

آکادمی سنجش از دور ایران

www.girs.ir



پرس

P
A
P
E
R
S

مجله علمی

شماره اول، خرداد ۱۴۰۱



شناسایی و نقشه‌برداری قابل تفسیر درختان با استفاده از تصاویر پهپادی
نقشه‌برداری گونه‌های (گیاهی) مهاجم توسط سیستم پهپاد

فهرست

پیش گفتار

3

مقاله اول؛

شناسایی و نقشه‌برداری قابل تفسیر درختان
با استفاده از تصویر RGB پهپادی
و یادگیری عمیق

مقاله دوم؛

نقشه‌برداری گونه‌های (گیاهی) مهاجم
کنار رودخانه‌ای با طبقه‌بندی نظارت شده
از تصاویر گرفته شده توسط سیستم پهپاد

مجله علمی

پیرز

شماره اول، خرداد ۱۴۰۱

هیئت تحریریه: تاراوش ناطقی - احمد نجفی
طراح و صفحه آرا: المیرا دواتگر خرسند

وبسایت: www.girs.ir

پست الکترونیکی: girs.academy@gmail.com

صفحه اینستاگرام: [girs_ir](https://www.instagram.com/girs_ir)

تلگرام: [rsandis](https://www.telegram.me/rsandis)

نشانی: تهران - خیابان فردوسی، خیابان نوفل لوشاتو، کوچه مسعود سعد، پردیس علم و فناوری تهران، اتاق ۳۱۵

پیش‌گفتار

احتمالا تا به حال بارها برای انجام پروژه یا انتخاب موضوع پایان نامه به مشکل برخوردیده‌اید و منابع درست و کافی در زمینه سنجش از دور به زبان فارسی در اختیار نداشته‌اید، شاید از جمله افراد علاقمند به مطالعه و بالابردن سطح اطلاعات تخصصی خود هستید اما به دلیل عدم تسلط کافی به زبان انگلیسی مطالعه شما بیش از حد زمان بر و خسته کننده می‌شود و حتی از ادامه آن منصرف می‌شوید. همه ما باور داریم که منابع علمی رشته سنجش از دور به زبان فارسی بسیار محدود و تکراری هستند و روند پیشرفت آنها با آنچه در جامعه علمی اتفاق می‌افتد همزمانی و تناسب خوبی ندارد. به عنوان کارشناس رشته سنجش از دور، با همراهی آکادمی سنجش از دور ایران، تصمیم گرفتیم در حد توان برای جبران این مساله قدمی برداریم. مجله علمی "Papers" که نخستین شماره آن در اسفندماه ۱۴۰۰ منتشر شد، به واکاوی دانش سنجش از دور در علوم مختلف زمین می‌پردازد. هر شماره از این مجله مختص یکی از موضوعات مربوطه و بررسی جدیدترین مقالات منتشر شده در معتبرترین مجلات علمی جهان با ایمپکت فکتور بالا می‌باشد. ترجمه این مقالات حاصل تلاش مترجمان مجرب بوده و ویرایش متون توسط هیئت تحریریه انجام می‌شود. برای برخی از موضوعات به دلیل گستردگی و اهمیت بالا نیاز به چاپ مقالات بیشتر و به تبع آن انتشار بیش از یک جلد مجله داریم، در این صورت در چند شماره پیاپی به آن موضوع پرداخته خواهد شد.

در پیش شماره Papers دو مقاله درباره کاربرد تکنولوژی پهپاد در علوم جنگل ارائه گردید. در صورتی که هنوز این فایل را دانلود و مطالعه نکردید می‌توانید از لینک <https://girs.ir/papers-prerelease> آن را بصورت رایگان دریافت نمایید. در ادامه‌ی این موضوع در این شماره نیز دو مقاله از معتبرترین مجلات علمی جهان را انتخاب نموده ایم.

آکادمی سنجش از دور ایران امیدوار است با تداوم انتشار مجله علمی "Papers"، تا حدی بتواند در راستای سرعت بخشیدن به چرخه دانش سنجش از دور در کشور تاثیرگذار باشد. از همراهی شما سپاسگزاریم.

شناسایی و نقشه‌برداری

1 مقاله اول

قابل تفسیر درختان با استفاده از تصویر RGB پهپادی و یادگیری عمیق

در انتها، برای هر تصویر تاج درختی، طبقه بندی CNN مبتنی بر شیء^۵ را اعمال کردیم. این سیستم در طبقه‌بندی هفت کلاس از درختان از جمله چندین گونه درختی با دقت بیش از ۹۰ درصد با موفقیت همراه بود. نقشه‌برداری فعال‌سازی کلاس وزن-دار گرادینان هدایت‌شونده^۶ (Grad-CAM هدایت‌شونده) نشان داد که CNN، درخت‌ها را بر اساس شکل و کنتراست برگ‌ها طبقه‌بندی می‌کند، بطوری که کارایی سیستم در طبقه‌بندی درختان مختلف با رنگ‌های مشابه را به روشی مقرون‌به‌صرفه افزایش می‌دهد- ویژگی مفیدی که می‌تواند جهت مدیریت جنگل بکار گرفته شود.

بررسی دقیق پراکنش گونه‌های درختی در مناطق جنگلی امری مهم برای مدیریت جنگل و مسائل تحقیقاتی مربوط به آن است. به طور خاص، مدیریت و حفاظت از پوشش گیاهی بومی، پایش گونه‌های مهاجم، تهیه نقشه از زیستگاه حیات

شناسایی و نقشه‌برداری درختان از طریق داده‌های سنجش از دور برای مدیریت جنگل، از جمله موضوعات فعال پژوهشی است. روش‌های پیشنهادی قبلی با استفاده از حسگرهای هواپرد و فراطیفی می‌توانند گونه‌های درختی را با دقت بالا شناسایی کنند، اما این‌ها روش‌های هزینه‌بری هستند و از اینرو برای افرادی که بر روی جنگل‌های کوچک‌مقیاس کار می‌کنند گزینه مناسبی نیست. در این مطالعه، ما یک سیستم دید ماشینی^۱ برای شناسایی درختان و تهیه نقشه با استفاده از تصویر قرمز-سبز-آبی^۲ (RGB) که توسط یک پهپاد^۳ (UAV) گرفته شده و توسط شبکه عصبی پیچشی^۴ (CNN) پردازش شده ایجاد کردیم. در این سیستم، ابتدا شیب را از مدل سه بعدی به دست آمده توسط پهپاد محاسبه کردیم. ما سپس، با استفاده از تصویر RGB پهپادی، جنگل را به طور خودکار با اطلاعات رنگی و سه بعدی و مدل شیب تهیه شده به چندین شیء تاج درختی قطعه‌بندی کردیم.

1- machine vision

2- Red-Green-Blue

3- unmanned aerial vehicle

4- convolutional neural network

5- object-based

6- guided gradient-weighted class activation mapping



وحش، و مدیریت پایدار جنگل از جمله اهداف مطالعاتی هستند که نیاز به بررسی پراکنش گونه‌های درختی در مقیاس وسیع دارند. در این راستا، مطالعات بسیاری با استفاده از داده‌های سنجش از دور انجام شده است. تا به امروز، در تحقیقات سنجش از دور با این اهداف عمدتاً از ماهواره‌ها یا هواپیماها استفاده شده است. در گذشته، عمده کار متوجه ماهواره‌های چندطیفی لندست بود که به دلیل هزینه کم، تهیه نقشه از انواع جنگل‌ها را تسهیل می‌کرد. مزیت ماهواره لندست این است که می‌تواند مناطق وسیعی، یعنی تا مقیاس کشوری پوشش دهد. با این وجود، وضوح آن ۳۰ متر است که امکان شناسایی آسان گونه‌های درختی را نمی‌دهد. از سال ۲۰۰۰، از ماهواره‌های تجاری در بسیاری از مطالعات از داده‌های با وضوح بسیار بالا برای طبقه‌بندی گونه‌های درختی استفاده شده است، به عنوان مثال از World-view2 و QuickBird، با وضوح ۵/۰ m و ۲/۰ m و ۴/۰ m متر برای به ترتیب داده‌های پانکروماتیک/چند طیفی. علاوه بر این، در سال‌های اخیر، مطالعاتی که در آن از هواپیما استفاده شده در شناسایی چندین گونه درختی موفقیت‌آمیز بوده است. وضوح فضایی تصاویر استفاده شده در آن نیز بسیار بالا و در حدود ۰٫۲-۳٫۰ متر است. در بیشتر این مطالعات از سخت افزارهای تخصصی مانند حسگرهای چند طیفی، ابرطیفی و LiDAR استفاده شده و کارایی بالای خود را در شناسایی گونه‌های درختی به اثبات رسانده‌اند. برای مثال، شن^۱ و کائو^۲ موفق شدند پنج گونه درختی را با

دقت بیش از ۸۵ درصد شناسایی کنند. دالپونته^۳ و همکاران هفت گونه درختی و البته هیچ کلاس جنگلی را با دقت تقریبی ۸۰ درصدی شناسایی کردند. این دو مطالعه نشان دادند که ترکیب حسگر فراطیفی و داده‌های LiDAR به‌دست‌آمده توسط هواپیما نسبت به استفاده از حسگرهای چند طیفی یا فراطیفی برتری دارد. با این حال، اگرچه این ترکیب از روش‌های داده‌برداری عملکرد بهتری دارد اما تجهیزات مورد استفاده در آن بسیار گران است. اینگونه روش‌هایی که از داده‌های چندطیفی / فراطیفی استفاده می‌کنند اغلب با مشکلاتی همراه هستند. یکی از این مشکلات، ویژگی‌های طیفی آنها است که نه تنها بین گونه‌ها، بلکه در تراکم برگ‌ها، وضعیت سلامتی و نویزهای پس‌زمینه مانند گیاهان زیردرختی یا خاک بایر نیز می‌تواند متفاوت باشد. هنگامی که سایه وجود دارد، طیف ناحیه سایه‌دار با ناحیه بدون سایه متفاوت است و در نتیجه دقت کمتری دارد. در شناسایی یک جنگل مختلط نیز کارایی آن ممکن است کمتر باشد زیرا چندین گونه در یک پیکسل جای می‌گیرند. این چالش‌ها را می‌توان به وابستگی این روش‌ها به استفاده از اطلاعات طیفی نسبت داد.

در دهه‌های اخیر، پهپادها به طور تجربی در امور جنگل‌داری مورد استفاده قرار گرفته‌اند. در مقایسه با هواپیماهای سرنشین‌دار، پهپادها ابزاری با کاربری آسان و کم هزینه در مطالعات سنجش از دور جنگل‌ها محسوب می‌شوند.

در مورد شناسایی درختان، مهمترین تفاوت بین هواپیماهای سرنشین‌دار و پهپادها این است که پهپادها می‌توانند در نزدیکی تاج‌پوش‌ها پرواز کنند و تصاویری با وضوح بسیار بالا بدست آورند. تصاویر برگرفته از پهپادها دارای وضوح فضایی تا حد چند سانتی‌متر هستند. در برخی موارد، حتی ویژگی‌های درخت در سطح برگ نیز قابل مشاهده است. اگر بتوانیم از این ویژگی‌ها در سیستم‌های شناسایی درختان بهره بگیریم، این امکان وجود دارد که از گونه‌های مختلف درخت با استفاده از تصاویر دیجیتالی ساده قرمز-سبز-آبی (RGB) نقشه تهیه کنیم. چنین روشی پای جنگل‌ها را بطور مقرون به صرفه و نیز با پتانسیل کاربری بالا تسهیل می‌کند.

در همین حال، یادگیری عمیق تبدیل به ابزاری موثر در تشخیص اشیا شده است. در سال‌های اخیر، مطالعاتی که داده‌های یادگیری عمیق و سنجش از دور را با هم ترکیب کرده‌اند مانند LiDAR هوابرد یا تصویر هوایی، قابلیت بالایی را برای تشخیص درختان بطور مجزا، نقشه‌برداری پوشش جنگلی مرده و ارزیابی خسارات وارده بر جنگل را نشان داده‌اند. در میان روش‌های یادگیری عمیق، شبکه عصبی پیچشی (CNN) کارایی بالایی در طبقه‌بندی تصاویر دیجیتال در میدان دید رایانه نشان داده‌اند. تا به امروز، دیگر روش‌های یادگیری ماشینی مانند ماشین‌های بردار پشتیبانی (SVM)^۱ یا جنگل تصادفی^۲ در این زمینه استفاده شده‌اند.

به ویژه SVM ها، که ما را قادر می‌سازند پیش بینی ناپارامتری نظارت شده‌ای را نیز انجام دهیم، یکی از روش‌های متداول یادگیری ماشینی هستند و برای شناسایی گونه‌های درختی استفاده شده‌اند.

یکی از مزایای قابل توجه یادگیری عمیق در مقایسه با چنین روش‌های یادگیری ماشینی این است که یادگیری عمیق نیازی به استخراج دستی ویژگی ندارد. سایر روش‌های یادگیری ماشینی، نیازمند آن است که پژوهشگران ویژگی‌های مورد نظر را بطور دستی استخراج کنند که در این زمینه، ویژگی‌های بافتی و شاخص‌های پوشش گیاهی و نیز مقادیر باندهای اصلی در فرآیند استخراج ویژگی برگرفته می‌شوند.

