

سیستم‌های طبقه‌بندی کننده‌ی چندگانه‌ی نوین درختی به منظور طبقه‌بندی زمین‌های کشاورزی از تصاویر نوری و راداری تمام‌قطبیده

ایمان خسروی^{۱*}، عبدالرضا صفری^۲، سعید همایونی^۳

^۱ دکتری مهندسی نقشه‌برداری سنجش‌ازدور - دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده -

های فنی - دانشگاه تهران

iman.khosravi@ut.ac.ir

^۲ استاد دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران

asafari@ut.ac.ir

^۳ استادیار گروه جغرافیا، محیط و ژئوماتیک - دانشگاه اتاوا - اتاوا - کانادا

saeid.homayouni@uOttawa.ca

(تاریخ دریافت دی ۱۳۹۶، تاریخ تصویب فروردین ۱۳۹۷)

چکیده

تصاویر نوری و راداری با درجه‌ی مصنوعی تمام‌قطبیده (PolSAR)، منابع ارزشمندی برای طبقه‌بندی زمین‌های کشاورزی است. ویژگی‌های مستخرج از تصاویر نوری حاوی اطلاعاتی در مورد امضای بازتابی محصولات مختلف است. در مقابل، یک تصویر PolSAR فراهم‌کننده‌ی اطلاعاتی در مورد خصوصیات ساختاری و سازوکارهای پراکنش محصولات است. ترکیب این دو منبع قادر به ایجاد یک مجموعه داده‌ی مکمل با تعداد قابل توجهی از ویژگی‌های زمانی طیفی، بافت و قطبیده برای طبقه‌بندی زمین‌های کشاورزی است. با این حال، طبقه‌بندی زمین‌های کشاورزی ممکن است با دو چالش افزایش تصاعدی ابعاد داده و مسأله‌ی داده‌های نامتوازن مواجه شود. در دهه‌ی گذشته، سیستم‌های طبقه‌بندی کننده‌ی چندگانه‌ی (MCS) درختی به‌ویژه روش مشهور جنگل تصادفی (RF) کارایی بالایی از خود برای حل چالش اول نشان داده است. با این حال، این روش‌ها به‌طور ذاتی برای حل مسأله‌ی داده‌های نامتوازن طراحی نشده است. به‌تازگی دو روش نوین جایگزین RF به نام‌های جنگل پالایشی متوازن شده (BFF) و جنگل پالایشی هزینه‌حساس (CFF) برای طبقه‌بندی تصاویر راداری پیشنهاد شده است که قابلیت بالایی در حل همزمان دو چالش از خود نشان داده است. این پژوهش نیز قصد دارد تا از این دو روش نوین برای طبقه‌بندی زمین‌های کشاورزی از ترکیب تصاویر نوری و راداری استفاده کرده و کارایی و عملکرد آن‌ها را با روش‌های MCS درختی کلاسیک از جمله روش RF در مواجهه با حل این دو چالش بررسی و مقایسه کند. نتایج نشان از افزایش دقت کلی تا حدود ۱۰٪ بیشتر روش‌های نوین درختی نسبت به روش‌های کلاسیک و سرعت ۶ برابر این روش‌ها نسبت به روش RF داشت. ضمن آن‌که در شناسایی محصولات کشاورزی، دقتی حدود ۲۰٪ بیشتر از روش RF کسب کرد.

واژگان کلیدی: سیستم طبقه‌بندی کننده‌ی چندگانه، درخت تصمیم، طبقه‌بندی زمین‌های کشاورزی، تصاویر نوری، تصاویر راداری

۱- مقدمه

تهیه نقشه‌ی محصولات کشاورزی، نقش مهمی در کاربردهای مختلف کشاورزی و منابع طبیعی همچون فهرست دارایی محصولات، بیمه محصولات، برآورد بار محصولات و اعمال محدودیت‌های سهمیه‌ای دارد [۱]. با توسعه‌ی سیستم‌های ماهواره‌ای، مطالعه، بررسی، تهیه‌ی نقشه و پایش محصولات کشاورزی با این فن‌آوری، بیش از پیش مورد توجه پژوهشگران قرار گرفت [۲].

تاکنون، داده‌های ماهواره‌های نوری به‌طور گسترده در پژوهش‌های طبقه‌بندی زمین‌های کشاورزی استفاده شده است [۳]. ابتدایی‌ترین ویژگی‌های نوری، اطلاعات حاصل از باندهای طیفی و شاخص‌های گیاهی است که امضای طیفی بازتابی محصولات را ارائه می‌دهد [۴]. همچنین، پارامترهای بافت به عنوان ویژگی‌های مفید در چندین پژوهش استفاده شده است [۵-۷]. این پارامترها، حاوی اطلاعاتی درباره‌ی آرایش مکانی سطوح خاکستری در یک تصویر است و برای پوشش‌های گیاهی متنوع، مقادیر متفاوتی دارد.

علی‌رغم قابلیت‌های فراوان تصاویر نوری در شناسایی و تفکیک محصولات، این تصاویر ممکن است با محدودیت‌هایی مواجه شود. یکی از عوامل محدودکننده در این تصاویر، تأثیرپذیری آن‌ها از شرایط مختلف آب و هوایی به ویژه وجود پوشش ابر در آسمان است. همچنین، عامل دیگری که در تصاویر نوری چالش‌انگیز است، شباهت‌های فراوان موجود در انعکاس طیفی یک منطقه‌ی کشاورزی است [۸].

در مقایسه با داده‌های ماهواره‌های نوری، داده‌های راداری با درجه‌ی مصنوعی^۱ (SAR) به‌طور نسبتاً کمتری برای تهیه نقشه‌ی محصولات استفاده شد. در یک دهه‌ی گذشته با توسعه‌ی ماهواره‌های SAR و ظهور ماهواره‌های SAR تمام‌قطبیده^۲ (PolSAR)، استفاده از آن‌ها نیز افزایش یافت [۳]. ابتدایی‌ترین ویژگی‌های راداری یک تصویر SAR، اطلاعات دامنه و فاز قطبش یا قطبش‌های آن است که به‌نوعی امضای ساختاری گیاه را نشان می‌دهد [۹]. با این حال، یک تصویر PolSAR می‌تواند ویژگی‌های

بیشتری شامل ماتریس‌های پراکنش، کواریانس و هم‌دوسی و همچنین پارامترهای تجزیه‌ی هدف در کاربردهای کشاورزی فراهم کند. پارامترهای تجزیه‌ی هدف، نقش ویژه‌ای در آشکارسازی سازوکارهای پراکنش و ساختار محصولات کشاورزی ایفا می‌کند [۱۰].

ریزموج پس‌پراکنش‌شده‌ی راداری برخلاف پرتو بازتابی نوری، دارای خاصیت نفوذپذیری در شرایط مختلف جوی است که یک امتیاز برای تصاویر SAR محسوب می‌شود [۱۱]. با این حال، وجود نوفه‌ی ذاتی اسپکل مهمترین نقص این تصاویر است که می‌تواند باعث افزایش عدم قطعیت و نتیجتاً کاهش دقت طبقه‌بندی شود [۱۲]. محدودیت دیگر، اثرات نامطلوب رادیومتریکی و یا هندسی همچون تشکیل سایه‌های راداری حاصل از پدیده‌های کوتاه‌شدگی و وارونگی است که به‌دلیل وجود توپوگرافی سطح زمین در این تصاویر ایجاد می‌شود [۳].

در دو دهه‌ی گذشته، پژوهش‌هایی از ترکیب تصاویر نوری و راداری برای بهبود دقت تهیه‌ی نقشه محصولات کشاورزی استفاده کرده است [۳]. ترکیب این داده‌ها علاوه بر اینکه می‌تواند باعث جبران محدودیت‌های هر یک شود، فراهم‌کننده‌ی یک مجموعه اطلاعات مکمل از حساسیت هر منبع داده به خصوصیات پوشش گیاهی است. انرژی نوری غیرفعال بازتاب‌شده توسط گیاهان وابسته به ساختار برگ، رنگینه و رطوبت آن‌هاست. در مقابل، انرژی میکروویو فعال پراکنش‌شده توسط گیاهان وابسته به اندازه، چگالی، جهت و خواص دی الکتریک عناصر قابل مقایسه با اندازه‌ی طول موج راداری است [۱۳].

