۱ ChanceAgree

۲ Agree

۳ Precision



شکل ۷. نمونه‌هایی از تصاویر طبقه‌بندی شده توسط U-Net بهینه شده برای ارزیابی عملکرد: (الف) رنگ طبیعی؛ (ب) ماسک؛ (ج) طبقه‌بندی شده توسط U-Net بهینه شده؛ (د) طبقه‌بندی شده توسط RF و (ه) طبقه‌بندی شده توسط ANN. مناطق سفید نشان‌دهنده کلاس جنگل هستند و مناطق سیاه نشان‌دهنده نواحی غیر جنگلی

### ۲-۳- نتایج طبقه‌بندی

شکل ۷ تعدادی از تصاویری که توسط شبکه عمیق U-Net بهینه شده طبقه‌بندی شده‌اند را نشان می‌دهد و آن‌ها را با ماسک‌های تولیدشده و طبقه‌بندی به دست آمده توسط الگوریتم‌های جنگل تصادفی و شبکه عصبی مصنوعی مقایسه می‌کند (مقایسه با روش‌های مرسوم یادگیری ماشین).

جدول ۲. مقایسه معیارهای ارزیابی بین U-Net و ANN، RF بهینه شده

	U-Net بهینه شده	RF	ANN
صحت کلی (%)	۹۶,۵۳	۹۳,۰۸	۹۴,۹۲
کاپا (%)	۹۱,۵۵	۷۹,۳۱	۸۵,۰۸
امتیاز F1 (%)	۹۴,۶۸	۸۳,۶۳	۸۸,۲۹
IoU (%)	۹۰,۰۴	۷۱,۸۷	۷۹,۰۴

به‌عنوان پس‌پردازش، تصاویر طبقه‌بندی شده توسط کرنل رأی‌گیری اکثریت<sup>۱</sup> با کرنل  $3 \times 3$ ، پردازش شدند تا نویزهای نقطه‌ای از بین بروند. نتایج نشان می‌دهد که تصاویر تولیدشده توسط شبکه عمیق U-Net بهینه شده شباهت زیادی، به تصاویر رنگ طبیعی و ماسک‌ها دارند. این

موضوع توسط مقادیر به دست آمده برای معیارهای ارزیابی، همان‌طور که در جدول ۲ نشان داده شده، تأیید می‌شود.

### ۳-۳- نتایج پایش جنگل‌زدایی

تصاویر طبقه‌بندی شده، که توسط مدل عمیق به دست آمده‌اند، در اینجا برای پایش و تحلیل هرگونه تغییراتی که در جنگل‌های ارسباران بین سال‌های ۲۰۰۰ و ۲۰۲۲ رخ داده است، استفاده و درصد تغییرات به لحاظ کاهش مساحت جنگل (جنگل‌زدایی) یا افزایش مساحت جنگل (جنگل‌زایی) محاسبه می‌شوند. شکل ۸ نمونه‌ای از جنگل را نشان می‌دهد که در آن تغییرات ایجاد شده در دوره مدنظر، تعیین شده است. مقادیر کاهش یا افزایش نشان داده شده در هر جفت تصویر، توسط بررسی مطلق مشابهت پیکسل به پیکسل محاسبه شده است. به‌عنوان مثال، شکل ۸ (الف) یکی از پوشش‌های جنگلی در جنگل‌های ارسباران را نشان می‌دهد که جعبه‌های قرمز بخش‌هایی از جنگل را که به میزان ۶,۸۸٪ تحت تأثیر جنگل‌زدایی و جعبه‌های سبز بخش‌هایی از جنگل را که به میزان ۱,۴۸٪ تحت تأثیر جنگل‌زایی قرار گرفته‌اند، به‌عنوان نمونه نمایش می‌دهد. شکل ۸ (ب) هم رشد جنگل به میزان ۰,۸۱٪ و کاهش جنگل به میزان ۶,۲۷٪ را نشان می‌دهد.

<sup>۱</sup> Majority Voting Kernel


تغییرات در مساحت جنگل‌زدایی و جنگل‌زایی در این سه دوره زمانی محاسبه شده است. سپس مجموع کاهش و افزایش مساحت جنگل در تمامی مناطق به صورت کلی ارائه شده است. این تحلیل جامع کمک می‌کند تا روندهای کلی در جنگل‌زدایی و جنگل‌زایی در منطقه مورد مطالعه بهتر درک شود و اقدامات مناسبی برای حفاظت و مدیریت جنگل‌ها انجام پذیرد. این جدول نشان می‌دهد که سطح جنگل‌های ارسباران از سال ۲۰۰۰ تا ۲۰۲۲ افزایش داشته است. این نتایج نشان‌دهنده تغییرات مثبت در پوشش جنگلی ارسباران طی دو دهه گذشته است و بیانگر موفقیت تلاش‌ها برای حفظ و احیای جنگل‌ها در این منطقه می‌باشد [۵۱].