در ارتباط با ویژگی‌های بافتی، علاوه بر مقادیر میانگین و تغییرات هر باند، ماتریس هم‌رخداد سطح خاکستری^۳ (GLCM) به طور گسترده‌ای برای استخراج ویژگی‌های بافتی جهت بهبود عملکرد کار استفاده شده است. پس از استخراج ویژگی، در مطالعات گذشته که از داده‌های فراطیفی استفاده می‌شد گاهی اوقات انتخاب ویژگی را برای کاهش ابعاد انجام می‌دادند تا از مشکل ابعاد^۴ و عملیات محاسباتی بالا جلوگیری شود. اما به جای آن، یادگیری عمیق می‌تواند از اطلاعات کامل ویژگی‌ها استفاده کند، به‌ویژه اطلاعات مربوط به رابطه فضایی پیکسل‌ها، که اطلاعاتی در مورد بافت و شکل درختان ارائه می‌دهد.

1- support vector machine
2- random forest
3- grey-level co-occurrence matrix
4- curse of dimensionality

1- Shen
2- Cao
3- Dalponte



بنابراین، حتی زمانی که از تصاویر دیجیتالی ساده استفاده می‌شود، انتظار می‌رود یادگیری عمیق در شناسایی درختان با جزئیات و دقت بالا موفق‌آمیز باشد.

برای تفسیر طبقه‌بندی یادگیری عمیق، الگوریتم‌هایی که برخی از ویژگی‌های مدل‌های CNN را به تصویر می‌کشند ایجاد شده‌اند. نقشه‌برداری فعال‌سازی کلاس وزن‌دار گرادیان هدایت‌شونده (Grad-CAM) یکی از این الگوریتم‌ها است، و می‌تواند مناطق خاصی از تصویر را برجسته کند که اطلاعات معناداری را برای پیش‌بینی مدل ارائه می‌کند. استفاده از این الگوریتم به ما کمک می‌کند تا ویژگی‌هایی را که یادگیری عمیق از آنها بهره می‌گیرد شناسایی کنیم، به این معنی که اکنون می‌توانیم بدانیم که آیا یادگیری عمیق واقعاً از ویژگی‌های دقیقی همچون بافت‌های برگ‌ها و شکل درختان استفاده می‌کند و نیز می‌تواند اطلاعات چشمی قابل فهمی در مورد عملکرد مدل ارائه دهد.

در این مطالعه، ما یادگیری عمیق را برای تصاویر RGB گرفته شده توسط یک پهپاد اجرا کردیم. انتظار می‌رود این ترکیب پتانسیل بالایی برای شناسایی انواع و گونه‌های درختی داشته باشد، حتی اگر تصویر RGB با یک دوربین دیجیتال دستی گرفته شده باشد. در برخی از مطالعات اخیر پتانسیل این روش را در شناسایی و طبقه‌بندی درختان برای یک یا چند گونه خاص درختی

نشان داده است. روش تشخیص شی، این امکان را فراهم می‌آورد که وجود شیء گونه درختی را شناسایی کنیم. بنابراین، ممکن است برای یافتن گونه‌های درختی خاص مانند گونه‌های درختی مهاجم مناسب باشد. از سوی دیگر، تهیه نقشه جنگل، که سبب می‌شود نسبت تاج به مساحت هر کلاس درخت و نیز وجود درختان را به دست آوریم، به ما کمک می‌کند تا تغییرات پویایی جنگل را تحت پایش قرار داده و زیست‌توده را پیش‌بینی کنیم. یک سیستم نقشه‌برداری جنگل با استفاده از پهپادها و تصاویر دیجیتالی ابزاری مقرون به صرفه و مفید در مسائل مربوط به مدیریت جنگل خواهد بود.

در این مطالعه سه مورد حائز اهمیت است: (۱) ما یک سیستم تهیه نقشه از جنگل را با استفاده از پهپادها و طبقه‌بندی CNN پیشنهاد می‌کنیم. (۲) ما پتانسیل طبقه‌بندی آن را برای چندین کلاس درختی از جمله انواع درختان (برگریز و مخروطیان) و گونه‌ها در دو فصل آشکار می‌کنیم. برای ارزیابی عملکرد CNN، آن را با روش یادگیری ماشین دیگری مقایسه کردیم. در این مطالعه، ما از SVM به عنوان یک پلتفرم یادگیری ماشینی و مقادیر پیکسل هر باند و مقادیر بافت GLCM به عنوان ویژگی‌هایی برای یادگیری ماشین استفاده کردیم. (۳) ما نشان می‌دهیم که یک CNN از چه نوع ویژگی‌هایی از درخت استفاده می‌کند و با مقایسه آن با سایر روش‌های یادگیری ماشینی، اهمیت (سهام) آن را برای طبقه‌بندی نشان می‌دهیم.

مواد و روش‌ها

- مکان مورد مطالعه

مکان مورد مطالعه، ایستگاه آزمایشی کامیگامو^۱ دانشگاه کیوتو، واقع در حومه کیوتو ژاپن است (شکل پیوست S۱). این منطقه در یک ناحیه آب و هوایی گرم و مرطوب با ارتفاع ۱۰۹ تا ۲۲۵ متر بالاتر از سطح دریا واقع شده است. میانگین بارندگی و دمای سالانه به ترتیب ۱۵۸۲ میلی‌متر و ۱۴٫۶ درجه سانتی‌گراد است. مساحت کل ۴۶٫۸ هکتار است. ۶۵ درصد از مساحت آن از جنگل‌های طبیعی تشکیل شده که عمدتاً از سرو پاکوتاه (*Chamaecyparis obtuse*) و برخی درختان پهن برگ مانند بلوط (*Quercus serrata* یا *Quercus glauca*) تشکیل شده است. ۲۸ درصد از این منطقه از جنگل‌های مصنوعی عمدتاً از گونه‌های مخروطی خارجی تشکیل شده است. ۷ درصد باقیمانده نیز شامل باغ‌ها، گلخانه‌ها یا ساختمان‌هایی می‌شود. در این مطالعه، ما بر روی بخش شمالی (مساحتی در حدود ۱۱ هکتار) ایستگاه آزمایشی کامیگامو، شامل جنگلی طبیعی از سرو پاکوتاه، و جنگل مدیریت شده متاسکویا (*Metasequoia glyptostroboides*)، کاج سفید (*Pinus strobus*) کاج باتلاقی (*Pinus elliptii*) و کاج تدا (*Pinus taeda*) تمرکز کردیم.

- داده‌های سنجش از دور

برنامه‌های پرواز در حوالی ظهر در دو فصل انجام شد: در ۲ اکتبر ۲۰۱۶، که پایان فصل برگ است و ۲۰ نوامبر ۲۰۱۶، اوج فصل زرد برگ پاییزی. ما از پهپاد DJI Phantom ۴ (DJI، شنژن، چین) استفاده کردیم. این پهپاد دارای یک دوربین



داخلی با سنسور CMOS ۱ / ۲٫۳ بود که می‌تواند اطلاعات طیفی RGB را برداشت کند. این پهپاد به طور خودکار با استفاده از برنامه DroneDeploy نسخه ۲٫۶۶ (<https://www.drone.com>)، Infatics Inc، سانفرانسیسکو، ایالات متحده) عمل می‌کند. در ۲ اکتبر، ما پارامترهای پرواز را به صورت زیر تنظیم کردیم: همپوشانی و پوشش عرضی روی ۷۵٪ و ارتفاع پرواز روی ۸۰ متر از سطح برخاست زمین تنظیم شد. با این حال، ما نتوانستیم برخی از قسمت‌های تصاویر را در یک راستا قرار دهیم. بنابراین، پارامترهای همپوشانی و ارتفاع را در ۲۰ نوامبر به ۸۰٪ و ۱۰۰ متر تغییر دادیم. از ۱۰ نقطه کنترل زمینی^۲ (GCP) برای کاهش خطای GPS با تصاویر استفاده کردیم. از تصاویر گرفته شده توسط پهپاد، ما با استفاده از نرم افزار Agisoft PhotoScan Professional نسخه ۱٫۳٫۴ (Agisoft LLC، <https://www.agisoft.com>)، سنت پترزبورگ، روسیه) یک تصویر ارتوموزائیک و یک مدل رقومی سطح^۳ (DSM) تولید کردیم. تصویر ارتوموزائیک تصویری است متشکل از چندین تصویر هوایی که از لحاظ نما و مقیاس تصحیح شده است. تنظیمات پارامتر مورد استفاده در تولید تصویر ارتوموزائیک در جدول پیوست S۱ نشان داده شده است. این پارامترها به تاریخ ۲۰ نوامبر تنظیم شده‌اند. پارامترهای مربوط به ۲ اکتبر تنها از این جهت متفاوت است که فاصله نمونه‌برداری زمینی^۴ (GSD) تقریباً یک سانتی‌متر بود. GSD تصویر ارتوموزائیک و DSM به ترتیب تقریباً ۵ و ۱۰ سانتی‌متر بودند.

1- Kamigamo
2- ground-control points
3- digital surface model
4- ground sampling distance

قطعه‌بندی و آماده‌سازی داده‌های نظارت شده.

گردش کار فنی مورد استفاده در روش قطعه‌بندی و استخراج تصویر درختان در شکل ۱ بطور خلاصه آورده شده است. ابتدا، هر تاج درخت را با استفاده از تصویر پهپاد (عکس ارتوموزائیک)، یک DSM و یک مدل شیب قطعه‌بندی کردیم. در گام دوم، ما به صورت چشمی نقشه واقعیت زمینی را ساختیم. در گام سوم، ما هر تصویر درخت را با یک برچسب واقعیت زمینی استخراج کردیم. جزئیات بیشتر در بخش‌هایی از «قطعه‌بندی تاج درخت مبتنی بر شیء» تا «استخراج تصویر درخت با برچسب واقعیت زمینی» مورد بحث قرار گرفته است.

قطعه‌بندی تاج درخت مبتنی بر شیء.

مرحله قطعه‌بندی، ما در سطح درخت قطعه‌بندی کردیم. ابتدا، ما یک مدل شیب با محاسبه شیب از DSM و با استفاده از نرم افزار ArcGIS Desktop نسخه ۱۰،۴ (<https://www.esri.com>)، موسسه تحقیقات سیستم‌های محیطی، ردلندز^۱، ایالات متحده) ساختیم. مدل شیب بیشترین میزان تغییر ارتفاع را بین هر سلول و همسایه‌های آن نشان می‌دهد، به طوری که مرزهای درختان تفکیک می‌شود. از تصویر ارتوموزائیک، DSM و مدل شیب، قطعه‌بندی تاج درخت با استفاده از الگوریتم «قطعه‌بندی چندتوانی» در نرم افزار eCognition Developer نسخه ۹،۰،۰ (<https://www.trimble.com>) انجام شد. مقادیر پارامتر با آزمون و خطا تنظیم شد. نقشه تاج درخت ساخته شده توسط

این فرآیند قطعه‌بندی در شکل ۲ با تصاویر بزرگنمایی شده برای تأیید چشمی نتیجه نشان داده شده و بهترین پارامترها در جدول پیوست S۲ ارائه شده است.


در اینجا، ما دقت قطعه‌بندی را ارزیابی کردیم. تاج‌های قطعه‌بندی شده با توجه به روابط فضایی آنها با تاج مرجع تأیید شده چشمی در پنج دسته زیر قرار گرفتند. این پنج دسته، که بر اساس مطالعه قبلی تنظیم شده‌اند و در شکل پیوست S۲ نشان داده شده‌اند، به شرح زیر هستند.

(الف) منطبق^۲: اگر همپوشانی چندضلعی قطعه‌بندی شده و تاج مرجع بیش از ۸۰٪ بود، چند ضلعی قطعه‌بندی شده در دسته "منطبق" قرار می‌گیرد.

(ب) تقریباً منطبق^۳: اگر همپوشانی چندضلعی قطعه‌بندی شده و تاج مرجع ۶۰-۸۰٪ بود، چندضلعی قطعه‌بندی شده به عنوان «تقریباً منطبق» طبقه‌بندی می‌شود.

(ج) تقسیم‌شده^۴: اگر همپوشانی چندضلعی قطعه‌بندی شده و تاج مرجع ۲۰ تا ۶۰ درصد بود، چندضلعی قطعه‌بندی شده به عنوان «تقسیم‌شده» طبقه‌بندی می‌شود.