از طرفی، عوارض طبیعی همچون محصولات کشاورزی برخلاف عوارض دست‌ساز بشری همچون ساختمان‌ها و جاده‌ها دارای رفتاری پویا است یعنی خصوصیات ظاهری و درونی و به‌نوعی پدیدارشناسی آن‌ها در حین دوره‌ی رشدشان به‌طور پیوسته تغییر می‌کند. در این راستا، پژوهش‌های فراوانی نشان داد که ترکیب زمانی مشاهدات نوری و SAR، قادر به تولید نتایج مطمئن‌تر و کارآمدتر برای طبقه‌بندی زمین‌های کشاورزی است [۱۴-۱۸]. بنابراین، این ادغام چندزمانی چندمنبعی قادر به فراهم کردن یک مجموعه داده‌ی نوری-راداری بزرگ با یک فضای جامع ویژگی‌های زمانی، طیفی، بافت و قطبیده برای طبقه‌بندی زمین‌های کشاورزی است.

^۱ Synthetic Aperture Radar

^۲ Full-Polarimetric Synthetic Aperture Radar

برای هر جفت نمونه‌ی آموزشی باعث افزایش زمان محاسبات آن می‌شود [۳۴].

روش‌های غیرپارامتریک دیگری همچون الگوریتم‌های مبتنی بر درخت از جمله درخت تصمیم و روش جنگل تصادفی^۳ (RF) برای پژوهش‌های طبقه‌بندی زمین‌های کشاورزی نیز استفاده شده است [۸، ۱۴-۱۷، ۲۳، ۲۶، ۲۹، ۳۰، ۳۵، ۳۶]. درخت تصمیم برخلاف شبکه‌ی عصبی دارای ساختاری ساده‌تر است اما همانند آن، به‌عنوان یک طبقه‌بندی‌کننده‌ی ضعیف و ناپایدار به‌ویژه در یک فضای ویژگی ابعاد بالا یا داده‌های بزرگ شناخته می‌شود [۳۲، ۳۷]. برعکس، الگوریتم RF که جز سیستم‌های طبقه‌بندی‌کننده‌ی چندگانه‌ی^۴ (MCS) درختی است، همانند ماشین بردار پشتیبان دارای کارایی و اعتمادپذیری بالایی در چنین شرایطی است. حتی، الگوریتم RF بیشتر ترجیح داده می‌شود. RF دارای سرعت عملکرد بالاتر، منعطف‌تر، ساختار ساده‌تر و نسبت به داده‌های نویزی، مقاوم‌تر است. همچنین RF برخلاف ماشین بردار پشتیبان، دغدغه‌ی کمتری برای انتخاب پارامترهایش دارد [۳۷].

در مورد چالش دوم یعنی مسأله‌ی داده‌های نامتوازن، هیچ‌یک از الگوریتم‌های بیان‌شده نمی‌تواند به خوبی عمل کند. این موضوع ناشی از این دلیل است که این الگوریتم‌ها، توزیع داده‌ها برای همه‌ی کلاس‌ها را برابر فرض می‌کند. همچنین، فرض می‌کند که خطاهای ناشی از کلاس‌های مختلف (اقلیت و اکثریت) دارای هزینه‌ی یکسانی است. به-علاوه، این الگوریتم‌ها معمولاً به‌گونه‌ای طراحی شده که به-جای توجه‌ی ویژه به کلاس‌های اقلیت، نرخ خطای کل را کاهش می‌دهد. حتی الگوریتم RF که برای حل چالش اول کارآمد است، به‌طور ذاتی برای حل چالش داده‌های نامتوازن طراحی نشده است. در همین راستا در پژوهش [۳۸]، دو روش MCS درختی نوین به‌نام‌های جنگل پالایشی متوازن-شده^۵ (BFF) و جنگل پالایشی هزینه‌حساس^۶ (CFF) به-عنوان جایگزین‌های سریع و کارا تر از RF جهت طبقه‌بندی تصاویر راداری پیشنهاد شد. این MCS‌های نوین علاوه بر حل چالش اول، راهکارهای حل چالش دوم را نیز دارد. ضمن این‌که از دو روش رأی‌گیری توسعه‌یافته به‌نام‌های

این مجموعه‌داده‌ی بزرگ می‌تواند باعث بهبود دقت طبقه‌بندی زمین‌های کشاورزی شود. با این حال، ممکن است چندین ویژگی این مجموعه به‌دلیل همبستگی زیاد بین ویژگی‌های نوری یا همبستگی زیاد بین ویژگی‌های راداری، ویژگی‌های افزون محسوب شود [۸]. این مسأله موجب ایجاد محدودیت‌هایی همچون افزایش پیچیدگی و بار محاسباتی در طبقه‌بندی خواهد شد. به‌ویژه زمانی که نسبت تعداد نمونه‌ها به تعداد ویژگی‌ها بیش از حد پایین باشد، چالش معروفی به‌نام افزایش تصاعدی ابعاد داده^۱ رخ خواهد داد. چالش دیگری که معمولاً بروز آن در طبقه‌بندی زمین‌های کشاورزی اجتناب‌ناپذیر است، عدم توازن شدید بین توزیع داده‌ها در بین مزارع کشاورزی متنوع است که به مسأله‌ی داده‌های نامتوازن شهرت^۲ دارد. درواقع، یک یا چند محصول کشاورزی (مشهور به کلاس-های اقلیت) دارای نمونه‌های خیلی کمتری نسبت به سایر محصولات (کلاس‌های اکثریت) است.

تاکنون الگوریتم‌های طبقه‌بندی‌کننده‌ی متنوعی برای تهیه‌ی نقشه‌ی محصولات از ترکیب تصاویر نوری و راداری استفاده شده است. برخی پژوهش‌ها از روش شبکه‌ی بیزین و روش بیشترین شباهت استفاده کرده‌اند [۱۹-۲۵]. این دو روش، روش‌های پارامتریک یعنی به شدت وابسته به توزیع داده‌هاست. بنابراین، ممکن است در طبقه‌بندی مجموعه‌داده‌ی بزرگ با نقصان مواجه شود.

پژوهش‌های دیگری از روش‌های غیرپارامتریکی همچون شبکه عصبی و ماشین بردار پشتیبان و یا هر دو بهره بردند [۱۴، ۱۸، ۲۱، ۲۶-۳۰]. شبکه عصبی دارای یک ساختار مبهم و جعبه‌سیاه مانند است و معمولاً به عنوان یک طبقه‌بندی‌کننده‌ی نسبتاً ناپایدار شناخته می‌شود [۳۱، ۳۲]. در مقابل، روش ماشین بردار پشتیبان که مبتنی بر کرنل است، به عنوان یک روش تعمیم‌پذیر و پایدار جهت طبقه‌بندی داده‌ها در فضای ویژگی ابعاد بالا و حل چالش اول شناخته می‌شود. با این حال، این روش نیز ممکن است با چالش‌های بزرگی همچون انتخاب کرنل و پارامترهای بهینه‌ی آن و اثر داده‌های نویزی روی کارایی-اش مواجه شود [۳۳]. همچنین، افزایش تعداد کرنل‌ها

^۳ Random Forest

^۴ Multiple Classifier Systems

^۵ Balanced Filter Forest

^۶ Cost-Sensitive Filter Forest

^۱ Curse of Dimensionality

^۲ Imbalanced Data Problem

رأی‌گیری حداکثریت هدفمند^۱ (OMV) و رأی‌گیری حداکثریت وزن‌دار^۲ (WMV) در ساختار خود بهره می‌برد. این پژوهش نیز به دنبال آن است تا از روش‌های نوین BFF و CFF جهت طبقه‌بندی زمین‌های کشاورزی از تصاویر نوری و راداری استفاده نماید. به‌طور خلاصه، اهداف این پژوهش عبارت است از: (۱) مقایسه‌ی عملکرد، کارایی و سرعت روش‌های MCS درختی کلاسیک در مقابل روش‌های MCS درختی پیشنهادی در طبقه‌بندی زمین‌های کشاورزی؛ (۲) بررسی و مقایسه‌ی تأثیر توازن و عدم‌توازن نمونه‌ی آموزشی روی دقت طبقه‌بندی زمین‌های کشاورزی حاصل از روش‌های MCS درختی کلاسیک و پیشنهادی؛ (۳) بررسی تأثیر اندازه‌ی نمونه‌ی آموزشی روی دقت طبقه‌بندی زمین‌های کشاورزی حاصل از روش‌های MCS درختی کلاسیک و پیشنهادی؛ و (۴) بررسی کارایی و عملکرد روش‌های رأی‌گیری پیشنهادی OMV و WMV نسبت به روش رأی‌گیری کلاسیک MV.