جدول ۳. نتایج کلی پایش جنگل‌زدایی


دوره زمانی	افزایش مساحت جنگل (کل٪)		کاهش مساحت جنگل (کل٪)		تصمیم‌گیری
	۲۰۱۰-۲۰۰۰	۲۰۲۲-۲۰۱۰	۲۰۲۲-۲۰۰۰	۲۰۲۲-۲۰۱۰	
جنگل‌زدایی	۱۶,۹۴	۴۴,۵	۲۷,۷۸	۳۲,۶۹	جنگل‌زدایی
جنگل‌زایی	۲۰۱,۰۴	۲۱,۸۶	۱۴,۸۹	۲۱,۸۶	جنگل‌زایی

مقایسه تصاویر ماهواره‌ای با ماسک‌ها و تصاویری که توسط شبکه U-Net بهینه‌شده طبقه‌بندی شده‌اند، نشان می‌دهد که در برخی موارد، این شبکه موفق شده است نواحی جنگلی را که در فرآیند تهیه ماسک اولیه شناسایی نشده بودند، به درستی طبقه‌بندی کند (شکل ۱۰). این موضوع نشان‌دهنده توانایی بالای مدل آموزش‌دیده در شناسایی و طبقه‌بندی پوشش جنگلی است، حتی زمانی که مجموعه آموزشی دارای نواقصی باشد. همچنین، شبکه U-Net بهینه‌شده پیشنهادی توانسته است به خوبی بین نواحی کشاورزی و نواحی جنگلی تمایز قائل شود. این شبکه با دقت بالا، نواحی کشاورزی را که در ماسک اولیه حذف شده بودند، شناسایی کرده و از طبقه‌بندی این نواحی به همراه نواحی جنگلی جلوگیری کرده است (شکل ۱۱). این عملکرد نشان‌دهنده توانایی بالای مدل بهینه‌شده در تشخیص دقیق و طبقه‌بندی صحیح پوشش جنگلی است.

شکل ۹ چندین منطقه نمونه را به همراه تصاویر رنگ طبیعی متناظر نمایش می‌دهد که کاهش یا افزایش مساحت پوشش جنگلی را نشان داده‌اند. افزایش در مساحت جنگل‌ها در سال ۲۰۲۲ به دلیل فرآیندهای جنگل‌کاری که اخیراً توسط سازمان‌های دولتی و خصوصی انجام شده است، اتفاق افتاده است [۵۱]. با این حال، بسیاری از جنگل‌ها در سال‌های مابین ۲۰۰۰ و ۲۰۱۰ توسط مدل U-Net بهینه‌شده با نرخ‌های بالای کاهش تشخیص داده شده‌اند. بر اساس آزمایش‌های دقیق انجام شده بر روی جنگل‌های ارسباران، این نتیجه حاصل می‌شود که مدل عمیق موضوعی ارائه شده می‌تواند پوشش جنگلی را به طور مؤثری طبقه‌بندی کرده و هرگونه تغییر را از نظر برآورد کاهش و افزایش مساحت شناسایی کند.



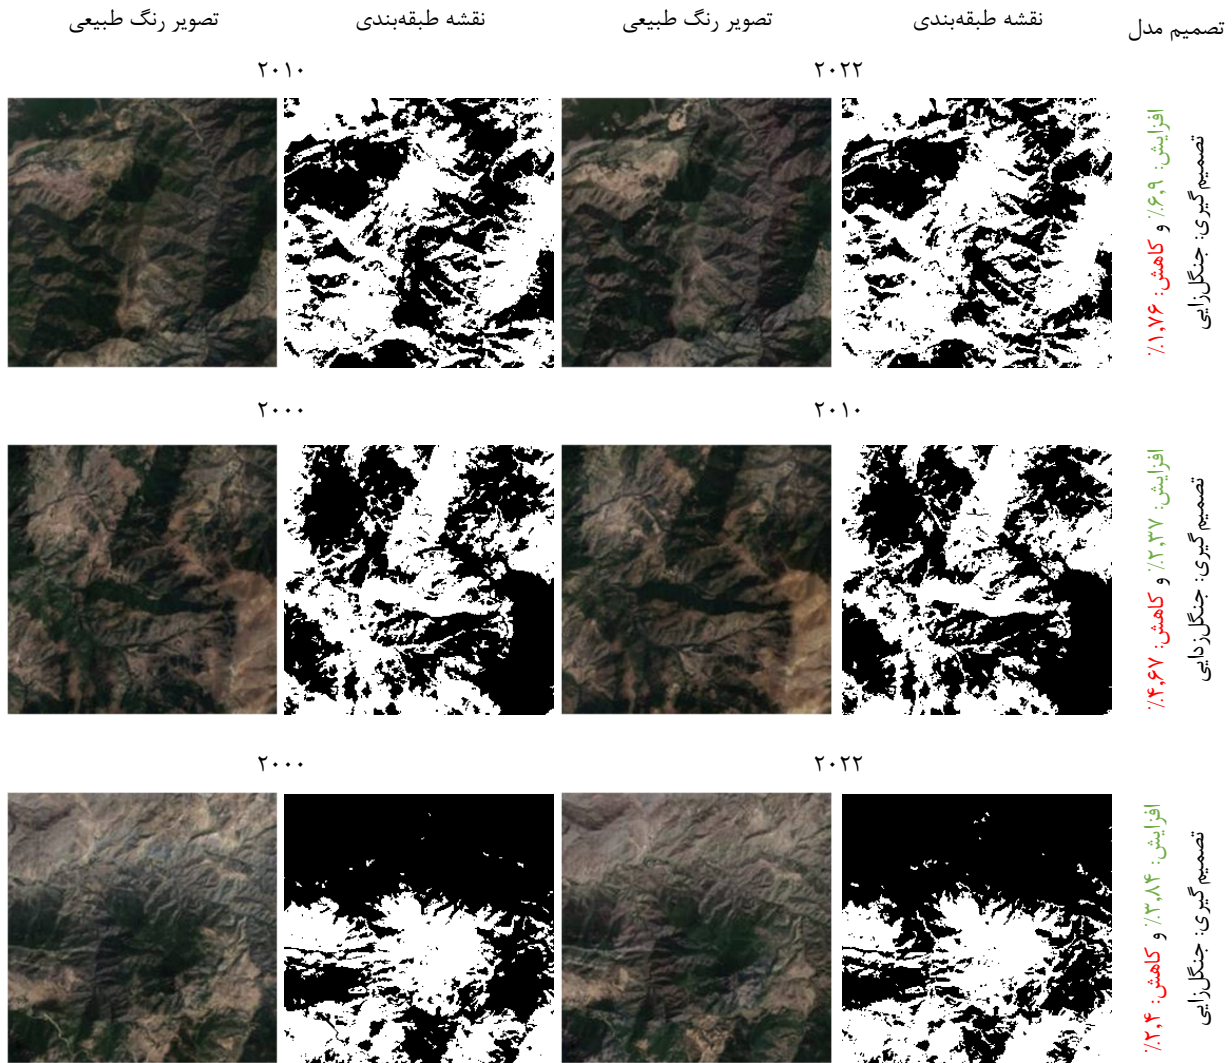
الف) مدل ۱,۴۸٪ افزایش مساحت جنگل و ۶,۸۸٪ کاهش مساحت جنگل شناسایی کرد. تصمیم‌گیری: جنگل‌زدایی