- 1- Redlands
- 2- Matched
- 3- Nearly matched
- 4- Split



UAV RGB image	تصویر RGB توسط پهپاد
Digital Surface Model	مدل رقومی سطح
Slope Model	مدل شیب
slope calculation by ArcGIS software	محاسبه شیب توسط نرم افزار ArcGIS
Multiresolution Segmentation by eCognition software	قطعه بندی چند توانی توسط نرم افزار eCognition
Tree Crown Map	نقشه تاج درخت
Ground Truth Label	برچسب واقعیت زمینی
label attachment by photo interpretation by eCognition software	برچسبگذاری از طریق تفسیر عکس توسط نرم افزار eCognition
Tree Crown Map with Labels	نقشه تاج درخت با برچسب
each tree crown image extraction by ArcGIS software	استخراج تصویر تاج درخت توسط نرم افزار ArcGIS
Individual Tree Images with a label	تصاویر از درختان بطور جداگانه همراه با یک برچسب

شکل ۱- گردش کار در استخراج تصاویر نظارت‌شده




(د) ادغام شده: اگر چندین تاج مرجع توسط چندضلعی قطعه‌بندی شده پوشانده شده باشد، و حتی یک همپوشانی بیش از ۲۰ درصد باشد، چند ضلعی قطعه‌بندی شده به عنوان «ادغام شده» طبقه‌بندی می‌شود. اگر چندضلعی قطعه‌بندی شده فقط یک تاج‌های مرجع را داشته باشد، چندضلعی به عنوان یک کلاس ادغام شده طبقه‌بندی می‌شود. اگر چندضلعی

قطعه‌بندی شده دارای چندین کلاس تاج‌های مرجع باشد، چند ضلعی به عنوان "کلاس چندگانه ادغام شده" طبقه‌بندی می‌شود.

(ه) چندپاره: اگر یک یا چند تاج مرجع توسط چند ضلعی قطعه‌بندی شده پوشانده شود و همپوشانی‌های مربوطه آنها کمتر از ۲۰ درصد باشد، چند ضلعی قطعه‌بندی شده به عنوان یک "چند ضلعی چندپاره" محسوب می‌شود.

شکل ۲- کل منطقه و نقشه بزرگ‌شده تاج درخت مربوطه. خط آبی خط شبکه چند ضلعی‌های قطعه‌بندی شده را نشان می‌دهد. مستطیل سفید، موقعیت ناحیه بزرگ شده را نشان می‌دهد و چند ضلعی‌های آبی روشن برای ارزیابی دقت قطعه‌بندی درخت استفاده می‌شود. این نقشه از طریق قطعه‌بندی چندتوانی با استفاده از رنگ، DSM و مدل شیب تهیه شده است. این شکل با استفاده از نرم افزار ArcGIS Desktop نسخه ۱۰.۶ (<https://www.esri.com>)، موسسه تحقیقات سیستم‌های محیطی، ردلندز، ایالات متحده) ایجاد شده است.



1- Merged
2- Fragmented



برای تصمیم‌گیری در مورد این کلاس‌ها، ما تحقیقات میدانی انجام دادیم. ما سه قطعه مستطیلی به ابعاد ۳۰ × ۳۰ متر طراحی و با توجه به کلاس‌های مذکور از تصاویر پهپاد گرفته شده در ۲۰ نوامبر گونه‌های درختی را بررسی کردیم. کلاس کاج باتلاقی یا کاج تدا از دو گونه کاج تشکیل شده است، زیرا شناسایی این دو گونه از تصاویر پهپادی دشوار است. در مرحله تهیه نقشه واقعیت زمینی، برای بهبود کارایی عملیاتی با استفاده از قابلیت طبقه‌بندی نزدیک‌ترین همسایه^۱ در نرم‌افزار eCognition، برچسب کلاس را به صورت چشمی به هر تاج درخت متصل کردیم، که این در ادامه برای تهیه نقشه از جنگل نیز مورد استفاده قرار گرفت (شکل ۳). به طور دقیق‌تر، ما برخی از شیء‌های تصویر را به عنوان نمونه‌های آموزشی انتخاب کردیم و آن الگوریتم را به کل تاج‌های درخت اعمال کردیم. در مراحل بعدی، با افزودن شیء‌های طبقه‌بندی شده اشتباهی به کلاس‌های صحیح نمونه‌های آموزشی، دقت نقشه واقعیت زمینی را بهبود بخشیدیم.

ما دقت قطعه‌بندی درختان را در قالب چهار منطقه محاسبه کردیم: منطقه ۱ یک جنگل مخروطی برگ‌ریز و منطقه ۲ یک جنگل کاج سفید بود که کل منطقه را برای آن محاسبه کردیم. منطقه ۳ یک جنگل کاج باتلاقی و کاج تدا بود که ما برای آن بخشی از منطقه را محاسبه کردیم. منطقه ۴ یک جنگل به طور طبیعی احیاء شده بود که برای آن مساحتی در حدود یک هکتار از آن را محاسبه کردیم. در نتیجه، برخی از تصاویر قطعه‌بندی‌شده دارای چندین تاج درخت بود، اما این روش تقریباً موفق شد هر کلاس درختی را از هم جدا کند (جدول ۱).

چسباندن برچسب واقعیت زمینی به نقشه تاج درخت. پس از قطعه‌بندی، تصاویر را در هفت کلاس زیر طبقه‌بندی کردیم: درختان پهن‌برگ برگ‌ریز، درختان مخروطی برگ‌ریز، درختان پهن‌برگ همیشه سبز، سرو پاکوتاه، کاج باتلاقی یا کاج تدا، کاج سفید و غیر جنگلی. کلاس غیر جنگلی شامل گیاهان زیردرختی و زمین بایر و نیز سازه‌های مصنوعی می‌شود.

منطقه جنگلی	منطبق	نسبتاً منطبق	تقسیم	ادغام شده		چندپاره
				چند کلاس	یک کلاس	
منطقه ۱	۷	۷	۱۳	۲	۳۱	۱۷
منطقه ۲	۱	۰	۵	۲	۴۱	۱۷
منطقه ۳	۱۹	۶	۷	۲	۲۷	۷
منطقه ۴	۳۸	۱۱	۲۳	۲۴	۴۸	۱۶

جدول ۱. آمار دقت نقشه‌های تاج درخت. (منطقه ۱: درختان مخروطی برگ‌ریز؛ منطقه ۲: جنگل کاج سفید؛ منطقه ۳: جنگل کاج باتلاقی و کاج تدا؛ منطقه ۴: جنگل احیاء شده طبیعی).

1-nearest neighbour classification



استخراج تصویر درخت با برچسب واقعیت زمینی.

از تصاویر ارتوموزائیک دو فصل و نقشه واقعیت زمینی، هر تصویر درخت را با یک برچسب کلاس با استفاده از ابزار "Extract by Mask" در ArcGIS استخراج کردیم. برخی از تصاویر نامناسب بودند، مانند آن بخش‌هایی از درختان که تفسیر یا طبقه‌بندی چشمی آنها دشوار است و آنهایی که شامل چندین کلاس بودند. بنابراین، ما به صورت دستی تصاویر نامناسب را حذف کردیم و تصاویری که نادرست طبقه‌بندی شده بودند را طبق نظرخواهی گروهی در کلاس صحیحی قرار دادیم. تعدادی تصویر شاخص از کلاس‌های درختی در شکل‌های ۴ و ۵ نشان داده شده است. تعداد تصاویر استخراج شده و تصاویر مرتب شده در جدول پیوست S۳ نشان داده شده است. پس از چیدمان، تعداد هر کلاس از ۳۷ تا ۴۱۶ متغیر بود. تصاویر دارای اندازه‌های متفاوتی بودند، اما طول یک طرف بزرگترین تصویر تقریباً ۴۰۰ پیکسل بود.


پس از استخراج، ما اندازه تصاویر مربوط به تاریخ ۲ اکتبر را به اندازه تصاویر گرفته شده در ۲۰ نوامبر تغییر دادیم تا شرایط دو فصل را هماهنگ کنیم. بنابراین، همه تصاویر با اندازه تصاویر گرفته شده از ارتفاع تقریباً ۱۰۰ متری تنظیم شدند.

یادگیری ماشینی. جهت ساخت یک مدل برای شناسایی شی، از نرم‌افزار پای‌تورچ^۱ نسخه ۰.۴.۱

به عنوان یک بستر یادگیری عمیق و چهار مدل شبکه عصبی استاندارد - به ویژه AlexNet، VGG16، Resnet و Resnet152 برای میزبانی دقیق^۲ استفاده کردیم. میزبانی دقیق روشی موثر برای بهبود عملکرد یادگیری است، به ویژه زمانی که مقدار داده برای آموزش کافی نباشد. ما از هر مدل شبکه عصبی که با مجموعه داده ImageNet آموزش دیده بود استفاده کردیم و تمام لایه‌های شبکه عصبی را با استفاده از داده‌های خود آموزش دادیم. در مرحله آموزش CNN، تصاویر آموزشی را هشت بار با برگرداندن و چرخاندن آنها تقویت کردیم. تقویت بیشتر تأثیری در افزایش دقت نداشت. بعنوان داده ورودی برای CNN، "برش با اندازه تصادفی"^۳ را در مقیاس ۲۲۴ × ۲۲۴ پیکسل برای آموزش اعمال کردیم، که تصویر مورد نظر را به اندازه و نسبت ابعاد تصادفی برش می‌دهد.


برای اعتبارسنجی و آموزش، اندازه تصاویر را به اندازه‌های ۲۵۶ × ۲۵۶ پیکسل تغییر دادیم و از "برش مرکز" در مقیاس ۲۲۴ × ۲۲۴ پیکسل استفاده کردیم. این الگوریتم‌های برش تنها یک تصویر تغییر اندازه داده شده (patch) را از هر تصویر برش داده شده استخراج کردند. محدوده سایر تنظیمات یادگیری در جدول پیوست S۴ بیان شده است.

- 1- PyTorch
- 2- fine-tuning
- 3- random resized crop
- 4- centre crop



deciduous broad-leaved tree	درخت پهن برگ برگ‌ریز
deciduous coniferous tree	درخت مخروطی برگ‌ریز
evergreen broad-leaved tree	درخت همیشه سبز پهن برگ
Chamaecyparis obtuse	سرو پاکوتاه
Pinus elliottii or Pinus taeda	کاج باتلاقی یا کاج تدا
Pinus strobus	کاج سفید
non-forest	غیر جنگلی

شکل ۳- نتایج قطعه‌بندی و تهیه نقشه واقعیت زمینی. کلاس درختان موجود در تصویر سمت چپ با رنگ‌های توضیح داده شده در لژاند واقع در شکل سمت راست مشخص می‌شوند. این شکل با استفاده از نرم افزار ArcGIS Desktop نسخه ۱۰.۶ (<https://www.esri.com>)، موسسه تحقیقات سیستم‌های محیطی، ردلندز، ایالات متحده تهیه شده است



deciduous broad-leaved tree	درخت پهن برگ برگ‌ریز
deciduous coniferous tree	درخت مخروطی برگ‌ریز
evergreen broad-leaved tree	درخت همیشه سبز پهن‌برگ
Chamaecyparis obtuse	سرو پاکوتاه
Pinus elliotii or Pinus taeda	کاج باتلاقی یا کاج تدا
Pinus strobus	کاج سفید
non-forest	غیر جنگلی

شکل ۵- تصاویر شاخص استخراج شده از هر کلاس مربوط به ۲ اکتبر. این تصاویر از همان چندضلعی نقشه تاج درختی که تصاویر ۲۰ نوامبر استخراج شده گرفته شده است.



deciduous broad-leaved tree	درخت پهن برگ برگ‌ریز
deciduous coniferous tree	درخت مخروطی برگ‌ریز
evergreen broad-leaved tree	درخت همیشه سبز پهن‌برگ
Chamaecyparis obtuse	سرو پاکوتاه
Pinus elliotii or Pinus taeda	کاج باتلاقی یا کاج تدا
Pinus strobus	کاج سفید
non-forest	غیر جنگلی

شکل ۴- تصاویر شاخص استخراج شده از هر کلاس مربوط به ۲۰ نوامبر. این تصاویر در هر سطح تاج درخت به خوبی قطعه‌بندی شدند. با این حال، تصویر کاج سفید شامل چندین تصویر درختی است. تصویر کلاس غیرجنگلی سقف یک خانه را نشان می‌دهد.



برای ارزیابی عملکرد CNN، ما از SVM به عنوان یک پلتفرم یادگیری ماشینی استفاده کردیم. ما میانگین و انحراف استاندارد هر باند و مقادیر بافت GLCM را به عنوان ابزار محاسباتی بکار گرفتیم. GLCM یک ماتریس هم‌رویداد^۱ فضایی است که روابط مقادیر پیکسل را محاسبه و از این روابط برای محاسبه آمار بافت استفاده می‌کند.