۲- روش‌شناسی

در این پژوهش، روش‌های MCS برای طبقه‌بندی استفاده شد. در ادامه، ابتدا روش‌های MCS درختی کلاسیک و پس از آن، روش‌های MCS درختی پیشنهادی به‌طور مفصل شرح داده می‌شود.

۲-۱- روش‌های MCS درختی کلاسیک

روش‌های MCS درختی کلاسیک به‌کار رفته در این پژوهش عبارت‌است از الگوریتم‌های بگینگ درختی، جنگل تصادفی و جنگل دورانی.

۲-۱-۱- الگوریتم بگینگ درختی

رویه‌ی الگوریتم بگینگ درختی^۳ (TBa) بدین‌صورت است: ابتدا با استفاده از روش نمونه‌برداری تصادفی خودراه‌انداز، چندین زیر مجموعه‌ی مختلف به‌طور یکنواخت و با جایگذاری از کل داده‌های آموزشی انتخاب می‌شود. سپس، یک مدل خاص از الگوریتم درخت تصمیم توسط هر یک از این زیرمجموعه‌ها آموزش داده می‌شود. سرانجام، خروجی حاصل از این الگوریتم‌های منفرد به-

کمک قانون رأی‌گیری MV با یکدیگر ترکیب می‌شود. روش MV، کلاسی را انتخاب می‌کند که بیشترین تعداد آرای به‌دست آمده از همه‌ی طبقه‌بندی‌کننده‌ها را کسب کند [۳۱]. مهم‌ترین پارامتر تنظیم الگوریتم TBa، تعداد الگوریتم درخت تصمیم (nTrees) است.

۲-۱-۲- الگوریتم جنگل تصادفی

جنگل تصادفی (RF) دارای مراحل زیر است: همانند TBa، ابتدا چندین زیرمجموعه‌ی آموزشی از کل مجموعه-ی آموزشی با استفاده از نمونه‌برداری خودراه‌انداز انتخاب می‌شود. پس از آن، در هر زیرمجموعه‌ی آموزشی، زیرمجموعه‌ای از کل ویژگی‌ها ($mTry$) با استفاده از روش به‌نام انتخاب ویژگی زیرمجموعه‌ی تصادفی^۴ (RSFS) انتخاب می‌شود. سپس، یک الگوریتم درخت تصمیم توسط هر زیرمجموعه آموزش داده می‌شود. درنهایت، با استفاده از روش MV، خروجی حاصل از الگوریتم‌های منفرد با یکدیگر ترکیب می‌شود [۳۷]. مهم‌ترین پارامترهای الگوریتم RF، nTrees و $mTry$ است.

۲-۱-۳- الگوریتم جنگل دورانی

جنگل دورانی^۵ (RoF) دارای این مراحل است: ابتدا مجموعه‌ویژگی‌ها به چندین زیرمجموعه ویژگی (K) تقسیم می‌شود. سپس برای هر زیرمجموعه ویژگی، یک زیرمجموعه با روش نمونه‌برداری خودراه‌انداز^۶ انتخاب می‌شود. در ادامه، روش تجزیه و تحلیل مولفه‌های اصلی^۷ (PCA) روی این زیرمجموعه به‌کار رفته و سپس با استفاده از مولفه‌های PCA، یک ماتریس دوران ساخته و مطابق با موقعیت ویژگی‌ها در داده‌ی آموزشی اصلی مرتب می‌شود. پس از این کار، نمونه‌های آموزشی با ضرب در ماتریس دوران به‌روز می‌شود. سپس یک مدل از الگوریتم درخت تصمیم با این نمونه‌ی آموزشی به‌روز شده، آموزش داده می‌شود. مراحل قبلی برای چندین الگوریتم درخت تصمیم تکرار تا در هر مرحله، یک تنوعی از آن ساخته شود. درنهایت با روش MV نتایج آن‌ها با یکدیگر ترکیب می‌شود [۳۹]. الگوریتم RoF نیز دارای دو پارامتر تنظیم اصلی شامل K و nTrees است.

۴ Random Subset Feature Selection

۵ Rotation Forest

۶ Bootstrap Sampling

۷ Principal Component Analysis

۱ Objective Majority Voting

۲ Weighted Majority Voting


۳ Tree Bagging

۲-۲- روش‌های MCS درختی پیشنهادی

دو روش MCS درختی نوین BFF و CFF در سه بخش اصلی پیرایش‌هایی نسبت به RF دارد که در شکل ۱ مشاهده می‌شود: گام انتخاب ویژگی‌های بهینه، گام ادغام برچسب و تمرکز بر مسأله‌ی داده‌ی نامتوازن [۳۸].

روش‌های پیشنهادی به جای یک الگوریتم انتخاب ویژگی بسته‌بندی، از یک الگوریتم پالایشی به نام الگوریتم پالایشی مبتنی بر همبستگی سریع^۱ (FCBF) بهره می‌برد که دارای کارایی قابل مقایسه با RSFS در فضای ویژگی ابعاد بالا و در عین حال، سریعتر از آن است [۴۰].

همچنین مهمترین تفاوت روش‌های پیشنهادی نسبت به RF، تعبیه راهکارهای حل مسأله‌ی داده‌های نامتوازن است. در روش BFF، از یک تکنیک نمونه‌برداری و در روش CFF از یادگیری هزینه‌حساس برای حل این مسأله چاره شده است. علاوه بر این، در روش‌های BFF و CFF، به ترتیب دو الگوریتم رأی‌گیری توسعه‌یافته به نام‌های الگوریتم‌های OMV و WMV پیشنهاد می‌شود. روش OMV یک نسخه‌ی بهبودیافته از روش MV است که دو ابهام آن را با راهکارهایی موثر برطرف می‌کند. همچنین روش WMV نسخه‌ی وزن‌دار MV است که براساس وزن کلاس‌ها اقدام به تصمیم‌گیری می‌کند [۳۸]. رویه‌ی این دو الگوریتم رأی‌گیری در شکل ۲ نشان داده شده است.



شکل ۱- تفاوت بین ساختار RF با ساختار روش‌های MCS درختی پیشنهادی شامل (الف) BFF و (ب) CFF [۳۸]

۲-۲-۱- روش BFF

مطابق با شکل ۱الف، روش BFF دارای مراحل زیر است: در ابتدا، نمونه‌ی آموزشی با استفاده از یک روش نمونه‌برداری خودراه‌انداز متوازن‌شده به چندین زیرمجموعه تقسیم می‌شود. برای هر زیرمجموعه، ابتدا یک نمونه‌ی خودراه‌انداز از کلاس اقلیت انتخاب و سپس تعداد یکسان از داده‌های انتخابی این کلاس، به طور تصادفی و با جایگذاری از سایر کلاس‌ها انتخاب می‌شود.