ب) مدل ۰,۸۱٪ افزایش مساحت جنگل و ۶,۲۷٪ کاهش مساحت جنگل شناسایی کرد. تصمیم‌گیری: جنگل‌زدایی

شکل ۸. میزان افزایش و کاهش شناسایی شده توسط مدل

نتایج کل پایش جنگل‌زدایی در بازه‌های زمانی ۲۰۰۰-۲۰۱۰، ۲۰۱۰-۲۰۲۲ و ۲۰۲۲-۲۰۰۰ در جدول ۳ ارائه شده است. در این جدول، برای هر منطقه جنگلی،



شکل ۹. نمونه‌هایی از پایش جنگل‌زدایی در سه دوره ۲۰۱۰-۲۰۲۲، ۲۰۱۰-۲۰۰۰ و ۲۰۲۲-۲۰۰۰


#### ۴- بحث

در این بخش، نتایج تجربی در زمینه طبقه‌بندی اعمال‌شده بر پوشش جنگلی، پایش جنگل‌زدایی و نقاط قوت و محدودیت‌های مدل بیشتر مورد بحث قرار می‌گیرد. پس از گزارش ارزیابی عملکرد، مدل آموزش‌دیده U-Net بهینه‌شده برای شناسایی جنگل‌زدایی یا جنگل‌زایی با استفاده از تحلیل چند زمانه تصاویر ماهواره‌ای اعمال شد. برای این منظور، یک جفت از تصاویر ماهواره‌ای از یک منطقه یکسان انتخاب و به‌عنوان تصاویر ورودی به مدل عمیق وارد شدند. به‌منظور دستیابی به چنین شناسایی جنگل، پیکسل‌های تصاویر جفتی با ماسک مرجع جنگل مقایسه شدند تا عملکرد معماری عمیق در طبقه‌بندی نواحی جنگل در تصاویر ورودی، ارزیابی شود.


#### ۴-۱- شناسایی مرزهای جنگل

پیشینه تحقیق انجام‌شده نشان می‌دهد که هیچ مطالعه‌ای در ادبیات علمی وجود ندارد که از شبکه‌های عصبی پیچشی برای نظارت بر جنگل‌زدایی در ایران با استفاده از تصاویر ماهواره‌ای استفاده کرده باشد. با این حال، نتایج مطالعات مرتبط که از این شبکه‌ها استفاده کرده‌اند، کاربرد شبکه‌های عصبی پیچشی در تحلیل پوشش جنگلی را تأیید می‌کنند. این نتایج نشان‌دهنده U-Net به‌عنوان یک کدگذار-کدگشا تصویری قوی است [۳۰-۳۸].

نتایج تجربی نشان می‌دهند که تصاویر خروجی تولیدشده توسط مدل عمیق ارائه‌شده همخوانی بالایی با تصاویر رنگ طبیعی و تصاویر ماسک مرجع دارند.