برای محاسبه GLCM، تصاویر با تعداد زیادی بیت داده، سبب پیچیدگی محاسباتی زیادی می‌شود. در این مورد، آنهایی که به تصویر خاکستری^۲ تبدیل شدند ۸ بیتی هستند. مشخص شده که کم شدن اندازه بیت تنها باعث کاهش جزئی در دقت طبقه‌بندی می‌شود. از این رو، ما از ۸ بیت به ۵ بیت تغییر مقیاس دادیم. پس از محاسبه GLCM، ما پنج ویژگی بافت GLCM (گشتاور دوم زاویه‌ای^۳ (ASM)، کنتراست، ناهمگونی^۴، بی‌نظمی^۵ و همگنی^۶) را استخراج کردیم. الگوریتم‌های آنها در معادلات ۱ تا ۵ آورده شده است:

$$1: ASM = \sum_{i,j}^N (P_{ij})^2$$

$$2: Contrast = \sum_{i,j}^N P_{ij} (i - j)^2$$

$$3: Dissimilarity = \sum_{i,j}^N P_{ij} |i - j|$$

$$4: Entropy = \sum_{i,j}^N P_{ij} \log(P_{ij})$$

$$5: Homogeneity = \sum_{i,j}^N P_{ij} / (1 + (i - j)^2)$$

خاکستری در پیکسلی است که در ردیف شماره i و ستون شماره j قرار دارد. ما این ویژگی‌های بافت GLCM را برای هر پیکسل، با حذف پیکسل‌های نزدیک به حاشیه تصویر، به‌دست آوردیم و سپس میانگین و انحراف استاندارد آنها را برای هر تصویر محاسبه کردیم. پارامتر مهم دیگری که بر عملکرد طبقه‌بندی تأثیر می‌گذارد اندازه هسته^۷ است. برای تعیین مناسب‌ترین اندازه هسته برای عملیات GLCM، ویژگی‌های بافت GLCM را با اندازه‌های مختلفی از هسته شامل ۳، ۱۱، ۱۹، ۲۷، ۳۵، ۴۳، ۵۱ و ۵۹ محاسبه کردیم. برای اعتبارسنجی SVM، از تابع شعاعی پایه^۸ (rbf) هسته استفاده کردیم و یک جستجوی شبکه پارامتری در محدوده گاما از 10^{-1} تا 10^{-5} و هزینه^۹ ۱ تا 10^5 انجام دادیم. در نتیجه عمل جستجوی شبکه، بهترین دقت اعتبارسنجی و بهترین پارامترها را برای هر اندازه از هسته GLCM به دست آوردیم (شکل پیوست S۳). دقت اعتبارسنجی همراه با افزایش اندازه هسته کمی بالاتر رفت و روند افزایش دقت در اندازه هسته 51×51 متوقف شد. با در نظر گرفتن این نتیجه، اندازه هسته را روی 51×51 قرار دادیم و بهترین پارامترها را به شرح زیر اتخاذ کردیم: گاما و هزینه به ترتیب 10^{-2} و 10^3 در فصل اوج پاییز و 10^{-3} و 10^4 در فصل برگ سبز بودند.

سپس از این پارامترها برای یادگیری SVM و ارزیابی

- 1- co-occurrence matrix
- 2- grey scale
- 3- angular second moment
- 4- dissimilarity
- 5- entropy
- 6- homogeneity
- 7- kernel size
- 8- radial basis function
- 9- cost

مقایسه‌ای استفاده کردیم. برای یادگیری ماشینی، داده‌ها را به مجموعه‌های آموزشی، اعتبارسنجی و آزمایشی تقسیم کردیم. مجموعه داده مربوط به اعتبارسنجی برای تنظیم ابرپارامترها^۱ مانند نرخ یادگیری، اندازه دسته^۲ برای یادگیری عمیق و اندازه هسته، هزینه و مقادیر گاما برای SVM استفاده شد. در مرحله آزمایشی، از داده‌هایی استفاده کردیم که برای آموزش و تنظیم پارامتری استفاده نشده بودند. دقت اعتبارسنجی برای مقایسه عملکرد و نتیجه‌گیری نهایی از آن مناسب نیست زیرا این نوع دقت می‌تواند بالاتر از دقت آزمایش باشد. ما در ابرپارامترها تغییراتی ایجاد کردیم تا با استفاده از داده‌های اعتبارسنجی به دقت بالاتری برسیم.

با استفاده از داده‌های آزمایشی، می‌توانیم سوگیری^۳ تنظیم پارامتر را حذف کنیم. ما همچنین از نوعی اعتبارسنجی متقابل^۴ استفاده کردیم زیرا داده‌های محدودی در اختیار داشتیم و از این طریق احتمال خطا را کاهش دادیم. در این مورد، ما به طور تصادفی تمام تصاویر را به طور مساوی به چهار مجموعه داده تقسیم کردیم و از دو مورد برای آموزش، یکی برای اعتبارسنجی و دیگری برای آزمایش استفاده کردیم. در ادامه، ما مجموعه داده‌های مورد استفاده برای آموزش، اعتبارسنجی و آزمایش را به‌طور متوالی با هم عوض کردیم. این روند چهار بار تکرار شد. برای ارزیابی دقت و ماتریس درهم‌ریختگی^۵، از دقت کل و تمام تصاویر استفاده کردیم.

برای این محاسبه، از یک رایانه رومیزی ساخت

به سفارش^۶ (BTO) با پردازنده Xeon E۵-۲۶۴۰، ۳۲ گیگابایت رم و کارت گرافیک GeForce GTX ۱۰۸۰ استفاده کردیم. سیستم عامل اوبونتو ۱۶.۰۴ بود.

ارزیابی. برای ارزیابی، از دقت کلی^۷، ضریب کاپا کوهن^۸ و متوسط کلان امتیاز F۱^۹ استفاده کردیم. امتیاز F۱ میانگین همسازی از بازخوانی^{۱۰} و صحت^{۱۱} است. در این مطالعه، تعداد تصاویر به دست آمده برای هر کلاس به طور قابل توجهی متفاوت بود. دقت کلی، که معمولاً برای ارزیابی عملکرد یادگیری ماشینی استفاده می‌شود، منوط به تفاوت در مقدار داده‌های موجود برای هر کلاس است. بنابراین، ما از روش‌های کاپا و امتیاز F۱ استفاده کردیم که برای ارزیابی دقت مجموعه داده‌ای نامتعادل و نیز دقت کلی جهت رسیدن به یک ارزیابی عینی مناسب است. علاوه بر این، برای ارزیابی دقت هر کلاسی، از امتیاز F۱ هر کلاس استفاده کردیم.

- 1- hyperparameter
- 2- batch size
- 3- bias
- 4- Cross-validation
- 5- confusion matrix
- 6- built to order
- 7- overall accuracy
- 8- Cohen's Kappa coefficient
- 9- macro average F1 score
- 10- Recall
- 11- Precision

نتایج


- فصل اوج پاییز.

ابتدا چهار مدل شبکه عصبی استاندارد ایجاد و آنها را بر روی داده‌های تصاویر ۲۰ نوامبر آموزش دادیم. اگرچه Resnet۱۵۲ بهترین عملکرد را نشان داد، تفاوت کمی بین دقت مدل‌های شبکه عصبی وجود داشت (جدول پیوست S۵). بنابراین ما Resnet۱۵۲ را به عنوان یک مدل معرف از شبکه عصبی پیش‌بینی پذیرفتیم و آن را تحت عنوان مدل CNN ۱ معرفی کردیم.


نتایج طبقه‌بندی مدل CNN ۱ در شکل ۶ نشان داده شده است. نتایج روش دقت کلی ۰,۹۷۶، روش کاپا ۰,۹۷۰ و روش امتیاز F1 ۰,۹۶۲ بود. مدل ۱ تقریباً تمام کلاس‌ها را با دقت بیش از ۹۰ درصد شناسایی کرد. یک کلاس که با دقت کمتر از ۹۰٪ بود، همچنان در زمره موارد با دقت نسبتاً بالا در نظر گرفته شد (بیش از ۸۵,۰٪). ماتریس درهم‌ریختگی نتایج دقیق پیش‌بینی مدل را نشان می‌دهد. محور عمودی واقعیت زمینی است که ما به صورت چشمی شناسایی کردیم. محور افقی کلاسی است که مدل پیش‌بینی کرده است. عدد در هر سلول نشان دهنده تعداد تصاویر طبقه بندی شده است. هر سلول نسبت به تعداد تصاویر در کلاس واقعیت زمینی رنگ می‌شود.

برای مثال، نسبت ۰,۰ (آبی روشن) نشان می‌دهد که هیچ تصویری در آن سلول طبقه بندی نشده است، در حالی که نسبت ۱,۰ (آبی تیره) نشان می‌دهد که تمام تصاویر واقعیت زمینی در آن سلول طبقه بندی شده‌اند. از این ماتریس درهم‌ریختگی، می‌توان دریافت که تقریباً همه کلاس‌ها به درستی طبقه بندی شده‌اند.


روش SVM را نیز با همین تصاویر آزمودیم. مشخص شد که دقت SVM کمتر از CNN بود. با این حال، عملکرد بالایی نیز از خود نشان داد (شکل ۷). برای SVM، روش‌های دقت کلی، کاپا و امتیاز F1 به ترتیب ۰,۹۱۸، ۰,۸۹۶ و ۰,۸۵۷ بودند. این مقادیر تقریباً ۶-۱۰٪ کمتر از نتایج مربوط به CNN هستند. با این حال، آنها هنوز هم نسبتاً بالا هستند. بیشتر موارد دقت خاص هر کلاس کمتر از نتایج CNN است، به ویژه در کلاس ۲ مربوط به درختان مخروطی برگ‌ریز، که شناسایی آن دشوار بود. همانطور که در مقایسه ماتریس درهم‌ریختگی نتایج CNN با نتایج SVM مشاهده می‌شود، طبقه‌بندی نادرست درختان پهن‌برگ و درختان مخروطی برگ‌ریز، به ویژه در دومی افزایش یافته است.



شکل ۶- ماتریس درهم‌ریختگی CNN در فصل پاییز (مدل ۱). محور عمودی، واقعیت زمینی و محور افقی، پیش‌بینی مدل است. عدد در هر سلول تعداد تصاویر طبقه‌بندی شده را نشان می‌دهد. هر سلول بر طبق درصد تعداد تصاویر در هر کلاس رنگی می‌شود. (کلاس ۱: درخت پهن برگ برگ‌ریز؛ ۲: درخت مخروطی برگ‌ریز؛ ۳: درخت همیشه سبز پهن برگ؛ ۴: سرو پاکوتاه؛ ۵: کاج باتلاقی یا کاج تدا؛ ۶: کاج سفید؛ ۷: غیر جنگلی).



شکل ۷- ماتریس درهم‌ریختگی SVM در فصل پاییز. (کلاس ۱: درخت پهن برگ برگ‌ریز؛ ۲: درخت مخروطی برگ‌ریز؛ ۳: درخت همیشه سبز پهن برگ؛ ۴: سرو پاکوتاه؛ ۵: کاج باتلاقی یا کاج تدا؛ ۶: کاج سفید؛ ۷: غیر جنگلی).



شکل ۸- ماتریس درهم‌ریختگی CNN در فصل برگ‌دار (مدل ۲). (کلاس ۱: درخت پهن برگ برگ‌ریز؛ ۲: درخت مخروطی برگ‌ریز؛ ۳: درخت همیشه سبز پهن برگ؛ ۴: سرو پاکوتاه؛ ۵: کاج باتلاقی یا کاج تدا؛ ۶: کاج سفید؛ ۷: غیر جنگلی).

- فصل برگ سبز.

برگ‌ریز دشوارتر باشد زیرا رنگ‌های هر کلاس مشابه است. با این حال، مدل ۲ بطور قابل توجهی عملکرد بهتری از آنچه ما انتظار داشتیم از خود نشان داد. عملکرد مدل ۲ در شکل ۸ نشان داده شده است. روش‌های دقت کلی، کاپا و امتیاز F1 به ترتیب ۰,۹۳۳، ۰,۹۱۴ و ۰,۹۰۱ بودند. دقت در هر کلاس نیز بالا است، در حدود ۹۰٪ در بیشتر کلاس‌ها. در مقایسه با طبقه‌بندی‌های نادرست در فصل پاییز، طبقه‌بندی نادرست درختان پهن‌برگ

سپس، چهار مدل شبکه عصبی استاندارد ایجاد کردیم و آنها را بر اساس داده‌های پایان فصل برگ سبز آموزش دادیم. همانند فصل اوج پاییز، Resnet۱۵۲ بالاترین عملکرد را نشان داد، اما اختلاف در عملکرد مدل‌ها بیشتر از آن فصل بود (جدول پیوست S۵). بنابراین ما Resnet۱۵۲ را به عنوان یک مدل CNN معرفی کردیم و آن را به عنوان مدل ۲ CNN معرفی کردیم. ما انتظار داشتیم که در این فصل شناسایی کلاس‌های



توجه که توسط Grad-CAM هدایت‌شونده تهیه شده و نیز تصویر اصلی خاکستری^۲ که بر روی نقشه توجه برای هر کلاس مشخص شده را نشان می‌دهد. برای درختان پهن برگ، تفهیم اینکه CNN از چه منطقه‌ای استفاده می‌کند، مشکل است. برای درختان مخروطی برگ‌ریز، ویژگی‌ها از کل منطقه استخراج می‌شوند و مکان آنها با کنتراست لبه شاخ و برگ کوچک منطبق است. در درخت همیشه سبز پهن برگ، اگرچه ویژگی‌های مورد نظر از رنگ کمی برخوردارند، اما می‌توانیم ویژگی‌های شاخصی را در امتداد لبه بوته شاخه در مقایسه با درخت پهن‌برگ برگ‌ریز مشاهده کنیم. برای سرو پاکوتاه، به روشنی می‌توان ویژگی‌هایی را در امتداد لبه انشعاب شاخه‌ها مشاهده کرد. در تصاویر کاج باتلاقی یا کاج تدا، ویژگی‌ها با لبه شاخه مطابقت دارند. برای کاج سفید، حاشیه درختان مشخص شده است.