پس از تولید زیرمجموعه‌های آموزشی، الگوریتم FCBF برای انتخاب ویژگی‌های بهینه‌ی هر زیرمجموعه به کار می‌رود. در ادامه، یک درخت توسط هر زیرمجموعه آموزش داده می‌شود. برخلاف روش RF، در روش BFF درختان بعد از رشد یافتن، هرس می‌شود. خروجی‌های حاصل از درختان منفرد، سرانجام با روش OMV با یکدیگر ادغام می‌شود [۳۸].

۲-۲-۲- روش CFF

مراحل روش CFF مطابق با شکل ۱ب به صورت زیر است: مشابه با روش RF در این روش نیز ابتدا از یک نمونه‌برداری خودراه‌انداز معمولی برای تولید زیرمجموعه‌های آموزشی استفاده می‌شود. پس از آن مشابه با روش BFF، الگوریتم FCBF جهت انتخاب ویژگی‌های هر زیرمجموعه به کار می‌رود. سپس، یک درخت تصمیم با عمل هرس شدن توسط هر زیرمجموعه، آموزش داده می‌شود. این آموزش براساس یادگیری هزینه‌حساس با در نظر گرفتن یک جریمه‌ی سنگین‌تر برای اشتباه طبقه‌بندی شدن کلاس اقلیت انجام می‌شود. بعد از آموزش همه‌ی درختان، نتایج آن‌ها با استفاده از الگوریتم WMV ادغام می‌شود. در اینجا، وزن الگوریتم مربوط به وزن کلاس‌هاست که از جمع نرمال‌شده‌ی همه‌ی سطرهای آن کلاس در ماتریس هزینه به دست می‌آید [۳۸].

۳- معرفی داده‌ها و منطقه‌ی مطالعاتی


۳-۱- مشخصات منطقه‌ی مطالعاتی

منطقه‌ی مورد مطالعه در این پژوهش، یک بخش از شهر وینیپگ از ایالت مانیتوبای کانادا است. این منطقه تماماً پوشیده از مزارع کشاورزی با محصولات تابستانه و در قسمت جنوب شرقی وینیپگ و در حد فاصل طول‌های

^۱ Fast Correlation-Based Filter

جغرافیایی ۹۷ درجه، ۵ دقیقه و ۲ ثانیه‌ی غربی تا ۹۷ درجه، ۴۵ دقیقه و ۱۳ ثانیه‌ی غربی و عرض‌های جغرافیایی ۴۷ درجه، ۳۲ دقیقه و ۱۶ ثانیه‌ی شمالی تا ۴۸ درجه، ۱۲ دقیقه و ۵۶ ثانیه‌ی شمالی واقع شده است. مساحت این منطقه حدود ۴۰۰ هکتار و ارتفاع متوسط آن از سطح دریا ۷۴۸ فوت معادل ۲۳۹ متر است. داده‌ی مرجع منطقه طی یک آزمایش اعتبارسنجی فعال-غیرفعال نقشه‌برداری رطوبت خاک در سال ۲۰۱۲


جهت کالیبراسیون و اعتبارسنجی ماهواره SMAP ناسا تهیه شد. جمع آوری داده‌های این آزمایش حدود ۴۳ روز در تابستان سال ۲۰۱۲ میلادی طول کشید. در واقع، جمع آوری این مشاهدات در مراحل اولیه‌ی توسعه‌ی محصولات کشاورزی شروع و در طول دوره‌ی بیشینه‌ی تجمع جرم‌توده پایان یافت [۴۱].



شکل ۲- رویه‌ی روش‌های ادغام برچسب در روش‌های پیشنهادی: (الف) الگوریتم OMV در BFF، (ب) الگوریتم WMV در CFF [۳۸]

مطابق با داده‌ی مرجع برای منطقه‌ی مطالعاتی این پژوهش (شکل ۳الف)، تنها ۶ محصول کشاورزی عمده در این منطقه وجود دارد: سویا (۷۴۰۶۷ پیکسل)، کانولا (۷۵۶۷۳)، گندم معمولی (۸۵۰۷۴)، نخود فرنگی (۳۵۹۸)، ذرت (۳۹۱۶۲) و جوی دوسر (۴۷۱۱۷). علاوه بر این شش محصول، درختان پهن‌برگ (۱۱۴۳) در لابلای برخی از این محصولات این منطقه دیده می‌شود. سویا، کانولا و گندم،

بیشترین تعداد نمونه‌ها (کلاس‌های اکثریت) و درختان پهن‌برگ و نخود، کمترین نمونه‌ها را داراست (کلاس‌های اقلیت). ۵٪ این داده‌ها به‌صورت تصادفی (در دو شیوه‌ی متوازن و نامتوازن) به‌عنوان نمونه‌ی آموزشی انتخاب می‌شود. همچنین ۱۰٪ داده‌ها به‌عنوان نمونه‌ی اعتبارسنجی جهت بهینه‌سازی روش‌ها و مابقی داده‌ها به عنوان نمونه‌ی آزمایشی جهت ارزیابی دقت و صحت روش‌ها انتخاب می‌شود.



شکل ۳- (الف) داده‌ی مرجع، (ب) و (پ) تصاویر نوری تاریخ‌های ۵ و ۱۴ جولای ۲۰۱۲، و (ت) و (ث) تصاویر راداری تاریخ‌های ۵ و ۱۴ جولای ۲۰۱۲ منطقه‌ی مطالعاتی این پژوهش

۳-۲- مشخصات داده‌های ماهواره‌ای

داده‌های این پژوهش، تصاویر دو زمانی نوری و راداری اخذ شده توسط سنجنده‌ی ماهواره‌ی RapidEye و سنجنده‌ی هوایی UAVSAR است.

سنجنده‌ی ماهواره‌ی RapidEye دارای ۵ باند طیفی در طول موج‌های مرئی شامل آبی (B)، سبز (G) و قرمز (R) و طول موج مادون قرمز نزدیک (NIR) و باند لبه-قرمز (RE) است. تمایز ویژه‌ی این سنجنده، دارا بودن همین باند RE است که مخصوص تجزیه و تحلیل رفتار گیاهان است [۴۲]. تصاویر نوری، اخذ شده در تاریخ‌های ۵ و ۱۴ جولای ۲۰۱۲ میلادی است. این تصاویر در دیتوم محلی آمریکای شمالی ۱۹۸۳ میلادی (NAD-83) زمین-مرجع شده و دارای تفکیک‌پذیری مکانی ۵ متر است. شکل‌های ۳ و ۳، ترکیب رنگی حقیقی این تصاویر را نشان می‌دهد. از هر دو تصویر نوری، ۳۸ ویژگی نوری متنوع شامل باندهای طیفی، شاخص‌های گیاهی و ویژگی‌های بافت استخراج شد که در جدول ۱ ارائه شده است.

جدول ۱- ویژگی‌های نوری استفاده‌شده در این پژوهش [۹]

B : 440 – 510nm, G : 520 – 590nm, R : 630 – 685nm, RE : 690 – 730nm, NIR : 760 – 850nm
$NDVI = (NIR - R) / (NIR + R)$, $SR = NIR / R$, $RGRI = G / R$, $NDGI = (G - R) / (G + R)$, $EVI = 2.5(NIR - R) / (NIR + 6R - 7.5B + 1)$, $ARVI = (NIR - (2R - B)) / (NIR + (2R - B))$, $gNDVI = (NIR - G) / (NIR + G)$, $SAVI = (1 + 0.5)(NIR - R) / (NIR + R + 0.5)$, $MTVI2 = 1.5(1.2(NIR - G) - 2.5(R - G)) / \sqrt{(2NIR + 1)^2 - (6NIR - 5\sqrt{R}) - 0.5}$
$NDVI_{re} = (NIR - RE) / (NIR + RE)$, $PRI2 = RE / R$, $NDGI_{re} = (G - RE) / (G + RE)$, $RTVI = 100(NIR - RE) - 10(NIR - G)$, $RNDVI = (RE - R) / (RE + R)$, $SRe = NIR / RE$, $TCARI = 3((RE - R) - 0.2(RE - G)(RE / R))$, $TVI = 0.5(120(RE - G) - 200(R - G))$
μ , σ , CON, HOM, DIS, H, ASM, COR