شکل ۱۰. مثال هایی از مناطقی که به درستی به عنوان غیر جنگل طبقه بندی شده اند در حالی که در طی فرآیند تهیه ماسک اولیه شناسایی نشده بودند



شکل ۱۱. مناطق کشاورزی که توسط شبکه U-Net بهینه شده به درستی شناسایی و از مناطق جنگلی تفکیک شده اند (الف) تصویر رنگ طبیعی، (ب) ماسک تهیه شده، (ج) تصویر پیش بینی شده توسط U-Net بهینه شده


مرزهای جنگلی در تصاویر ماهواره ای به طور عمده مشخص نیستند و چنین مکان های جنگلی نامشخصی حتی توسط یک بازرس بصری خیره نیز دشوار است که طبقه بندی شوند. این محدودیت باعث کاهش کمی در معیارهای ارزیابی طبقه بندی می شود، به طور مثال، تقریباً ۹٪ در کاپا و ۱۰٪ در IoU کاهش مشاهده می شود.

با این حال، در طبقه بندی تصویر توسط مدل، پیکسل هایی وجود دارند که به اشتباه طبقه بندی شده اند (جنگل به جای پس زمینه یا برعکس) که عمدتاً در مرز بین مناطق جنگلی و غیر جنگلی متمرکز هستند. طبقه بندی چنین پیکسل هایی عموماً چالش برانگیزتر و سخت تر از پیکسل های داخلی یا خارجی مناطق جنگلی هستند. به ویژه،

#### ۴-۲- اثربخشی پایش تغییرات پوشش جنگلی

نتایج پایش نشان‌دهنده قابلیت مدل ارائه شده در شناسایی تغییرات پوشش جنگلی در جنگل‌های ارسباران است. شکل ۱۰ این امکان را می‌دهد تا بازرسی بصری چندین منطقه از تغییرات پوشش جنگلی که به درستی شناسایی شده‌اند، انجام شود. دوره زمانی که در آن جنگل‌زدایی/جنگل‌زایی رخ داده است را می‌توان از زمان اخذ تصاویر تعیین کرد که این یک نیاز اساسی برای اثربخشی هرگونه اقدامات محیط‌زیستی است.

مقایسه بین نتایج فرآیند پایش جنگل‌زدایی ارائه شده و تغییرات جنگل گزارش شده در سکو GFW می‌تواند اعتبارسنجی اضافی به پیش‌بینی‌های مدل ارائه دهد. روند کاهش جنگل گزارش شده در سکو GFW برای شهر کلیر (شامل منطقه حفاظت شده ارسباران و دیزمار) از سال ۲۰۰۱ تا ۲۰۲۲ روندی کاهشی بوده است (شکل ۱۲) و از سوی دیگر در این بازه زمانی، میزان افزایش مساحت جنگل بیشتر از کاهش مساحت جنگل بوده است (شکل ۱۳). این نتایج با داده‌های فرآیند پایش جنگل‌زدایی ارائه شده نیز تطابق دارد، به طوری که گزارش شد از سال ۲۰۰۰ تا ۲۰۲۲ میزان جنگل‌های منطقه حفاظت شده ارسباران افزایش داشته است.



شکل ۱۲. کاهش پوشش درختی در کلیر، آذربایجان شرقی مستخرج از GFW در بازه ۲۰۰۱-۲۰۲۲

خواهد شد، زیرا درختان جوان به اندازه کافی بزرگ می‌شوند تا تاج درختی کامل را تشکیل دهند. نکته مهم در این زمینه این است که کاهش جنگل مشاهده شده توسط GFW در کلیر به طور عمده با خروجی فرآیند پایش جنگل‌زدایی ارائه شده مطابقت دارد.



شکل ۱۳. اجزا تغییر پوشش درختی در کلیر، آذربایجان شرقی مستخرج از GFW در بازه ۲۰۰۱-۲۰۲۲

#### ۴-۳- محدودیت‌های پژوهش

محدودیت اصلی مدل ارائه شده در مشاهده پیش‌بینی‌های مربوط به حاشیه جنگل آشکار شد. مشاهده شد که کدگذار-کدگشای طبقه‌بندی قادر به پردازش دقیق برخی جزئیات تصویر، مانند تغییرات ناشی از درختان پراکنده در نزدیکی مرزهای جنگل، نیست؛ بنابراین، استفاده از مدل طبقه‌بندی ارائه شده که با مجموعه داده‌های تصویری ماهواره‌ای آموزش داده شده است، ممکن است نیازمند یک فرآیند پس‌پردازش برای غلبه بر چنین محدودیت‌هایی باشد.

بخشی دیگر از عملیات پس‌پردازش، بررسی هشدارهای جنگل‌زدایی است. به طور خاص، زمانی که هشدارهای جنگل‌زدایی توسط فرآیند پایش گزارش می‌شود نیاز به تأیید مناطق جنگل‌زدایی، وجود دارد. در این پژوهش هیچ فرآیند پس‌پردازشی انجام نشده است.