بحث

این مطالعه به منظور بررسی توانایی سیستم دید ماشین، که تصویر RGB پهپادی و یادگیری عمیق را ترکیب می‌کند، برای طبقه‌بندی مجموعه درختان به چندین نوع و شناسایی گونه‌های خاصی از آنها انجام شد.

با توجه به طبقه بندی انواع درختان، مدل ۱ (مربوط به فصل پاییز) چهار نوع درخت و یک

برگ‌ریز و درختان همیشه سبز پهن‌برگ در فصل برگ سبز افزایش یافت. ما عملکرد SVM را نیز با مدل ۲ سنجیدیم، که در آن SVM در شناسایی این کلاس‌ها مشکل داشت (شکل ۹). دقت کلی به ۰,۷۰۰-۰,۸۰۳ کاهش یافت، با دقت خاص هر کلاس تقریباً ۷۰-۹۵ درصدی برای برخی کلاس‌ها، ۴۸٪ برای کلاس درخت کاج سفید و ۲۲٪ برای کلاس درختان همیشه سبز پهن برگ. طبق ماتریس درهم‌ریختگی، کلاس درختان همیشه سبز پهن‌برگ اغلب به اشتباه به عنوان درختان پهن‌برگ برگ‌ریز طبقه بندی می‌شود، در حالی که درخت کاج سفید عمدتاً به اشتباه در کلاس دیگر کاج‌ها و نیز درختان پهن‌برگ برگ‌ریز طبقه بندی می‌شود. در نهایت، ما نتایج طبقه‌بندی CNN مدل ۱ را در GIS به تصویر کشیدیم (شکل ۱۰). بیشتر تصاویر شیء در این شکل برای آموزش استفاده شده است. با در نظر گرفتن این موضوع، می‌توان مشاهده کرد که CNN در شناسایی درست درختان موفق بود.

در نتیجه، ما Grad-CAM هدایت‌شونده را برای ایجاد یک نقشه توجه^۱ به منظور به تصویر کشیدن ویژگی‌هایی که CNN برای طبقه‌بندی استفاده می‌کند، به خدمت گرفتیم. Grad-CAM هدایت‌شونده می‌تواند مکان‌ها و ویژگی‌های دقیقی را که به کلاس داوری شده مرتبط هستند، به تصویر بکشد. ما الگوریتم‌ها را برای کلاس‌ها به جز کلاس غیر جنگلی، به لایه ۴، آخرین لایه مدل ۲ اعمال کردیم. شکل ۱۱ تصویر اصلی، نقشه

1- Attention Map
2- grayscale



بنابراین، سیستم دید ماشینی ما می تواند به عنوان یک ابزار مقرون به صرفه و مفید برای استفاده در نقشه برداری و مدیریت جنگل استفاده شود.

با مقایسه عملکرد CNN با عملکرد SVM، در فصل اوج پاییز، کارایی بالای هر دو روش نشان داده شد. با این حال، در فصل برگ سبز، CNN عملکرد بسیار بهتری نسبت به SVM از خود نشان داد. ما از مقادیر میانگین و انحراف استاندارد باندهای RGB و ویژگی های بافت GLCM برای یادگیری SVM استفاده کردیم.

بنابراین، این تفاوت در ویژگی ها ممکن است در تفاوت عملکردی بین SVM و CNN نقش داشته باشد. این نتیجه همچنین نشان می دهد که CNN از ویژگی های بیشتری غیر از مقادیر میانگین و انحراف استاندارد باندهای RGB و ویژگی های بافت GLCM استفاده کرده است.

با استفاده از Grad-CAM هدایت شونده، ما موفق شدیم ویژگی هایی را که CNN استفاده می کرد، به تصویر بکشیم. نتایج Grad-CAM هدایت شونده نشان می دهد که مدل CNN از تفاوت در شکل لبه شاخ و برگ و بوته شاخه، الگوی شاخه بندی و طرح شکل درختان برای طبقه بندی استفاده کرده است. با رعایت این موارد، می توان گفت که CNN درختان را بر اساس ویژگی های ساختارهای بیولوژیکی که نمایانگر ویژگی های


کلاس غیر جنگلی را با کاپا ۰,۹۷۱ و امتیاز F1 ۰,۹۵۵ طبقه بندی کرد، در حالی که مدل ۲ آنها را با کاپا ۰,۹۱۱ و امتیاز F1 ۰,۸۸۲ طبقه بندی کرد. در سطح گونه درختی، مدل های ۱ و ۲ توانستند سرو پاکوتاه، کاج سفید از کاج باتلاقی و کاج تدا را با دقت بیش از ۹۰ درصد طبقه بندی کنند.

بنابراین، سیستم ما توانست انواع درختان را طبقه بندی کند و این توانایی را دارد که این کار را برای چندین گونه درختی در فصول دیگر نیز انجام دهد.

این قابلیت قابل توجه است زیرا ما فقط از تصاویر دیجیتالی RGB سهل الوصول استفاده کردیم. در مقابل، بیشتر مطالعات قبلی از سخت افزارهای گران قیمت، مانند تصویرگرهای چندطیفی، برای بهبود کیفیت کار استفاده می کردند. با توجه به مقیاس فضایی، روش ما با استفاده از پهنای ممکن است محدودتر از روش های قبلی با استفاده از حسگرهای هواپردی باشد. با این حال، ویژگی کم هزینه و استفاده آسان پهپادها می تواند پایش دوره ای را امکان پذیر سازد.

در همین حال، سایر مطالعات صورت گرفته با پهپادها تنها چند گونه درختی را شناسایی کردند یا از روش تشخیص اشیاء مستطیلی^۱ استفاده کردند. با توجه به این مسائل، سیستم ما بطور موفقیت آمیزی چندین کلاس از درختان را شناسایی و تهیه نقشه از جنگل را میسر ساخت.

1- rectangle object detection




شکل ۹. ماتریس درهم ریختگی SVM در فصل برگ سبز. (کلاس ۱: درخت پهن برگ برگریز؛ ۲: درخت مخروطی برگریز؛ ۳: درخت همیشه سبز پهن برگ؛ ۴: سرو پاکوتاه؛ ۵: کاج باتلاقی یا کاج تدا؛ ۶: کاج سفید؛ ۷: غیر جنگلی).

فیزیولوژیکی و اکولوژیکی کلاس های درخت هدف هستند، شناسایی کرده است.

این نتیجه همچنین نشان می دهد که CNN با استفاده از تصویر پهپادی می تواند درختان را با توجه به تفاوت در ویژگی های ساختاری آنها با موفقیت شناسایی کند، حتی اگر درختان رنگ های مشابهی داشته باشند. با توجه به این واقعیت، انتظار توانمندی مکانی و زمانی بالایی از این سیستم می رود، زیرا در صورت تغییر رنگ برگ در اثر عواملی مانند آب و هوا یا فصل، باز

هم می توان با استفاده از ویژگی های ساختاری آن را به درستی طبقه بندی کرد. در روش ما، دو دلیل برای این نتیجه درخشان وجود دارد. ابتدا، ما طبقه بندی مبتنی بر شیء را انجام دادیم. مطالعات قبلی نشان داده اند که قطعه بندی مبتنی بر شیء می تواند دقت بالاتری نسبت به طبقه بندی مبتنی بر پیکسل داشته باشد. یکی از مزایای استفاده از قطعه بندی اشیاء این است که هر تصویر می تواند ویژگی های مشترک بیشتری داشته باشد.



deciduous broad-leaved tree	درخت پهن برگ برگ‌ریز
deciduous coniferous tree	درخت مخروطی برگ‌ریز
evergreen broad-leaved tree	درخت همیشه سبز پهن‌برگ
Chamaecyparis obtuse	سرو پاکوتاه
Pinus elliottii or Pinus taeda	کاج باتلاقی یا کاج تدا
Pinus strobus	کاج سفید
non-forest	غیر جنگلی

شکل ۱۰. تصاویر ارتوموزائیک و نقشه‌های طبقه‌بندی به‌دست‌آمده با استفاده از CNN. تصاویر بالایی هر یک نمای کلی از یک منطقه را ارائه می‌دهند، و تصاویر پایینی در هر ستون، ناحیه بزرگ شده مربوطه را نشان می‌دهند. کلاس‌های درختی موجود در تصاویر در لژاند پایین شکل مشخص شده‌اند. این شکل با استفاده از نرم افزار ArcGIS Desktop نسخه ۱۰.۶ (<https://www.esri.com>)، موسسه تحقیقات سیستم‌های محیطی، ردلندز، ایالات متحده) تهیه شده است.

درختی (یا DSM) و فصلی بودن رنگ برگ‌ها، بر دقت طبقه‌بندی می‌افزاید. با این وجود، به طور کلی، این ویژگی‌ها ممکن است تأثیر منفی بر یادگیری ماشینی ساده داشته باشند. از لحاظ عملی، در مطالعات آتی تهیه یک مدل چند بعدی که شامل تصاویر آموزش دیده از مکان‌ها و زمان‌های مختلف باشد، مورد نیاز است. اگرچه ما با استفاده از CNN به طبقه‌بندی با دقت بالایی دست یافتیم، اما بعضاً طبقه‌بندی نادرستی نیز داشتیم. بطور شاخص مدل ۲ تلاش کرد درختان پهن‌برگ و درختان همیشه سبز را شناسایی کند این طبقه‌بندی نادرست ممکن است به گنجاندن کلاس چندین گونه درختی نسبت داده شود، یعنی الگوی شاخه و رنگ ممکن است در یک نوع درخت مشترک نباشد. بنابراین، جداسازی کلاس‌ها در اندازه انواع شاخه‌های ریزدانه یا گونه های درختی ممکن است دقت طبقه بندی را بهبود بخشد. بنابراین، روش جداسازی هر کلاس ممکن است یکی از پارامترهای کلیدی باشد که بر عملکرد طبقه‌بندی تأثیر می‌گذارد.

در نهایت، ما زنجیره‌ای از سیستم‌های دید ماشینی ساختیم که می‌تواند درختان را به طور خودکار طبقه‌بندی و شناسایی کند. اگر چه این کلاس‌ها محدود هستند اما این روش می‌تواند به عنوان یک سیستم پایه برای سیستم‌های نقشه‌برداری درختی با استفاده از تصاویر پهپادی مورد استفاده قرار گیرد.

برای مثال، با قضاوت از تصویر سرو پاکوتاه در شکل ۱۱، CNN از ویژگی‌های اطراف نوک درخت استفاده کرد. با استفاده از طبقه‌بندی شیء، بیشتر تصاویر می‌توانند از این ویژگی برخوردار باشند. با این حال، اگر از طبقه‌بندی مبتنی بر پیکسل استفاده کنیم، هر تصویر با یک تصویر مستطیلی مانند 64×64 پیکسل برش داده می‌شود. بنابراین، احتمال اینکه تصویر دارای آن ویژگی‌های مشترک باشد کم خواهد بود و دقت طبقه‌بندی ممکن است کمتر باشد. روش ما نمی‌تواند تاج هر درخت را به طور کامل طبقه‌بندی کند. بنابراین، بهبود روش طبقه‌بندی منجر به دقت طبقه‌بندی بالاتر می‌شود و همچنین ما را قادر می‌سازد تا تعداد درختان را بشماریم. طبقه‌بندی تاج درختان با استفاده از یک پارامتر خاص مشکل است زیرا اندازه درخت و تفکیک نوک درختان مختلف دشوار است، به خصوص در جنگل‌های مختلط. در مطالعات بعدی، استفاده از یک روش یادگیری عمیق مانند طبقه‌بندی نمونه‌ای می‌تواند پتانسیل بالایی برای طبقه‌بندی تاج درخت فراهم نماید.


دوم، ما تصاویر آموزشی و آزمایشی را از همان منطقه و در همان زمان انتخاب کردیم. شکل درختان در محیط‌های مختلف متغیر است و رنگ‌ها و روشنایی برگ‌ها بسته به دوره، نوع اقلیم و فصل‌ها متفاوت است. استفاده از اشکال

نتیجه گیری

در این مقاله، ما زنجیره‌ای از سیستم دید ماشینی کم هزینه را برای شناسایی درختان با استفاده از تصویر RGB پهپادی و یادگیری عمیق پیشنهاد کردیم. سیستم ما به دقت بیش از ۹۰ درصدی برای طبقه‌بندی انواع درختان و گونه‌های درختی خاص دست یافت. علاوه بر این، نتایج نشان می‌دهد که CNN درختان را بر اساس ویژگی‌های ساختار بیولوژیکی آنها مانند شکل شاخ و برگ و الگوی شاخه‌بندی طبقه‌بندی کرد. بنابراین، این سیستم ممکن است پتانسیل شناسایی چندین گونه درختی را داشته باشد، حتی اگر رنگ درختان مشابه باشد. در مطالعات بعدی، نیاز به قطعه‌بندی تاج درخت با استفاده از یادگیری عمیق است، و ما در حال برنامه‌ریزی برای شناسایی گونه‌های دقیق‌تر و نیز ارزیابی کارایی مکانی و زمانی سیستم تهیه شده هستیم.


دسترسی به داده‌ها

داده‌هایی که از یافته‌های این مطالعه پشتیبانی می‌کنند، بنا به درخواست مشخصی، توسط نویسنده مسئول در اختیار شما قرار خواهد گرفت.