سنجنده‌ی UAVSAR، یک سنجنده‌ی هوایی PolSAR است که در فرکانس L تصویربرداری می‌کند. تصاویر راداری به‌کار گرفته شده دقیقاً در همان تاریخ‌های تصاویر نوری جمع‌آوری شده است. شکل‌های ۳ و ۳، ترکیب رنگی پائولی این تصاویر را نشان می‌دهد. این تصاویر راداری توسط یک مدل ارتفاعی رقومی SRTM3 (با تفکیک‌پذیری مکانی حدود ۹۰ متر) در دیتوم سیستم ژئودتیک جهانی ۱۹۸۴ (WGS-84) زمین‌مرجع شده

است. جهت کاهش اثر نوفه‌ی اسپکل^۱ این تصاویر، ابتدا تصاویر راداری به صورت ۲ پیکسل در جهت آزیموت و ۳ پیکسل در جهت رنج چند دید شد و سپس، پالایشگر باکس‌کار^۲ با ابعاد پنجره‌ی ۵ × ۵ پیکسل برای هر دو تصویر راداری استفاده شد. پس از پیش‌پردازش این تصاویر، تفکیک‌پذیری مکانی آن‌ها به ۱۵ متر کاهش یافت. از هر دو تصویر راداری، ۴۹ ویژگی راداری همچون شدت‌های پس‌پراکنش، نسبت‌های قطبش، ضرایب همبستگی قطبش‌ها، و ضرایب تجزیه‌ی همدوس و غیرهمدوس هدف استخراج شد (جدول ۲).

جدول ۲- ویژگی‌های راداری استفاده‌شده در این پژوهش [۹]

σ_{hh} , σ_{hv} , σ_{vh} , σ_{rr} , σ_{rl} , σ_{ll}
R_{hhvv} , R_{hvhv} , R_{hvvh} , R_{rrll} , R_{rlrr} , R_{rlll}
R_{hh} , R_{hv} , R_{vh} , R_{rr} , R_{rl} , R_{ll}
ρ_{hhvv} , ρ_{hvhv} , ρ_{hvvh} , ρ_{rrll} , ρ_{rlrr} , ρ_{rlll}
$ \alpha ^2$, $ \beta ^2$, $ \gamma ^2$, $ k_s ^2$, $ k_d ^2$, $ k_h ^2$
P_s , P_d , P_v , P_s^y , P_d^y , P_v^y , P_c^y
λ_1 , λ_2 , λ_3 , H, A, $\bar{\alpha}$, ψ , RVI
HA, $H(1-A)$, $(1-H)A$, $(1-H)(1-A)$,

پس از آماده‌سازی و استخراج ویژگی از هر دو منبع نوری و راداری، ویژگی‌های هر دو با یکدیگر ادغام می‌شود، یعنی کل ویژگی‌های چندزمانه‌ی نوری با کل ویژگی‌های چندزمانه‌ی راداری در کنار هم قرار می‌گیرد. اما قبل از ادغام، بایستی این دو منبع با یکدیگر هم‌سیستم‌مختصات شود. برای این‌کار از ۱۱ نقطه‌ی گرهی بین دو منبع استفاده شد. چون هر یک در دیتوم‌های مختلفی زمین-مرجع شده و همچنین دارای پیکسل‌های غیرهم‌اندازه است، بنابراین علاوه بر وجود انتقال، امکان وجود مقیاس و حتی کمی هم دوران بین این دو تصویر وجود دارد. برای این‌کار مدل‌های چندجمله‌ای با درجه‌ی ۱ و ۲ آزمایش و بهترین نتیجه براساس خطای جذر میانگین مربعات^۳ (RMSE) انتخاب شد. آزمایشات نشان داد که چندجمله‌ای درجه‌ی ۲ ($RMSE = 0.36$) نسبت به درجه‌ی ۱ ($1/55$) مدل مناسب‌تری برای برقراری رابطه‌ی بین سیستم‌مختصات دو داده است. از روش نزدیکترین همسایه نیز، برای درون‌یابی درجه‌خاکستری استفاده شد.

^۱ Speckle Noise

^۲ Box Car

^۳ Root Mean Square Error

۴- پیاده‌سازی و ارزیابی نتایج

پیش از انجام طبقه‌بندی، مقادیر بهینه‌ی پارامترهای تنظیمی روش‌های MCS درختی تعیین شد. برای مقایسه‌ی روش‌ها، پارامتر مشترک n Tree دارای مقادیر کم به زیاد یعنی ۵، ۲۵، ۵۰، ۱۰۰، ۲۵۰، ۵۰۰ و ۱۰۰۰ در نظر گرفته شد. همچنین ویژگی‌های استفاده‌شده برای پیاده‌سازی روش‌ها عبارت است از: ویژگی‌های نوری تاریخ اول (O_1) و تاریخ دوم (O_2)، ترکیب ویژگی‌های نوری تاریخ اول و تاریخ دوم (O)، ویژگی‌های راداری تاریخ اول (R_1) و تاریخ دوم (R_2)، ترکیب ویژگی‌های راداری تاریخ اول و تاریخ دوم (R)، ترکیب ویژگی‌های نوری و راداری تاریخ اول (O_1R_1) و تاریخ دوم (O_2R_2) و سرانجام، ترکیب ویژگی‌های نوری و راداری تاریخ اول و تاریخ دوم (OR). لازم به ذکر است که پیش از انجام طبقه‌بندی مشاهده شد که روش‌های این پژوهش نسبت به یکسان‌سازی ارزش ویژگی‌ها حساسیت ندارد و بنابراین، ویژگی‌ها به همان صورت خام در پیاده‌سازی‌ها استفاده شد.

برای مقایسه‌ی و ارزیابی دقت روش‌ها نیز از کمیت‌های معروف دقت کلی (OA) و امتیاز F - $(F\text{-score})$ و برای مقایسه‌ی سرعت آن‌ها از زمان اجرای روش‌ها (شامل مراحل آموزش و آزمایش) استفاده شد. علاوه بر مقایسه‌ی دقت و زمان روش‌ها، تأثیر اندازه‌ی نمونه‌ی آموزشی (اندازه‌های ۵٪، ۹۰٪ و تأثیر توزیع (توازن یا عدم توازن) نمونه‌ی آموزشی روی دقت کلی روش‌های MCS درختی کلاسیک و پیشنهادی در طبقه‌بندی ترکیب تصاویر نوری و راداری (OR) نیز بررسی شد. در انتها نیز دقت و کارایی روش‌های رأی‌گیری کلاسیک و پیشنهادی مورد مقایسه قرار گرفت.

۴-۱- مقایسه‌ی دقت روش‌های MCS درختی

نتایج مقایسه‌ی دقت روش‌های MCS درختی کلاسیک و پیشنهادی با دو نمونه‌ی آموزشی متوازن و نمونه‌ی آموزشی نامتوازن ارائه می‌شود.

۴-۱-۱- مقایسه‌ی دقت با نمونه‌ی آموزشی متوازن

• مقایسه با ویژگی‌های نوری

مطابق با نمودارهای شکل ۴الف، ب و پ، میانگین OA (روی تعداد درختان) روش‌های MCS درختی

پیشنهادی با نمونه‌ی آموزشی متوازن در هر سه دسته ویژگی O_1 ، O_2 و O بین حدود ۱٪ تا ۲۵٪ از میانگین OA روش‌های MCS درختی کلاسیک (حتی روش RF) بیشتر شد که در این میان، سهم موفقیت روش BFF بیشتر از روش CFF بود. البته تنها در ویژگی O_1 ، مقدار روش CFF حدود ۷٪ کمتر از مقدار روش RF شد. علاوه بر این، بیشینه‌ی مقادیر OA در هر سه دسته ویژگی نوری، متعلق به روش‌های پیشنهادی بود. همچنین جدول ۳ نشان داد که روش BFF در ویژگی‌های نوری، نتایج باثبات‌تری (انحراف معیار کمتری) نسبت به روش‌های RF و RoF داشت. با این حال، روش CFF تنها در ویژگی O_1 دارای نتایج باثبات‌تری نسبت به این دو روش بود و در ویژگی‌های O_2 و O نتایج خیلی بی‌ثبات‌تری داشت. این نتیجه‌گیری با مشاهده‌ی نمودار غیرخطی روش CFF در شکل‌های ۴ب و پ نیز کاملاً مشهود بود.