#### ۵- نتیجه‌گیری

این مطالعه یک مدل یادگیری عمیق مبتنی بر شبکه U-Net را برای پایش خودکار جنگل‌زدایی در

با این حال، کاهش پوشش درختی گزارش شده در GFW ممکن است به دلایل مختلفی از جمله جنگل‌زدایی، آتش‌سوزی و برداشت درختان در طول عملیات پایدار جنگل‌داری باشد؛ بنابراین، در جنگل‌های مدیریت شده به صورت پایدار، این کاهش در نهایت به عنوان بازایی ثبت

جنگل‌های ارسباران معرفی می‌کند. با استفاده از مدل U-Net بهینه‌شده مجموعه‌ای از ویژگی‌های متمایزکننده از تصاویر ماهواره‌ای استخراج شدند و برای شناسایی نواحی جنگلی در جنگل‌های ارسباران به کار گرفته شدند. نتیجه بهینه‌سازی شبکه پایه U-Net، کاهش پارامترها از ۳۱ میلیون به ۷ میلیون بود که با توجه به تعداد تصاویر، این بهینه‌سازی باعث بهبود عملکرد مدل شد و از بیش‌برازشی مدل جلوگیری کرد. همچنین یک مجموعه داده جدید از تصاویر ماهواره‌ای برای پوشش جنگلی ارسباران تهیه شد که به مطالعات آینده در زمینه تجزیه و تحلیل و تحقیق در مورد تغییرات محیطی در این جنگل‌ها کمک خواهد کرد. این مجموعه داده شامل تصاویر ماسک واقعیت زمینی جنگل‌هایی است که از سال‌های ۲۰۱۰، ۲۰۰۰ و ۲۰۲۲ برای پیش‌بینی جنگل‌زدایی ثبت‌شده‌اند.

چارچوب مدل یادگیری عمیق ارائه‌شده شامل سه مرحله اصلی است. مرحله اول: تصاویر ورودی با استفاده از افزایش داده پیش‌پردازش می‌شوند تا توانایی مدل موضوعی عمیق در شناسایی جنگل‌ها از زوایای مختلف بهبود یابد. مرحله دوم: مدل U-Net بهینه‌شده آموزش داده می‌شود تا ویژگی‌های کلیدی هر تصویر جنگل را به صورت موضوعی به دست آورد. نتایج نشان داد که U-Net بهینه‌شده نسبت به روش‌های مرسوم یادگیری ماشین (جنگل تصادفی و شبکه عصبی مصنوعی) در قطعه‌بندی تصویر به جنگل یا غیر جنگل، برتری دارد که در نتیجه صحت کلی ۹۶٫۵۳٪، کاپا ۹۱٫۵۵٪، امتیاز F1 ۹۴٫۶۸٪ و IoU ۹۰٫۰۴٪ به دست آمد. مرحله سوم: تصاویر پیش‌بینی‌شده توسط مدل موضوعی عمیق ارائه‌شده، برای تشخیص هرگونه جنگل‌زدایی یا جنگل‌زایی در طی سال‌های متمادی مقایسه شدند.

مدل ارائه‌شده می‌تواند تغییرات جنگل را به طور دقیق نشان دهد و مقادیر کاهش یا افزایش مساحت جنگل را تخمین بزند. این فرآیند پیش می‌تواند به طور مؤثر به سازمان‌های ملی در تصمیم‌گیری سریع‌تر کمک کند.

این مطالعه همچنین نشان داد که پوشش جنگلی در ارسباران در حال احیا و افزایش است که از تجزیه و تحلیل تصاویر بین سال‌های ۲۰۰۰ و ۲۰۲۲ به صورت تجربی نتیجه‌گیری شد. با این حال، برخی چالش‌های رایج باید بیشتر مورد توجه قرار گیرند زیرا بر عملکرد مدل تأثیر می‌گذارند. به عنوان مثال، هیچ روش استاندارد برای برخورد با درختان پراکنده در حاشیه جنگل وجود ندارد که به نوبه خود ممکن است بر شکل ماسک‌های تصاویر واقعیت زمینی تأثیر بگذارد.

نکته دیگر مورد توجه این است که از ترکیب مدل‌های پایه عمیق<sup>۱</sup> مختلف می‌توان برای بهره‌مندی از ویژگی‌های آن‌ها برای قطعه‌بندی استفاده کرد. این عمل باعث ایجاد ترکیبی از CNN‌های پایه با توابع هزینه مختلف می‌شود که کیفیت قطعه‌بندی را بهبود می‌بخشد و از استفاده تکی همه مدل‌ها یا طبقه‌بندی‌کننده‌ها بهتر عمل می‌کند. اخیراً، چنین رویکرد قطعه‌بندی موفق‌تری در کاربردهای مختلف اعمال شده است، مانند قطعه‌بندی ضایعات پوستی در تصاویر درموسکوپي [۵۲]، قطعه‌بندی تصاویر زیستی [۵۳] و قطعه‌بندی رگ‌ها در آنژیوگرافی تهاجمی عروق کرونر [۵۴]؛ بنابراین، تحقیقات بیشتری لازم است تا اثربخشی ترکیب مدل‌های پایه CNN مختلف با معماری‌های قطعه‌بندی مختلف، از جمله، Attention و Inception [۵۵]، بررسی شود.