شکل ۱۱- نقشه‌های توجه Grad-CAM هدایت‌شونده. (از چپ به راست) نام کلاس، تصویر اصلی، نتیجه Grad-CAM هدایت‌شونده، نتیجه Grad-CAM هدایت‌شونده‌ای که تصویر اصلی خاکستری روی آن قرار گرفته.

deciduous broad-leaved tree	درخت پهن برگ برگ‌ریز
deciduous coniferous tree	درخت مخروطی برگ‌ریز
evergreen broad-leaved tree	درخت همیشه سبز پهن‌برگ
Chamaecyparis obtuse	سرو پاکوتاه
Pinus elliottii or Pinus taeda	کاج باتلاقی یا کاج تدا
Pinus strobus	کاج سفید
non-forest	غیر جنگلی



مقاله دوم

نقشه‌برداری گونه‌های (گیاهی) مهاجم کنار رودخانه‌ای با طبقه‌بندی نظارت شده از تصاویر گرفته شده توسط سیستم پهپاد

چکیده

نواحی کنار رودخانه‌ای چشم‌اندازهای کلیدی هستند که نشانگر سطح مشترک بین اکوسیستم‌های زمینی (خاکی) و آبی هستند. با وجود اینکه آنها برای قرن‌ها توسط فعالیت‌های انسان تحت‌تاثیر قرار گرفته‌اند، نرخ کاهش این نواحی در طی قرن بیستم سریع‌تر شده است. همراه با (یا در نتیجه) این اختلال‌های انسانی، هجوم گونه‌های سمی در سراسر نواحی کناررودخانه‌ای جهان افزایش یافته است.

در این مطالعه، ما یک چارچوب روش‌شناختی با قابلیت تجدیدپذیری آسان را برای نقشه‌برداری سه‌آرایه (تاکسا) با استفاده از تصویربرداری با سیستم‌های پهپاد پیشنهاد می‌کنیم: روئل *Impatiens glandulifera*، سومیر و لویر *Heracleum Fallopia* mantegazzianum و گیاه هفت‌بند ژاپنی (*Fallopia japonica* (هوت) و گیاهان پیوندی و دورگه‌های آنها). براساس ارتوفوتوی مرئی و فروسرخ نزدیک

سیستم پهپاد، ما معیارهای طیفی و بافت ساده تصویر را که در مقیاس‌های متنوعی از بخش‌بندی تصویر محاسبه شدند را استخراج کردیم (۱۰، ۳۰، ۴۵، ۶۰ با استفاده از نرم‌افزار eCognition). دسته‌بندی نظارت شده براساس الگوریتم جنگل‌های تصادفی برای شناسایی مرتبط‌ترین متغیرهای مشتق شده (یا ترکیبی از متغیرها) از تصویربرداری با پهپاد برای نقشه‌برداری از گونه‌های گیاهی مهاجم حاشیه رودخانه‌ای استفاده شد. مدل‌ها با استفاده از ۲۰٪ مجموعه داده‌ها ساخته شدند و مابقی مجموعه داده‌ها به عنوان مجموعه آزمون استفاده شدند (۸۰٪).

به استثنای *H. mantegazzianum*، بهترین نتایج از لحاظ دقت کلی با ریزترین مقیاس تجزیه و تحلیل حاصل شدند (پارامتر مقیاس بخش‌بندی = ۱۰). بهترین مقادیر کلی دقت‌های ۷۲٪، ۶۸٪ و ۹۷٪ به ترتیب برای گیاهان *I. glandulifera*، هفت‌بند ژاپنی و *H. mantegazzianum* بدست آمدند.

۱. مقدمه

با توجه به معیارهای انتخاب شده، معیارهای طیفی ساده (میانگین لایه/روشنایی دوربین) پرکاربردترین معیارها بودند. نتایج ما نیز ارزش افزون معیارهای بافت (مشتقات GLCM) برای نقشه‌برداری گونه‌های مهاجم کناررودخانه‌ای را تایید می‌کنند. نتایج بدست آمده برای *I. glandulifera* و گیاه هفت‌بند ژاپنی به دقت‌های کافی برای کاربردهای عملیاتی نمی‌رسند. با این حال، نتایج حاصل شده برای *H. mantegazzianum* دلگرم‌کننده هستند. مقدار دقت‌های بالا همراه با ورودی‌های مدل نسبتاً سبک مورد نیاز (توصیف و طرح تعدادی چترک) رویکرد ما را به عنوان یک ابزار مقرون به صرفه برای بهبود مدیریت میدانی *H. mantegazzianum* به یک مدعی جدی تبدیل می‌کند.

نواحی کناررودخانه‌ای چشم‌اندازهای کلیدی هستند که نشانگر سطح اتصال بین اکوسیستم‌های خاکی - آبی هستند. آنها با وجود یک پوشش سطح کمتر، خدمات اکوسیستم متعددی را فراهم می‌کنند و یک پراکندگی زیستی غنی استثنایی را نشان می‌دهند (نایمان و ده‌کامپس، ۱۹۹۷). نواحی کناررودخانه‌ای طی قرن‌ها با فعالیت‌های انسانی تحت‌تاثیر قرار گرفته‌اند چون آنها غالباً شامل سکونت‌گاه‌های متمرکز و متراکم انسانی هستند (ده‌کامپس و همکاران، ۱۹۸۸). با این وجود، شیب کاهش آنها در قرن بیستم بیشتر



شده است. تا حدود ۹۰٪ دشت‌های سیلابی در اروپا و آمریکای شمالی با از بین رفتن عملکرد آنها اصلاح شده‌اند (تاکنر و استنفورد، ۲۰۰۲). اختلالات انسانی مختلفی از جمله تغییرات هیدرولوژیکی (جانسون و همکاران، ۲۰۰۰)، استفاده از حوزه آبخیز و سرزمین‌های مجاور و چوب‌بری و چرای مراتع (هنکاک و همکاران، ۱۹۹۶) و حتی فعالیت‌های تفریحی و سرگرمی (واشیتانی، ۲۰۰۱) می‌توانند زیستگاه‌های حاشیه رودخانه‌ای را تحت‌تاثیر قرار دهند. همراه با (یا در نتیجه) این اختلال‌ها، هجوم گونه‌های سمی نیز در سراسر مناطق کناررودخانه‌ای جهان افزایش یافته است (ریچاردسون و همکاران، ۲۰۰۷).

روند هجوم توسط گونه‌های سمی در نواحی کنار رودخانه‌ای به خوبی مستند شده است (پلانتی - تاباچی و همکاران، ۱۹۹۶؛ لیک و لیثمن، ۲۰۰۴؛ ریچاردسون و همکاران، ۲۰۰۷). اکوسیستم‌های حاشیه رودخانه‌ای به ویژه با وقوع سیل‌ها بسیار پویا و دینامیک هستند که حفره‌های با قاعده و مرتبی را برای کاشته شدن گونه‌های مهاجم مهیا می‌کنند. سیل‌ها فرصت پخش و انتشار را نیز فراهم می‌کنند که منجر به یک نرخ بالاتر هجوم در نواحی کناررودخانه‌ای می‌شود و این امر نیز برخی نویسندگان را وادار می‌سازد تا نواحی کناررودخانه‌ای را با عنوان "بهشتی برای گونه‌های گیاهی سمی" خطاب کنند (استولگرن و همکاران، ۱۹۹۸).



در اروپا، لامبدون و همکاران (۲۰۰۸) ۵۷۸۹ گونه گیاه سمی را گزارش کردند، درحالیکه اشنیتزلر و همکاران (۲۰۰۷) ۴۳ گونه گیاهی سمی در جنگل‌های کنار رودخانه‌ای اروپا با خصوصیات غیرمهاجم در حال تغییر را شناسایی کردند. بلژیک به طور ویژه با مشکل گونه‌های غیرمهاجم تحت‌تاثیر قرار می‌گیرد و بیشترین تعداد گونه‌های گیاهی سمی ثبت شده را در اروپا در سال ۱۹۶۹ دارد (لامبدون و همکاران، ۲۰۰۸). نواحی کناررودخانه‌ای بلژیک به طور ویژه توسط فعالیت‌های انسانی تحت فشار قرار می‌گیرند و به طور گسترده توسط سه آرایه مورد هجوم قرار گرفته‌اند: *Impatiens glandulifera*، *Heracleum mantegazzianum* و گیاه هفت‌بند ژاپنی (*Fallopia sachalinensis*) (اف. اشمیت پتروپ)؛ *Fallopia japonica* (هوت) و گیاهان پیوندی و دورگه‌های آنها). این گونه‌ها با عنوان مهاجمان بسیار موفق شناخته شده (پایسک و پراچ، ۱۹۹۳) و در اروپای قرن نوزدهم به عنوان گیاهان باغی تزئینی مشهور بوده‌اند (پایسک، ۱۹۹۱؛ پایسک و پراچ، ۱۹۹۵؛ بارنی، ۲۰۰۶).

این سه گونه عموماً پایه‌های غالب و ویژه‌ای را تشکیل می‌دهند که موجب پایین آوردن پوشش و پراکندگی خاص گونه‌های گیاهی کناررودخانه‌ای بومی می‌شود (هجدا و همکاران، ۲۰۰۹). با این وجود، تاثیر جمعیت‌های *I. glandulifera* روی پوشش گیاهی کناررودخانه‌ای پیچیده‌تر است چون آنها تاثیر نسبتاً کمتری روی جمعیت‌های

گیاهی دارند (هولم و برمنر، ۲۰۰۵) و به عنوان یک عامل مثبت برای جوامع و کلونی‌های زنبور توصیف شده‌اند (لوپزرایاز و میکل و همکاران، ۲۰۰۷).

در والونیا، تلاش‌ها و مطالعات انجام شده توسط زمین‌شناسان و مدیران املاک برای کاهش گسترش این گونه‌ها موفقیت‌های متفاوتی داشته‌اند (دلبارت و همکاران، ۲۰۱۰). هم‌اکنون نیز رویکردهای موثری برای مدیریت *H. mantegazzianum* و *I. glandulifera* موجود هستند درحالی‌که طبق نتایج این مطالعات هفت‌بند ژاپنی به روش‌های مدیریتی مختلف بسیار مقاوم بوده است (دلبارت و همکاران، ۲۰۱۲). از بین این گونه‌ها، در حال حاضر *H. mantegazzianum* ها تنها گونه‌هایی هستند که به صورت سیستماتیک توسط مدیران املاک عمومی در والونیا مدیریت شده‌اند.

با توجه به ظرفیت بالای هجوم این گونه‌ها، کلیه‌های راهبردهای مدیریتی بالقوه باید از طریق تحلیل‌های پایین‌دست و بالادست انجام شوند. در واقع، جمعیت‌های بالادست باقیمانده می‌توانند باز هم پروپاگول یا قطعه تکثیر را منتشر کنند که به طور بالقوه باعث یک هجوم جدید می‌شود. در مورد عملیات‌های ریشه‌کنی (مثل *H. mantegazzianum* والونیا)، هدف مدیران املاک حصول یک بازرسی کامل از شبکه رودخانه است. این کار بسیار زمان‌بر بوده و شامل هزینه‌های

انسانی زیادی است. این امر نشانگر مقداری خطر برای کاربران زمین است. به همین خاطر و نیز برای بازبینی کلی، روش‌های سنجش از دور می‌توانند اطلاعات عینی، قابل تکرار و مقرون به صرفه را برای مدیران املاک فراهم کنند.

رویکردهای سنجش از دور مختلف برای نقشه‌برداری گونه‌های گیاهی مهاجم می‌توانند در مقالات پیدا شوند. تصویربرداری هوایی با وضوح بسیار بالا استفاده متداولی در نگاشت و نقشه‌برداری توزیع فضایی (مکانی) گیاهان بیگانه دارد و با نتایج رضایتبخش روی *H. mantegazzianum* در جمهوری چک (مولرووا و همکاران، ۲۰۰۵، ۲۰۱۳) و روی هفت‌بند ژاپنی در انگلستان (جونز و همکاران، ۲۰۱۱) آزمایش شده‌اند. با توجه به وجود غیریکنواختی در مقیاس پیکسل (≥ 10 cm)، مطالعات نتایج بهتری را از طریق استفاده از تحلیل تصویر مبتنی بر شی (OBIA) حاصل کردند (باتز و شاپی، ۲۰۰۰). تصویربرداری ماهواره‌ای با وضوح بالا یک راه‌حل جایگزین هنگام نقشه‌برداری قطعه زمین‌های پوشیده از گونه‌های گیاهی مهاجم بزرگتر از وضوح فضایی مربوطه است (مولرووا و همکاران، ۲۰۱۳؛ فرناندز و همکاران، ۲۰۱۴). هوآنگ و آسنر (۲۰۰۹) بر این حقیقت صحنه می‌گذارند که "هجوم گیاهان بیگانه می‌تواند با استفاده از سنجش از دور مطالعه شود و این در زمانی است که گیاه مهاجم یک ساختار، پدیده‌شناسی یا زیست‌شیمی نوین مرتبط با پوشش گیاهی محلی مجاور را نشان دهد".