موضوع مهم دیگر نتایج حاصل از ویژگی‌های نوری این-که، روش‌های پیشنهادی به‌ویژه روش BFF در تعداد درختان کمتر نیز به دقت بالایی رسید. بنابراین، می‌توان اظهار داشت که روش‌های MCS درختی پیشنهادی در طبقه‌بندی فضای ویژگی‌های نوری، سیستم‌های جمعی^۱ کوچکی به حساب می‌آید. علاوه بر این، شکل‌های ۵الف، ب و پ (بالا) نشان داد که روش‌های پیشنهادی در تعداد درختان بالا (۵۰۰ و ۱۰۰۰) دارای سطح هرس غیرصفر است. این بدان معناست که این روش‌ها زمانی که تعداد درختانشان افزایش می‌یابد تا حد زیادی تمایل به کم بارتر شدن (یا کوچکتر شدن) دارد. در مقابل، روش‌های کلاسیک حتی روش RoF دقت‌های بالایشان را در تعداد درختان بالا کسب کرد. این بدان معناست که این روش‌ها از جمله روش RoF در طبقه‌بندی فضای ویژگی‌های نوری، جزو سیستم‌های جمعی بزرگ و حجیم محسوب می‌شود. این نتیجه، ادعای پژوهش‌های قبلی مبنی بر این که روش RoF یک سیستم جمعی کوچک است را رد می‌کند.


• مقایسه با ویژگی‌های راداری

نتایج حاصل از ویژگی‌های راداری متنوع‌تر و در عین حال متفاوت از نتایج ویژگی‌های نوری شد. با ویژگی‌های R_1 ، میانگین OA روش‌های پیشنهادی از مقدار نظیر روش TBa تا حدود ۲٪ بیشتر، اما حدود ۱٪ تا ۶٪ کمتر از مقادیر نظیر


^۱ Ensemble System

لیکن باز روش‌های پیشنهادی، کارایی نسبتاً بالاتری از روش‌های کلاسیک در فضای ویژگی‌های راداری داشت. بار دیگر نمودارهای شکل ۴، ت و ج نشان داد که روش‌های کلاسیک با افزایش تعداد درخت، دقتشان نیز افزایش یافته و بنابراین مجدداً ادعای کوچک بودن سیستم روش RoF رد و ادعای بزرگ‌بودن سیستم روش‌های TBa و RF تأیید شد. در مورد روش‌های پیشنهادی، اگرچه BFF تقریباً در تعداد درختان پایین، دقت بالایی کسب کرد اما CFF با افزایش تعداد درخت، با افزایش دقت روبرو شد. با این حال، شکل‌های الف، ب و پ (وسط) نشان داد که با افزایش تعداد درخت (از ۲۵۰ به بالا) در این دو روش به‌ویژه در روش CFF، سطح هرس بهینه نیز افزایش یافت (این افزایش نسبت به ویژگی‌های نوری زودتر اتفاق افتاد). این موضوع بیان‌گر آن است که اگرچه روش CFF در فضای ویژگی‌های راداری در Tree‌های بالا، دقت بالایی کسب کرده لیکن باز تمایل شدیدی به کم‌بار کردن درختان خود دارد. پس باز می‌توانیم ادعا کنیم که دو روش پیشنهادی، سیستم‌های جمعی کوچک می‌باشد.

روش‌های RF و RoF با این حال، بیشینه‌ی OA در این تاریخ متعلق به روش BFF است. با ویژگی‌های R_2 ، میانگین روش‌های پیشنهادی حدود ۱٪ تا ۴٪ بیشتر از مقادیر نظیر روش‌های TBa و RF، اما حدود ۱٪ تا ۳٪ کمتر از مقدار نظیر روش RoF شد. سرانجام با ویژگی‌های R_1 ، میانگین روش BFF از همه‌ی روش‌های کلاسیک تا حدود ۱۰٪ بیشتر شده اما روش CFF علی‌رغم افزایش ۸٪ دقت نسبت به روش‌های TBa و RoF باز ۲٪ کمتر از روش RF کسب کرد. با این حال، بیشینه‌ی OA در ویژگی‌های R مشترکاً متعلق به روش‌های CFF و RF است (۸۰٪). در ویژگی‌های R_1 و R_2 ، ثبات روش‌های پیشنهادی اگرچه بیشتر از روش‌های TBa و RoF بود، با این حال نسبت به رقیب اصلی‌شان یعنی RF نسبتاً کمتر بود. البته در ویژگی‌های R، نتایج روش BFF نسبت به روش‌های TBa و RF ثبات بیشتری داشت. به‌طور کلی می‌توان بیان کرد، اگرچه موفقیت روش‌های MCS درختی پیشنهادی نسبت به روش‌های MCS درختی کلاسیک با ویژگی‌های راداری در مقایسه با ویژگی‌های نوری مطلق نبود،



شکل ۴- نمودار دقت کلی روش‌های MCS درختی کلاسیک و پیشنهادی در تعداد درخت ۵ تا ۱۰۰۰ با نمونه آموزشی ۰٫۵٪ متوازن و با استفاده از ویژگی‌های: (الف) O_1 ، (ب) O_2 ، (پ) O ، (ت) R_1 ، (ث) R_2 ، (ج) R ، (چ) O_1R_1 ، (ح) O_2R_2 ، و (خ) OR



شکل ۵- سطح هرس بهینه‌ی روش‌های MCS درختی پیشنهادی (BFF و CFF) با نمونه‌ی آموزشی ۰.۵٪ متوازن با استفاده از ویژگی‌های نوری (بالا)، راداری (وسط) و ترکیب ویژگی‌های نوری و راداری (پایین) در: (الف) تاریخ اول، (ب) تاریخ دوم، و (پ) ترکیب تاریخ اول و دوم

• مقایسه با ترکیب ویژگی‌های نوری و راداری

با ویژگی‌های O_1R_1 ، میانگین OA روش پیشنهادی CFF بین ۲٪ تا ۶٪ از مقادیر نظیر همه‌ی روش‌های کلاسیک بیشتر شد. اما میانگین OA روش پیشنهادی BFF حدود ۱٪ بیشتر از روش‌های TBa و RoF و حدود ۳٪ کمتر از روش RF شد. با این حال، جدول ۳ نشان داد که نتایج دو روش پیشنهادی با ویژگی‌های O_1R_1 ، ثابت بیشتری از نتایج روش‌های کلاسیک دارد. با ویژگی‌های O_2R_2 ، میانگین OA هر دو روش پیشنهادی BFF و CFF تا حدود ۵٪ بیشتر از مقادیر نظیر هر سه روش کلاسیک شد. همچنین نتایج آن‌ها نسبت به روش‌های رقیبشان به-ویژه روش‌های TBa و RF، دارای ثبات بیشتری بود.

زمانی که ویژگی‌های نوری و راداری هر دو تاریخ با یکدیگر ترکیب شد (OR)، روش CFF دارای میانگین OA بیشتری از همه‌ی روش‌های MCS درختی شد (از ۲٪ تا ۱۳٪ بیشتر). علاوه بر این، میانگین OA روش BFF حدود ۴٪ و ۱۰٪ بیشتر از مقادیر روش‌های TBa و RoF و با مقدار نظیر روش RF تقریباً برابر شد. بیشینه‌ی OA نیز توسط روش CFF (حدود


۸۴/۵٪) کسب شد. علاوه بر این، اگرچه ثبات نتایج دو روش پیشنهادی نسبت به روش‌های TBa و RoF کمتر شده اما نسبت به رقیب اصلی‌شان یعنی روش RF بیشتر شد. مجدداً دیده شد که در ترکیب ویژگی‌های نوری و راداری، روش‌های کلاسیک از جمله روش RoF در $nTree$ های بالا، دقت بیشتری کسب کرد. در مورد روش‌های پیشنهادی نیز، اگرچه دقت‌های بالا در $nTree$ های بالا تحقق یافت، با این حال، با توجه به هرس درختان این دو روش در $nTree$ های بالا (۱۰۰ تا ۱۰۰۰)، باز مشخص است که روش‌های پیشنهادی همچنان به کم‌بار و کوچک بودن سیستم خود تمایل زیادی دارد (شکل ۵الف، ب و پ پایین).