<sup>۱</sup> Ensemble learning



## منابع

- [۱] C. Le Quéré *et al.*, 2009, "Trends in the sources and sinks of carbon dioxide," *Nature Geoscience*, vol. 2, no. 12, pp. 831-836, Art no., doi: 10.1038/ngeo689.
- [۲] G. R. van der Werf *et al.*, 2009, "CO2 emissions from forest loss," *Nature Geoscience*, vol. 2, no. 11, pp. 737-738, Art no., doi: 10.1038/ngeo671.
- [۳] J. Frick, N. Bauer, E. von Lindern, and M. Hunziker, 2018, "What forest is in the light of people's perceptions and values: Socio-cultural forest monitoring in Switzerland," *Geographica Helvetica*, vol. 73, pp. 335-345, Art no., doi: 10.5194/gh-73-335-2018.
- [۴] A. N. Darvishsefat, M. "The study of spatial distribution of forest changes tin the northern forests of Iran." <https://www.geospatialworld.net/article/the-study-of-spatial-distribution-of-forest-changes-tin-the-northern-forests-of-iran/> (accessed).
- [۵] B. H. Samset, J. S. Fuglestedt, and M. T. Lund, 2020, "Delayed emergence of a global temperature response after emission mitigation," *Nature Communications*, vol. 11, no. 1, p. 3261, Art no., doi: 10.1038/s41467-020-17001-1.
- [۶] T. S. Khosro Sagheb Talebi, Mehdi Pourhashemi, 2014, *Forests of Iran*, 1 ed. (Plant and Vegetation). Springer Dordrecht.
- [۷] K. S. T. F. Amirghasemi, D. Dargahi, 2001, "Study of Natural Regeneration Structure of Arasbaran Forests in the Seten Chay Study," *Iranian Journal of Forest and Poplar Research*, vol. 6, no. 1, pp. 1-62, Art no., doi: 10.22092/ijfpr.2001.109706.
- [۸] L. Bragagnolo, R. V. da Silva, and J. M. V. Grzybowski, 2021, "Towards the automatic monitoring of deforestation in Brazilian rainforest," *Ecological Informatics*, vol. 66, p. 101454, Art no., doi: <https://doi.org/10.1016/j.ecoinf.2021.101454>.
- [۹] Y. Gao, M. Skutsch, J. Paneque-Gálvez, and A. Ghilardi, 2020, "Remote sensing of forest degradation: a review," *Environmental Research Letters*, vol. 15, no. 10, p. 103001, Art no., doi: 10.1088/1748-9326/abaad7.
- [۱۰] M. M. Awad and M. Lauteri, "Self-Organizing Deep Learning (SO-UNet)—A Novel Framework to Classify Urban and Peri-Urban Forests," *Sustainability*, vol. 13, no. 10, doi: 10.3390/su13105548.
- [۱۱] N. Younes Cárdenas, K. E. Joyce, and S. W. Maier, 2017, "Monitoring mangrove forests: Are we taking full advantage of technology?," *International Journal of Applied Earth Observation and Geoinformation*, vol. 12, pp. 1-14, Art no., doi: <https://doi.org/10.1016/j.jag.2017.07.004>.
- [۱۲] Planet. "Available online from." <https://www.planet.com/> (accessed Sep 2023).
- [۱۳] F. Monitoring. "Available online from." <https://www.globalforestwatch.org/> (accessed Sep 2023).
- [۱۴] L. Zhang, L. Zhang, and B. Du, 2016, "Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art," *IEEE Geoscience and Remote Sensing Magazine*, vol. 4, no. 2, pp. 22-40, Art no., doi: 10.1109/MGRS.2016.2540798.
- [۱۵] A. Alzu'bi, A. Amira, and N. Ramzan, 2019, "Learning transfer using deep convolutional features for remote sensing image retrieval," *Int. J. Comput. Sci*, vol. 46, no. 4, pp. 637-644, Art no.
- [۱۶] G. J. Scott, M. R. England, W. A. Starms, R. A. Marcum, and C. H. Davis, 2017, "Training Deep Convolutional Neural Networks for Land-Cover Classification of High-Resolution Imagery," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 4, pp. 549-553, Art no., doi: 10.1109/LGRS.2017.2657778.
- [۱۷] F. Chen, R. Ren, T. Van de Voorde, W. Xu, G. Zhou, and Y. Zhou, 2018, "Fast Automatic Airport Detection in Remote Sensing Images Using Convolutional Neural Networks," *Remote Sensing*, vol. 10, no. 3, p. 443, Art no. [Online]. Available: <https://www.mdpi.com/2072-4292/10/3/443>.
- [۱۸] R. Kemker, C. Salvaggio, and C. Kanan, 2018, "Algorithms for semantic segmentation of multispectral remote sensing imagery using deep learning," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 145, pp. 60-77, Art no., doi: <https://doi.org/10.1016/j.isprsjprs.2018.04.014>.
- [۱۹] J. Morel, A. Bac, and T. Kanai, 2020, "Segmentation of unbalanced and in-homogeneous point clouds and its application to 3D scanned trees," *The Visual Computer*, vol. 36, no. 10, pp. 2419-2431, Art no., doi: 10.1007/s00371-020-02037-1
- [۲۰] Z. Cheng, A. Qu, and X. He, 2022, "Contour-aware semantic segmentation network with spatial attention mechanism for medical image," *The Visual Computer*, pp. 1-14, Art no.
- [۲۱] A. Ouahabi and A. Taleb-Ahmed, 2021, "RETRACTED: Deep learning for real-time semantic segmentation: Application in ultrasound imaging," *Pattern Recognition Letters*, vol. 144, pp. 27-34, Art no., doi: <https://doi.org/10.1016/j.patrec.2021.01.010>.