نویسندگان دیگر نیز از اهمیت کسب داده‌ها از طریق سنجش از دور در زمانی که مرحله پدیده‌شناسی گونه‌های مهاجم، آن را در مقایسه با گونه‌های بومی قابل تشخیص می‌سازد (مثلاً از طریق گلدهی مجزا) آگاه هستند (مولرووا و همکاران، ۲۰۰۵، ۲۰۱۳). استفاده از سیستم‌های پهپاد برای نقشه‌برداری گونه‌های مهاجم جدیدترین روند کاری در این زمینه است و می‌تواند الزامات و نیازمندی‌ها را به طور جزئی برآورده سازد.

تصویربرداری با پهپاد یک رویکرد مقرون به صرفه است که کاربران نهایی را قادر می‌سازد (با آگاهی کامل از زمین) تا داده‌ها را با وضوح زمانی و مکانی بسیار بالا بدست آورند. این دو مشخصه رابطه ویژه‌ای با نقشه‌برداری گونه‌های گیاهی مهاجم کوچک در یک مرحله پدیده‌شناسی ویژه همچون مرحله گل‌دهی دارد. کارهای قبلی از قبیل استفاده از تصویربرداری با پهپاد برای نگاشت گونه‌های مهاجم در مقالات نادر و کمیاب هستند اما نتایج پیشین امیدوارکننده و نویدبخش هستند. وان و همکاران (۲۰۱۴) طبقه‌بندی بسیار خوبی (دقت کلی ۹۴٪) از *Spartina alterniflora* را در چین بدست آوردند درحالی‌که زمان و همکاران (۲۰۱۱) و هونگ و همکاران (۲۰۱۴) نتایج مشابهی را (۹۵٪ و ۹۴٪) به ترتیب در نقشه‌برداری گونه‌های مهاجم در ایالات متحده آمریکا و استرالیا حاصل کردند. این مطالعات پیش‌تازانه روی یک مکان واحد و گونه‌های تکی تمرکز کرده‌اند (وان و همکاران ۲۰۱۴)، زمان و همکاران (۲۰۱۱)، درحالی‌که



هونگ و همکاران (۲۰۱۴) روی توسعه الگوریتم‌های یادگیری صفت تمرکز کرده‌اند. متعاقباً، رویکردهای روش‌شناختی جدید آزمایش شده روی مکان‌های مطالعاتی مختلف و گونه‌های مختلف موردنیاز هستند.

ما پیشنهاد می‌کنیم تا طبقه‌بندی نظارت‌شده‌ای را مبتنی بر الگوریتم جنگل‌های تصادفی بسازیم (بریمان، ۲۰۰۱) تا مرتبط‌ترین متغیر (یا ترکیبی از متغیرها) مشتق شده از تصویربرداری پهپادی را برای نقشه‌برداری گونه‌های گیاهی مهاجم حاشیه‌رودخانه‌ای شناسایی کنیم. هدف مطالعه ما پیشنهاد یک چارچوب روش‌شناختی کلی و تجدیدپذیر برای نقشه‌برداری دقیق گونه‌های مهاجم مختلف در نواحی کنار رودخانه‌ای استفاده کننده از تصویربرداری پهپادی آماده است. برطبق مطالعات موردی، این چارچوب روش‌شناختی در دو چشم‌انداز حاشیه‌رودخانه‌ای مجزا و گونه‌های مهاجم مختلف (هفت‌بند ژاپنی، *H. mantegazzianum* و *I. glandulifera*) بکار رفته است.

۲. روش‌ها

ما یک روش قابل تجدیدپذیر راحت را برای نقشه‌برداری گونه‌های مهاجم با تصویربرداری از طریق سیستم پهپاد (شکل ۱) مبتنی بر یک مجموعه آموزشی با ارجاع جغرافیایی پیشنهاد می‌کنیم.

۲-۱. مکان‌های مطالعاتی

ما تحلیل خود را روی دو ناحیه کناررودخانه‌ای ($>30\text{ m}$ از کانال مرطوب) واقع در والونیا متمرکز کرده‌ایم (بلژیک جنوبی، شکل ۲ را ببینید). دره بروین به دلیل وجود همزمان دو گونه *H. mantegazzianum* و *I. glandulifera* انتخاب شد. استفاده سرزمینی یافته شده در حوضچه آبی این انشعاب از رودخانه میوس عمدتاً کشاورزی است (چمنزار و باغ‌های میوه). دره اورنیو در یک چشم‌انداز کشاورزی واقع شده است که با محصولات کشاورزی کشت شده به صورت فشرده تحت تسلط قرار گرفته است. اورنیو یک انشعاب فرعی از رودخانه سامبر است که در آن گیاه هفت‌بند ژاپنی معمولاً در ساحل رود یافت می‌شود. مکان‌های مطالعه یک طول رودخانه ۲ کیلومتری و ۸ کیلومتری را به ترتیب برای دره‌های بروین و اورنیو پوشش می‌دهند.


۲-۲. نقشه‌برداری هوایی

پهپاد Gatewing X100 (طول بال: ۱۰۰ cm، وزن: ۲ kg؛ سرعت کروز: ۸۰ km/h؛ ارتفاع پرواز: از ۱۰۰ متر تا ۷۵۰ متر) در هفت پرواز استفاده شد (جدول ۱). سیستم پهپاد شامل دو دوربین Ricoh GR3 از پیش کالیبره شده (۱۰ مگاپیکسل؛ طول کانونی ۶ mm) است که یکی از آنها برای تصویربرداری نزدیک فروسرخ بکار گرفته شد. مدت زمان پرواز هیچگاه از ۴۵ دقیقه بیشتر نشد و همپوشانی بین تصاویر روی ۷۵٪ تنظیم شد.



هدف مورد استفاده قرار گرفتند: دوره گل‌دهی برای *H. mantegazzianum* و *I. glandulifera* و دوره زرد شدن برگ برای هفت‌بند ژاپنی که در اواخر فصل رویش روی می‌دهند.

سرعت شاتر دوربین روی ۱/۲۰۰۰ تنظیم شد درحالی‌که حساسیت ISO پیش از هر نقشه‌برداری پروازی مطابق با تابندگی در مکان اتخاذ شد. نقشه‌برداری‌های هوایی در یک مرحله پدیده‌شناختی ویژه برای هر یک از گونه‌های



شکل ۱. جریان کاری کلی



۲-۳. فرآیند فوتوگرامتری

ما از اگسافت فوتواسکن ۱,۰ حرفه‌ای برای انجام نقشه‌برداری‌های هوایی فوتوگرامتری به دلیل استفاده در حال رشد آن در صنعت پهپاد استفاده کردیم (دندویس و الیس، ۲۰۱۳، ۲۰۱۰؛ سونا و همکاران، ۲۰۱۴).

جریان کاری توصیف شده در شکل ۳ برای پردازش هر مجموعه داده پرواز استفاده شد.

تاریخ	گونه‌های هدف	پدیده‌شناسی	دوربین	تصاویر	ارتفاع پرواز (m)	پوشش (km ^۲)	GSD (m)
۲۰۱۲-۰۶-۱۲	H. mantegazzianum	گل‌دهی	RGB	۵۰۱	۲۰۰	۰,۷۵	۰,۰۵
۲۰۱۲-۰۶-۱۲	H. mantegazzianum	گل‌دهی	RGNIR	۴۲۶	۲۰۰	۰,۷۵	۰,۰۵
۲۰۱۲-۰۷-۲۴	I. glandulifera	گل‌دهی (آغاز)	RGB	۶۴۳	۱۵۰	۰,۷۵	۰,۰۵
۲۰۱۲-۰۷-۲۴	I. glandulifera	گل‌دهی (آغاز)	RGNIR	۴۶۵	۱۵۰	۰,۷۵	۰,۰۵
۲۰۱۲-۰۹-۰۵	I. glandulifera	گل‌دهی (پایان)	RGB	۳۷۱	۱۵۰	۰,۷۵	۰,۰۵
۲۰۱۲-۰۹-۰۵	I. glandulifera	گل‌دهی (پایان)	RGNIR	۳۷۳	۱۵۰	۰,۷۵	۰,۰۵
۲۰۱۳-۱۰-۰۱	هفت‌بند ژاپنی	زرد شدن برگ‌ها	RGB	۱۱۱۵	۳۰۰	۸	۰,۱۰
۲۰۱۳-۱۰-۲۴	هفت‌بند ژاپنی	زرد شدن برگ‌ها	RGB	۴۰۷	۳۰۰	۲	۰,۱۰

جدول ۱. نقشه‌برداری هوایی (GSD: فاصله نمونه‌برداری زمین اورتوفوتو؛ پدیده‌شناسی: مرحله پدیده‌شناسی گونه‌های هدف).

گونه‌ها	مساحت (m ^۲)	واحد نمونه	تاریخ نقشه‌برداری میدانی (زمینی)
H. mantegazzianum	۳۴,۴	چترک‌ها	۲۰۱۲-۰۶-۱۲
I. glandulifera	۵۸۶,۴	پایه‌های گل‌دهی	۲۰۱۲-۰۸-۲۲
هفت‌بند ژاپنی	۵۶۴۶,۲	قطعات هفت‌بند	۲۰۱۳-۱۰-۱۵

جدول ۲. مجموعه داده‌ها با مرجع جغرافیایی



۲-۵. بخش‌بندی تصویر چند - وضوحی

بخش‌بندی اورتوفوتوهای سیستم پهپاد با استفاده از نرم‌افزار eCognition developer با یک الگوریتم بخش‌بندی تصویر چند - وضوحی انجام شد (بلاشکی، ۲۰۱۰). پارامتر مقیاس (مربوط به اندازه شی) در ترکیب با معیار شکل و فشردگی (همگن بودن جسم) به اندازه و شکل اجسام حاصل شده ارتباط دارد. برای تعریف مرتبط‌ترین مقیاس تجزیه و تحلیل، ما چهار پارامتر مقیاس مختلف را آزمایش کردیم: ۱۰، ۳۰، ۴۵ و ۶۰ (جدول ۳). معیار هماهنگی و تجانس (شکل و فشردگی) روی مقادیر پیش‌فرض (به ترتیب ۰,۱ و ۰,۵) تنظیم شدند. سه باند طیفی به طور معادل در پارامتر بخش‌بندی ایجاد شدند.

در تکمیل جریان کاری فوتوگرامتری (شکل ۳)، ما اورتوفوتوهایی (با فاصله نمونه‌برداری زمینی ۰,۱ m و ۰,۰۵ m) را با فوتواسکن برای هر مجموعه داده پرواز با استفاده از حالت ترکیب و اختلاط "موزائیکی" همراه با گزینه تصحیح رنگ ساختیم.

۲-۴. مجموعه داده‌های مرجع

یک مجموعه داده با مرجع جغرافیایی از قطعات پوشیده از گونه‌های مهاجم برای هر گونه مطالعه شده جمع‌آوری شد (جدول ۲). مجموعه داده مرجع متشکل از چندضلعی‌هایی است که براساس نقشه‌برداری‌های زمین (یعنی موقعیت جسمی که باید نقشه‌برداری شود) و تصویر اصلاح شده زمین پسا - نقشه‌برداری براساس اورتوفوتوها رقمی‌سازی شده‌اند.




شکل ۲. مکان‌های مطالعاتی: دره اورنیو (هفت‌بند ژاپنی) و دره بروین (H.mantegazzianum و I.glandulifera) به ترتیب در

N_۳۶_۴۳۵۰/E_۲۵_۴۶۰ و N_۷_۳۳۵۰/E_۴۴_۴۲۵۴

۲- ۶. استخراج معیار


برای اطمینان از انتقال پذیری نتایج خود، ما معیارهای ساده تصویربرداری با پهپاد را با استفاده از رابط کاربری eCognition محاسبه کردیم. ما پنج مشتق از ماتریس هم‌رویداد برای سطوح خاکستری (GLCM) را براساس پژوهش هارالیک و همکاران (۱۹۷۳) انتخاب کردیم که عبارتند از: آنتروپی، انحراف معیار، همبستگی، میانگین و کنتراست. این مشتقات به دلیل کارایی اثبات شده آنها در رویکردهای مشابه انتخاب شدند

(لالیبرت و رانگو، ۲۰۰۹؛ استاپ و کرلی، ۲۰۱۱) و از طریق معیارهای متقارن برای پیکسل‌های مجاور در 0.45° ، 90° یا 135° محاسبه می‌شوند. در این مطالعه، ما روش "همه جهات" را انتخاب کردیم که در آن مجموع هر چهار جهت پیش از محاسبه بافت از GLCM محاسبه می‌شوند. با توجه به معیارهای طیفی، ما روش خود را تنها به در نظر گرفتن میانگین‌های لایه و روشنایی دوربین ساده محدود کردیم.