علی‌رغم محاسن نسبی که برای دو روش پیشنهادی نسبت به روش‌های کلاسیک به‌ویژه روش RF در طبقه‌بندی ویژگی‌های OR با نمونه‌ی آموزشی متوازن بیان شد، با این حال، شکل ۶ قابلیت بیشتری از روش‌های پیشنهادی ارائه داد. اولاً، میانگین دقت F -score روی کلاس‌ها در همه‌ی $nTree$ ها حاصل از روش‌های پیشنهادی تا حدود ۲۰٪ بیشتر از مقادیر نظیرشان حاصل از روش‌های کلاسیک شد.

علاوه بر دقت متوسط بالای روش‌های پیشنهادی، دقت F -score کلاس‌های اقلیت، شامل کلاس‌های نخودفرنگی (Pe) و درختان پهن‌برگ (Br)، حاصل از این روش‌ها خیلی چشم‌گیرتر از روش‌های کلاسیک شد. برای مثال، اگرچه OA روش TBa در $nTree = 5$ حدود ۰.۴٪ بیشتر از مقدار نظیر روش BFF شد و کمتر از ۰.۱٪ با دقت روش CFF اختلاف دارد، لیکن مقدار F -score کلاس‌های Pe و Br روش TBa خیلی کمتر از مقادیر نظیر آن برای روش‌های BFF و CFF شد (حدود ۰.۶٪ کمتر). اگرچه با افزایش تعداد درختان، مقدار F -score کلاس Pe توسط روش TBa افزایش یافت، اما در مقابل مقدار دقت کلاس Br آن کاهش و اختلاف دقت آن با روش‌های پیشنهادی از ۰.۶٪ هم بیشتر شد.

جدول ۳- انحراف معیار دقت کلی (٪) روش‌های MCS درختی کلاسیک و پیشنهادی در تعداد درخت ۵ تا ۱۰۰۰ با نمونه‌ی آموزشی ۰.۵٪ متوازن

ویژگی-ها	روش‌های MCS درختی کلاسیک					روش‌های MCS درختی پیشنهادی	
	TBa	RF	RoF	BFF	CFF		
O ₁	۰/۸۷	۳/۰۶	۳/۳۴	۱/۰۲	۱/۵۵		
O ₂	۰/۹۰	۵/۷۸	۳/۱۵	۱/۰۸	۹/۷۶		
O	۲/۰۶	۱/۱۷	۴/۶۱	۱/۵۲	۴/۶۱		
R ₁	۵/۳۴	۲/۲۳	۶/۲۴	۴/۷۲	۳/۶۰		
R ₂	۳/۹۶	۰/۸۵	۲/۸۷	۱/۹۸	۱/۳۵		
R	۴/۲۲	۵/۰۳	۲/۰۵	۲/۲۹	۶/۳۹		
O ₁ R ₁	۳/۸۳	۷/۵۳	۵/۰۵	۲/۸۶	۳/۳۸		
O ₂ R ₂	۸/۷۰	۳/۹۶	۳/۲۸	۳/۹۲	۳/۱۴		
OR	۰/۹۸	۶/۵۵	۲/۵۶	۴/۵۲	۳/۸۳		



شکل ۶- نمودار دقت F -score روش‌های MCS درختی کلاسیک و پیشنهادی در کلاس‌های مختلف و میانگین دقت‌ها (Ave.) با نمونه آموزشی ۰.۵٪ متوازن و ویژگی‌های OR در تعداد درخت: (الف) ۵، (ب) ۲۵، (پ) ۱۰۰، (ت) ۲۵۰، (ث) ۵۰۰، (ج) ۱۰۰۰

تعداد محدودی از $nTree = 5$ (۲۵، ۱۰۰ و ۱۰۰۰) مقدار آن کمی بیشتر از مقادیر نظیر روش BFF یا CFF یا هر دو شد، لیکن هنوز دقت کلاس Br آن حدود ۰.۶۵٪ کمتر از مقدار نظیر روش‌های BFF و CFF شد. با افزایش تعداد درختان، دقت F -score کلاس Pe حاصل از روش RF نیز افزایش و حتی در

همچنین در $nTree = 5$ روش RF اگرچه F -score بیشتری از روش BFF برای کلاس Pe کسب کرد، با این حال، مقدار دقت کلاس Br آن حدود ۰.۶۵٪ کمتر از مقدار نظیر روش‌های BFF و CFF شد. با افزایش تعداد درختان، دقت F -score کلاس Pe حاصل از روش RF نیز افزایش و حتی در

نتایج دقت F -score حاصل از روش RoF برعکس نتایج حاصل از روش RF شد. برای مثال در $nTree = 5$ اگرچه OA روش RoF کمتر از دو روش کلاسیک دیگر (یعنی TBa و RF) شد، اما مقدار F -score کلاس Br حاصل از آن خیلی بیشتر (تا حدود ۵۵٪ بیشتر) از مقادیر نظیر این روش‌ها شده به‌گونه‌ای که تنها حدود ۲۰٪ کمتر از مقادیر نظیر روش‌های پیشنهادی بود. همچنین مقدار F -score کلاس Pe آن تقریباً نزدیک به مقدار نظیر روش BFF شد. با افزایش تعداد درختان، مقدار F -score کلاس Br روش RoF نیز افزایش یافته به‌گونه‌ای که حتی در برخی $nTree$ ها (بالتر از ۲۵)، مقدار آن از مقدار نظیر روش BFF یا CFF یا هر دو بیشتر شد اما همچنان، مقدار F -score کلاس Pe آن تا حدود ۳۰٪ کمتر از مقادیر نظیر روش‌های پیشنهادی بود. به‌طور کلی می‌توان اظهار داشت که در میان روش‌های MCS درختی کلاسیک، روش RoF عملکرد موفقیت‌آمیزتری نسبت به دو روش دیگر در شناسایی کلاس‌های اقلیت داشت.

به‌طور کلی مشاهده شد که انحراف معیار مقادیر F -score کلاس‌ها حاصل از روش‌های پیشنهادی نسبت به روش‌های کلاسیک خیلی کمتر شد و این بدان معنی است که مقادیر دقت کلاس‌های حاصل از روش‌های پیشنهادی غالباً در یک بازه‌ی نزدیک قرار دارد و نوسانات کمتری بین مقادیر دقت آن‌ها در کلاس‌های مختلف وجود دارد. درحالی‌که روش‌های کلاسیک دارای نوسانات زیادی بین کمترین و بیشترین مقادیر F -score آن‌ها بود. این نتایج، نشان از عدم توانایی ذاتی روش‌های MCS درختی کلاسیک در شناسایی دقیق و مطمئن کلاس‌های اقلیت با استفاده از نمونه‌ی آموزشی متوازن دارد و این به‌خاطر همان دلیلی است که در مقدمه ذکر شد. در واقع تمرکز روش‌های کلاسیک در کاهش خطای مجموع روی داده‌ها به‌جای تمرکز ویژه روی کلاس‌های اقلیت سبب بروز چنین مشکلی در روش‌های کلاسیک شد. درمقابل، روش‌های پیشنهادی با نمونه‌ی آموزشی متوازن به‌خوبی از عهده‌ی طبقه‌بندی کلاس‌های اقلیت با حفظ دقت بالای کلاس‌های اکثریت برآمد که یک موفقیت چشم‌گیر برای آن‌ها در مقایسه با رقبایشان به‌ویژه RF محسوب می‌شود.