- [۲۲] V. Khryashchev, L. Ivanovsky, V. Pavlov, A. Ostrovskaya, and A. Rubtsov, "Comparison of Different Convolutional Neural Network Architectures for Satellite Image Segmentation," in *2018 23rd Conference of Open Innovations Association (FRUCT)*, 13-16 Nov. 2018 2018, pp. 172-179, doi: 10.23919/FRUCT.2018.8588071 .
- [۲۳] N. Flood, F. Watson, and L. Collett, 2019, "Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia," *International Journal of Applied Earth Observation and Geoinformation*, vol. 82, p. 101897, Art no., doi: 10.1016/j.jag.2019.101897.
- [۲۴] L. Bragagnolo, R. V. da Silva, and J. M. V. Grzybowski, 2021, "Amazon forest cover change mapping based on semantic segmentation by U-Nets," *Ecological Informatics*, vol. 62, p. 101279, Art no., doi: <https://doi.org/10.1016/j.ecoinf.2021.101279>.
- [۲۵] A. M. T. Z. Moradi, 2020, "Comparison of Artificial Neural Network, Logistic Regression, and Similarity-Based Weighted Sample Learning Approaches in Modeling and Predicting Deforestation: A Case Study of Gorganrud Watershed, Golestan Province," *Environmental Science and Technology*, vol. 21, no. 11, pp. 217-227, Art no., doi: 10.22034/jest.2020.10480.
- [۲۶] M. A. H. Mahmoudzadeh, 2019, "Modeling Deforestation Using Neural Network and Geographic Information System (Forests Around Khorramabad)," *Remote Sensing and GIS in Natural Resources*, vol. 10, no. 4, pp. 74-90, Art no. [Online]. Available: [https://girs.bushehr.iau.ir/article\\_670420\\_ae27ee70137f5a11f6ea3ae151b9c8af.pdf](https://girs.bushehr.iau.ir/article_670420_ae27ee70137f5a11f6ea3ae151b9c8af.pdf).
- [۲۷] A. Henareh Khalyani and A. L. Mayer, 2013, "Spatial and temporal deforestation dynamics of Zagros forests (Iran) from 1972 to 2009," *Landscape and Urban Planning*, vol. 117, pp. 1-12, Art no., doi: <https://doi.org/10.1016/j.landurbplan.2013.04.014>.
- [۲۸] N. Karimi, S. Golian, and D. Karimi, 2016, "Monitoring deforestation in Iran, Jangal-Abr Forest using multi-temporal satellite images and spectral mixture analysis method," *Arabian Journal of Geosciences*, vol. 9, no. 3, p. 214, Art no., doi: 10.1007/s12517-015-2250-4.
- [۲۹] S. Arekhi, 2011, "Modeling spatial pattern of deforestation using GIS and logistic regression: A case study of northern Ilam forests, Ilam province, Iran," *African Journal of Biotechnology*, vol. 10, pp. 16236-16249, Art no.
- [۳۰] P. P. de Bem, O. A. de Carvalho Junior, R. Fontes Guimarães, and R. A. Trancoso Gomes, 2020, "Change Detection of Deforestation in the Brazilian Amazon Using Landsat Data and Convolutional Neural Networks," *Remote Sensing*, vol. 12, no. 6, p. 901, Art no. [Online]. Available: <https://www.mdpi.com/2072-4292/12/6/901>.
- [۳۱] R. B. Andrade *et al.*, 2020, "Evaluation of Semantic Segmentation Methods for Deforestation Detection in the Amazon," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLIII-B3-2020, pp. 1497-1505, Art no., doi: 10.5194/isprs-archives-XLIII-B3-2020-1497-2020.
- [۳۲] A. Mazza, F. Sica, P. Rizzoli, and G. Scarpa, 2019, "TanDEM-X Forest Mapping Using Convolutional Neural Networks," *Remote Sensing*, vol. 11, no. 24, p. 4980, Art no. [Online]. Available: <https://www.mdpi.com/2072-4292/11/24/2980>.
- [۳۳] S.-H. Lee, K.-J. Han, K. Lee, K.-J. Lee, K.-Y. Oh, and M.-J. Lee, 2020, "Classification of Landscape Affected by Deforestation Using High-Resolution Remote Sensing Data and Deep-Learning Techniques," *Remote Sensing*, vol. 12, no. 20, p. 3372, Art no. [Online]. Available: <https://www.mdpi.com/2072-4292/12/20/3372>.
- [۳۴] F. H. Wagner *et al.*, 2020, "Regional Mapping and Spatial Distribution Analysis of Canopy Palms in an Amazon Forest Using Deep Learning and VHR Images," *Remote Sensing*, vol. 12, no. 14, p. 2225, Art no. [Online]. Available: <https://www.mdpi.com/2072-4292/12/14/2225>.
- [۳۵] F. H. Wagner *et al.*, 2020, "Mapping Atlantic rainforest degradation and regeneration history with indicator species using convolutional network," *PLoS One*, vol. 15, no. 2, p. e0229448, Art no., doi: 10.1371/journal.pone.0229448.
- [۳۶] A. Alzu'bi and L. Alsmadi, 2022, "Monitoring deforestation in Jordan using deep semantic segmentation with satellite imagery," *Ecological Informatics*, vol. 70, p. 101745, Art no., doi: 10.1016/j.ecoinf.2022.101745.
- [۳۷] A. Jamali, S. K. Roy, J. Li, and P. Ghamisi, 2023, "TransU-Net++: Rethinking attention gated TransU-Net for deforestation mapping," *International Journal of Applied Earth Observation and Geoinformation*, vol. 120, p. 103332, Art no., doi: 10.1016/j.jag.2023.103332.
- [۳۸] L. Shumilo, M. Lavreniuk, N. Kussul, and B. Shevchuk, "Automatic Deforestation Detection based on the Deep Learning in Ukraine," in *2021 IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, 22-25 Sept. 2021 2021, vol. 1, pp. 337-342, doi: 10.1109/IDAACS53288.2021.9661008 .
- [۳۹] L. Breiman, 2001, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5-32, Art no., doi: 10.1023/A:1010933404324.
- [۴۰] T. Hastie, R. Tibshirani, and J. Friedman, 2009, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition (Springer Series in Statistics)*.
- [۴۱] A. Liaw and M. Wiener, 2001, "Classification and Regression by RandomForest," *Forest*, vol. 23.