شکل ۳. جریان کاری فوتوگرامتری

۴. اجسام انتخاب شده ۳. حقایق عینی (داده‌های مرجع) ۲. بخش بندی ۱. تصاویر پهپادی



شکل ۴. ساخت اورتوفوتوهای سیستم پهپاد مجموعه داده نمونه (مورد H.mantegazzianum)؛ ۲ - بخش بندی چند - وضوحی؛ ۳ - مجموعه داده چندضلعی‌های مرجع؛ ۴ - اجسام گونه‌های گیاهی مهاجم انتخاب شده (پوشش بیشتر از ۷۵٪)

پارامتر مقیاس تحلیل OBIA	مساحت میانگین (m ²)	تعداد بخش‌ها
۱۰	۰,۳۴	۳,۸۱,۵۸۶
۳۰	۲,۴۵	۵۳,۵۹۲
۴۵	۴,۹۳	۲۶,۵۹۶
۶۰	۷,۷۸	۱۶,۸۴۶

جدول ۳. مشخصات بخش‌های ایجاد شده (مساحت میانگین و تعداد بخش‌ها). تعیین خصوصیات برای نقشه برداری هوایی ۲۰۱۲ - ۰۹ - ۰۵ انجام می‌شود (نقشه برداری I.glandulifera)

۲- ۷. طبقه بندی نظارت شده

داده‌های سنجش از دور بسیار پیچیده و دارای ابعاد بالاتر انتخاب شد (لارنس و همکاران، ۲۰۰۶؛ کاتلر و همکاران، ۲۰۰۷؛ واتس و همکاران، ۲۰۰۹؛ استامپر و کرلی، ۲۰۱۱). براساس زیرمجموعه‌های تصادفی مجموعه داده آموزشی، چندین درخت تصمیم‌گیری انفرادی رشد پیدا می‌کنند. اختلاف زیاد بین درخت‌های تصمیم‌گیری انفرادی، ساختن مدل‌های دقیق و استواری را حتی در

ما از فرآیندهای طبقه بندی نظارت شده براساس الگوریتم جنگل‌های تصادفی (RF) استفاده کردیم (بریمان، ۲۰۰۱). فرآیندهای RF امکان تشخیص و شناسایی مرتبط‌ترین ترکیبات معیارهای مشتق شده از تصویربرداری با پهپاد را برای نقشه برداری گونه‌های گیاهی مهاجم کناررونده‌ای فراهم می‌کنند. روش یادگیری ماشین RF به دلیل توانایی آن برای رسیدگی و بررسی مجموعه



حضور متغیرهای نويزدار و شلوغ امکان‌پذیر می‌سازد.

برای هر مقیاس از تجزیه و تحلیل (پارامترهای مقیاس: ۱۰، ۳۰، ۴۵ و ۶۰)، بخش‌های گونه‌های گیاهی مهاجم براساس همپوشانی آنها (آستانه ۷۵٪) با مجموعه داده‌های چندضلعی مرجع انتخاب می‌شوند (شکل ۴). جهت اطمینان از توازن و تعادل دسته، از تعداد نمونه‌های اجسام کناررودخانه‌ای دیگر (اجسامی مثل گونه‌های گیاهی غیرمهاجم) به طور تصادفی کاسته می‌شود تا با تعداد گونه‌های گیاهی مهاجم مطابقت کنند.

با استفاده از فرآیند اعتبارسنجی متقابل یک ارزیابی دقت انجام شد. مدل‌های جنگل تصادفی ساخته شده با مجموعه آموزشی (۲۰٪) در مجموعه ارزیابی بکار گرفته شدند (۸۰٪) تا دقت را برآورد کنند. فرآیند کلی (که به طور جزئی به فرآیندهای تصادفی بستگی دارد) ۵۰ مرتبه تکرار شد تا مقادیر میانگین $\pm$ انحراف معیار دقت محاسبه شود. دقت‌ها با استفاده از دقت کلی و شاخص کاپا ارزیابی شدند.

۳. نتایج

۳-۱. ارزیابی دقت و مقیاس تجزیه و تحلیل

به استثنای *H. mantegazzianum*، بهترین نتایج از لحاظ دقت کلی (جدول ۴) با ریزترین مقیاس تجزیه و تحلیل حاصل شدند (پارامتر مقیاس بخش‌بندی = ۱۰).

جالب توجه است که پروژه طبقه‌بندی براساس تصویربرداری انجام شده با نقشه‌برداری هوایی در انتهای دوره گل‌دهی برای *I. glandulifera* بهترین نتایج را حاصل کرد. بازرسی چشمی میدانی همراه با نقشه‌برداری هوایی امکان تشخیص و شناسایی این دوره را به عنوان تشخیص‌پذیرترین مرحله پدیده‌شناختی برای *I. glandulifera* (یعنی یک الگوی گل‌دهی مجزا در مقایسه با دیگر گونه‌های گیاهی کناررودخانه‌ای) فراهم می‌کند.

۳-۲. معیار انتخاب شده

برای هر گونه گیاهی مهاجم، ما متغیرهای انتخاب شده را برای بهترین مدل طبقه‌بندی معین کردیم (جدول ۵).

حتی با اینکه معیارهای طیفی (میانگین لایه و روشنایی دوربین) پرتکرارترین معیارها در جدول ۵ بودند، نتایج ما تاییدی بر ارزش افزون معیارهای بافت (مشتقات GLCM) برای نقشه‌برداری از گونه‌های مهاجم کناررودخانه‌ای هستند. برای *H. mantegazzianum* و *I. glandulifera*، مشتق GLCM در پیوند با همگونی و هماهنگی موضعی تصویر، پرکاربردترین مورد استفاده توسط الگوریتم RF بود. در مورد *H. mantegazzianum*، این استفاده نسبتاً شدید از مشتق همگنی GLCM می‌تواند با چترک‌های سفید تقریباً خالص نشان داده شود.



Classification project	Scale parameter of OBIA analysis							
	60		45		30		10	
	KI	OA	KI	OA	KI	OA	KI	OA
<i>I. glandulifera</i> (07-2012)	17 $\pm$ 13	58 $\pm$ 6.5	24 $\pm$ 8	62 $\pm$ 4	31 $\pm$ 5	66 $\pm$ 3	37 $\pm$ 2	68 $\pm$ 1 ^a
<i>I. glandulifera</i> (09-2012)	23 $\pm$ 12	62 $\pm$ 6	22 $\pm$ 11	61 $\pm$ 6	30 $\pm$ 6	65 $\pm$ 3	45 $\pm$ 2	72 $\pm$ 1 ^a
<i>H. mantegazzianum</i> (06-2012)	91 $\pm$ 6	96 $\pm$ 3	92 $\pm$ 5	96 $\pm$ 3	93 $\pm$ 5	97 $\pm$ 2 ^a	89 $\pm$ 2	95 $\pm$ 1
Japanese knotweed (10-2012)	17 $\pm$ 16	58 $\pm$ 8	32 $\pm$ 13.1	66 $\pm$ 7	29 $\pm$ 10	64 $\pm$ 5	38 $\pm$ 3	69 $\pm$ 2 ^a

^a Highest value for each classification project.

جدول ۴. ارزیابی دقت و مقیاس تحلیل OBIA. دقت‌های کلی (OA) میانگین $\pm$ انحراف معیار و شاخص‌های کاپای (KI)

میانگین $\pm$ انحراف معیار پس از ۵۰ مرتبه طبقه‌بندی نظارت شده و فرآیند اعتبارسنجی متقاطع محاسبه می‌شوند.

Species	Selected variable		
	1	2	3
<i>I. glandulifera</i> (07-2012)	GLCM contrast	GLCM homogeneity	GLCM homogeneity ^a
<i>I. glandulifera</i> (09-2012)	S.D. Ggreen ^a	S.D. NIR ^a	GLCM mean
<i>H. mantegazzianum</i> (06-2012)	GLCM homogeneity	S.D. red	S.D. green ^a
Japanese knotweed (10-2012)	Mean red	Mean blue	Brightness

^a Variable derived from imagery captured with the RGNIR camera.

جدول ۵. معیارهای انتخاب شده (از سه مقدار بالاتر از شاخص جینی) برای مدل طبقه‌بندی با بهترین عملکرد

۴. بحث

دوره زمانی و مرحله پدیده‌شناسی گونه‌های هدف هنگام کسب داده‌های سنجش از دور برای نقشه‌برداری گونه‌های گیاهی مهاجم حائز اهمیت خاصی هستند (هوآنگ و آسنر، ۲۰۰۹؛ مولروو و همکاران، ۲۰۱۳). تصویربرداری با سیستم پهپاد کاربر نهایی را قادر می‌سازد تا تصویربرداری مقرون به صرفه‌ای را در یک وضوح زمانی بسیار ریز در حین پنجره‌های زمانی ویژه موردنظر انجام دهند.

نتایج بدست آمده برای *I. glandulifera* و هفت‌بند ژاپنی به دقت‌های کافی برای کاربردهای عملیاتی نمی‌رسند. دقت کلی نسبتاً ضعیف برای این دو گونه مهاجم می‌تواند با شرایط

از لحاظ دقت، ما نتایج رضایت‌بخشی را برای هر سه گونه گیاهی مهاجم حاشیه رودخانه‌ای بدست آوردیم. برای *H. mantegazzianum*، ما نتایج بهتری را نسبت به آنهایی که از مطالعات سنجش از دور این گونه‌ها بدست آمدند، حاصل کردیم. مولروو و همکاران (۲۰۱۳) یک مقدار ۷۷٪ (کاپای شرطی) حاصل کردند درحالی‌که ما با استفاده از شاخص کاپای کلی، ۹۲٪ بدست آوردیم. یک نکته کلیدی این است که این نتیجه امیدوارکننده با استفاده از یک مجموعه آموزشی بسیار سبک (۲۰٪) و روش‌های تصویربرداری بسیار کم - هزینه بدست آمدند.

همانطور که نویسندگان متعدد مورد اشاره قرار گرفته است، علاوه بر وضوح فضایی (مکانی)،



درون جا و پنجره زمانی انتخاب شده به ترتیب برای *I. glandulifera* و هفت‌بند ژاپنی توصیف شود. *I. glandulifera* قطعات دارای پوشش گیاهی خاصی را شکل نمی‌دهد و پوشش گیاهی کمتری را ارائه می‌کند. این امر باعث وجود همزمان گونه‌های بومی می‌شود که عموماً در قطعات *I. glandulifera* مخلوط می‌شوند (هولم و برمنر، ۲۰۰۵). وجود این گونه‌های بومی در قطعات دارای *I. glandulifera* موجب اختلال در اثر طیفی اجسام هدف می‌شود. نقشه‌برداری‌های هوایی با پهپاد که مربوط به هفت‌بند ژاپنی هستند در طی فصل پائیز انجام شدند (جدول ۱).

با توجه به موقعیت خورشید در طی این دوره در بلژیک، تغییرات در درخشش و حضور سایه‌ها رخ دادند. این پدیده‌ها موجب گوناگونی طیفی بالاتر در مجموعه داده‌ها شده و یک تاثیر منفی روی دقت مدل‌های طبقه‌بندی ساخته شده می‌شوند. موضوع مربوط به همگنی طیفی بخش‌های نمونه آموزشی در روش طبقه‌بندی نظارت شده ذاتی است. با این وجود، برای *H. mantegazzianum* و هفت‌بند ژاپنی این نگرانی با یک نرخ پوشش گیاهی بالاتر کاهش پیدا می‌کند. استفاده از روش‌های طبقه‌بندی بدون نظارت (با بخش‌های OBIA ریز) می‌تواند یک راه‌حل جایگزین برای جلوگیری از چنین مشکلاتی باشد.

با توجه به مورد *H. mantegazzianum*، از آنجاییکه مجموعه داده مرجع چندضلعی‌های اصلی تقریباً ۵۰ چترک انفرادی نمایش می‌دهند، مجموعه یادگیری می‌تواند برای نمایش تقریباً ۱۰ گیاه انفرادی تخمین زده شود. متعاقباً، روش ما امکان ساخت مدل‌های طبقه‌بندی بسیار دقیق با ورودی‌های جزئی را فراهم می‌کند (ترسیم دستی تعدادی از چترک‌ها).

نتایج ما همراه با دقت طبقه‌بندی بسیار بالا (شاخص کاپای کلی $> 90\%$) این روش را به عنوان یک ابزار مقرون به صرفه برای بهبود مدیریت این گونه‌ها به یک مدعی جدی تبدیل می‌کند. نقشه‌برداری‌های هوایی با پهپاد می‌توانند برای نگاشت و نقشه‌برداری توزیع جمعیت *H. mantegazzianum* در حال گلدهی قبل و پس از عملیات‌های میدانی برنامه‌ریزی شوند که بازرسی‌های میدانی زمان‌بر را محدود می‌سازد.

Papers



پیپرز به معنی مقالات است و هدف آن ترجمه مقالات کاربردی با موضوعات جدید و مرجع از مجلات معتبر لاتین (ISI) است که به صورت مجله‌ای شکل در اختیار پژوهشگران و دانشجویان علاقمند بخصوص مقاطع ارشد و دکتری قرار می‌گیرد. هر شماره به یک موضوع کاربردی و یک شاخه از علوم زمین می‌پردازد و تلاش می‌شود که مقالات انتخاب شده موضوعاتی را در بر بگیرند که کاربردی باشند. بیشتر این مقالات حول موضوعات محیط زیست، آلودگی، منابع طبیعی، جنگلداری، آبخیزداری، زمین‌شناسی و معدن، عمران، نقشه‌برداری، علوم آب و هیدرولوژی، علوم شهری، سنجش از دور و جی آی اس، هواشناسی و اقلیم، کشاورزی و خاکشناسی می‌باشد.