- [۴۲] M. M. Taye, 2023, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," *Computation*, vol. 11, no. 3, p. 52, Art no. [Online]. Available: <https://www.mdpi.com/2079-3197/11/3/52>.
- [۴۳] W. S. McCulloch and W. Pitts, 1943, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, pp. 115-133, Art no.
- [۴۴] R. C. Hernández-Gómez and E. Cantillo-Higuera, 2018, "La restauración ecológica como estrategia de construcción social en la Vereda Chipautá, Municipio de Guaduas, Cundinamarca," *Ambiente y Desarrollo*, vol. 22, no. 42, pp. 1-15, Art no.
- [۴۵] T. Pinheiro, M. Escada, D. Valeriano, P. Hostert, F. Gollnow, and H. Müller, 2016, "Forest degradation associated with logging frontier expansion in the Amazon: the BR-163 region in Southwestern Pará, Brazil," *Earth Interactions*, vol. 20, no. 17, pp. 1-26, Art no.
- [۴۶] I. Md Jelas, M. A. Zulkifley, M. Abdullah, and M. Spraggon, 2024, "Deforestation detection using deep learning-based semantic segmentation techniques: a systematic review," *Frontiers in Forests and Global Change*, vol. 7, p. 1300060, Art no.
- [۴۷] C. Shorten and T. M. Khoshgoftaar, 2019, "A survey on image data augmentation for deep learning," *Journal of big data*, vol. 6, no. 1, pp. 1-48, Art no.
- [۴۸] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Cham, N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, Eds., 2015// 2015: Springer International Publishing, pp. 234-241 .
- [۴۹] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 3431-3440 .
- [۵۰] P. P. Fork. "Available online from." <https://pillow.readthedocs.io/en/stable/reference/ImageChops.html> (accessed.
- [۵۱] R. a. W. M. O. o. I. Forest. <https://frw.ir/index.jsp?siteid=1&pageid=1493&newsview=169950&pro=nobak> (accessed May 2024.
- [۵۲] M. Goyal, A. Oakley, P. Bansal, D. Dancey, and M. H. Yap, 2019" ,Skin lesion segmentation in dermoscopic images with ensemble deep learning methods," *Ieee Access*, vol. 8, pp. 4171-4181, Art no.
- [۵۳] L. Nanni, D. Cuza, A. Lumini, A. Loreggia, and S. Brahmam, 2021, "Deep ensembles in bioimage segmentation," *arXiv preprint arXiv:2112.12955*.
- [۵۴] J. Park *et al.*, 2023, "Selective ensemble methods for deep learning segmentation of major vessels in invasive coronary angiography," (in eng), *Med Phys*, vol. 50, no. 12, pp. 7822-7839, Art no., doi: 10.1002/mp.16554.
- [۵۵] A. ebrahimi, A. Garousi, A. hosseini naveh, and A. \_mohammadzadeh, 2023, "Improving the YOLOv5 Deep Neural Network for Detecting Vehicles and Outdoor Pools from Drone Data," (in eng), *Journal of Geomatics Science and Technology*, Research vol. 13, no. 1, pp. 83 ,<sup>9v</sup>-Art no., doi: 10.61186/jgst.13.1.83.