۴-۱-۱- مقایسه‌ی دقت با نمونه‌ی آموزشی نامتوازن

• مقایسه با ویژگی‌های نوری

نتایجی که با استفاده از نمونه‌ی آموزشی نامتوازن با ویژگی‌های نوری توسط روش‌ها کسب شد (شکل ۷) در وضعیتی متفاوت با نتایج کسب‌شده از نمونه‌ی آموزشی متوازن


قرار داشت. به‌عنوان مثال، در ویژگی‌های O_1 با استفاده از نمونه‌ی آموزشی نامتوازن، میانگین OA روش پیشنهادی BFF تنها ۳٪ بیشتر از روش RoF اما حدود ۲٪ تا ۶٪ کمتر از روش‌های TBa و RF شد. همچنین مقدار نظیر روش CFF از روش‌های RoF و کمی هم RF بیشتر اما حدود ۴٪ کمتر از مقدار نظیر روش TBa شد. علاوه بر این، جدول ۴ نشان از ثبات کمتر نتایج روش‌های پیشنهادی نسبت به روش‌های کلاسیک در ویژگی‌های O_1 با نمونه‌ی آموزشی نامتوازن داشت.

جدول ۴- انحراف معیار دقت کلی (٪) روش‌های MCS درختی کلاسیک و پیشنهادی در تعداد درخت ۵ تا ۱۰۰۰ با نمونه‌ی آموزشی ۵٪ نامتوازن


ویژگی‌ها	روش‌های MCS درختی				
	کلاسیک	روش‌های پیشنهادی	درختی		
	TBa	RF	RoF	BFF	CFF
O_1	۰/۶۳	۰/۶۹	۰/۱۵	۰/۷۳	۱/۲۲
O_2	۲/۰۲	۱/۱۲	۰/۴۸	۲/۲۳	۲/۹۱
O	۳/۳۷	۱/۷۸	۱/۶۲	۱/۹۴	۱/۸۳
R_1	۱/۵۴	۲/۵۲	۰/۵۲	۳/۳۰	۱/۵۸
R_2	۲/۹۵	۲/۷۰	۱/۹۲	۱/۴۹	۱/۰۳
R	۱/۰۲	۳/۱۹	۰/۸۵	۳/۵۲	۲/۵۳
O_1R_1	۳/۴۱	۱/۸۱	۲/۱۳	۴/۰۹	۲/۴۶
O_2R_2	۱/۲۰	۱/۳۱	۰/۸۷	۲/۰۹	۱/۲۷
OR	۲/۱۰	۲/۴۴	۲/۷۴	۲/۱۹	۱/۱۵

با ویژگی‌های O_2 ، هر دو روش پیشنهادی دارای میانگین OA بیشتر از روش RoF اما خیلی کمتر (حدود ۲٪ تا ۱۰٪) از دو روش RF و TBa بود. همچنین نتایج دو روش پیشنهادی، ثبات‌پذیری کمتری نسبت به هر سه روش کلاسیک داشت. با ویژگی‌های O، روش BFF فقط دارای میانگین OA بیشتر از روش RoF و در مقابل کمتر از دو روش RF و TBa بود. روش CFF نیز علی‌رغم کسب مقدار بیشتر از روش‌های RF و RoF همچنان حدود ۳٪ کمتر از روش TBa کسب کرد. طبق روال دو نتیجه‌ی قبلی، ثبات نتایج دو روش BFF و CFF از روش‌های RF و RoF کمتر اما از روش TBa بیشتر شد. پس به‌طور کلی می‌توان بیان داشت که با نمونه‌ی آموزشی نامتوازن، روش‌های MCS درختی پیشنهادی کارایی نسبتاً کمتری از روش‌های کلاسیک در طبقه‌بندی ویژگی‌های نوری داشت.

مشابه با نتایج حاصل از نمونه‌ی آموزشی متوازن، روش‌های MCS درختی کلاسیک به‌عنوان سیستم‌های جمعی بزرگ و پر حجم شناخته می‌شود. در مورد روش‌های پیشنهادی، شکل ۸ نشان از سطح هرس غیر صفر با ویژگی‌های نوری دارد که باز تمایل این روش‌ها در کوچک و کم‌بار بودن را نشان می‌دهد.



شکل ۷- نمودار دقت کلی روش‌های MCS درختی کلاسیک و پیشنهادی در تعداد درخت ۵ تا ۱۰۰۰ با نمونه آموزشی ۰.۵٪ نامتوازن و با استفاده از ویژگی‌های: (الف) O_1 ، (ب) O_2 ، (پ) O ، (ت) R_1 ، (ث) R_2 ، (ج) R ، (چ) O_1R_1 ، (ح) O_2R_2 ، و (خ) OR



شکل ۸- سطح هرس بهینه‌ی روش‌های MCS درختی پیشنهادی (BFF و CFF) با نمونه‌ی آموزشی ۰.۵٪ نامتوازن با استفاده از ویژگی‌های نوری (بالا)، راداری (وسط) و ترکیب ویژگی‌های نوری و راداری (پایین) در: (الف) تاریخ اول، (ب) تاریخ دوم، و (پ) ترکیب تاریخ اول و دوم

• مقایسه با ویژگی‌های راداری

برخلاف نتایج ویژگی‌های نوری که عملکرد روش‌های کلاسیک بهتر از عملکرد روش‌های پیشنهادی بود، در ویژگی‌های راداری مجدداً موفقیت‌هایی از روش‌های پیشنهادی دیده شد. با ویژگی‌های R_1 ، مقدار میانگین OA روش‌های پیشنهادی از مقادیر نظیر روش‌های TBa و RoF بیشتر اما حول و حوش ۱٪ تا ۲٪ کمتر از مقدار نظیر روش RF شد. با این حال، بیشینه‌ی OA مشترکاً متعلق به روش پیشنهادی BFF و روش کلاسیک RF بود. از لحاظ ثبات‌پذیری، نتایج روش CFF باثبات‌تر و نتایج روش BFF کم‌ثبات‌تر از نتایج روش RF بود.

با ویژگی‌های R_2 ، میانگین OA روش BFF بین ۲٪ تا ۱۰٪ بیشتر از همه‌ی روش‌های کلاسیک شد. اما برای روش CFF، مقدار آن بین ۴٪ تا ۶٪ بیشتر از روش‌های TBa و RF و حدود ۲٪ کمتر از روش RoF شد. ضمن این‌که، نتایج روش‌های پیشنهادی باثبات‌تر از همه‌ی روش‌های کلاسیک بود.

سرانجام با ویژگی‌های R، نتایج بدین‌صورت شد: روش BFF تا حدود ۱۲٪ موفق‌تر از روش‌های کلاسیک شد اما روش CFF تنها حدود ۴٪ موفق‌تر از روش TBa ولی بین ۱٪ تا ۴٪ ناموفق‌تر از دو روش RF و RoF شد. مشابه نتایج R_1 ، نتایج روش CFF حاصل از R باثبات‌تر از روش RF اما نتایج روش BFF کم‌ثبات‌تر از روش RF شد. شکل‌های ۸ الف، ب و پ (وسط) مجدداً نشان از سطح هرس بالاتر نسبت به نمونه‌ی آموزشی متوازن با ویژگی-های راداری برای روش‌های پیشنهادی داشت که این سطح هرس در روش CFF بیشتر از روش BFF بود. این موضوع بار دیگر موید نتایج پیشین این پژوهش بود که ادعای کم‌بار و کوچک بودن روش‌های MCS درختی پیشنهادی در طبقه‌بندی ابعاد بالا را داشت.

• مقایسه با ترکیب ویژگی‌های نوری و راداری

با ویژگی‌های O_1R_1 ، میانگین OA روش‌های BFF و CFF حدود ۷٪ بیشتر از مقادیر روش‌های TBa و RoF و حدود ۱٪ کمتر از مقدار روش RF شد. با این حال بیشینه-ی OA توسط همین دو روش پیشنهادی CFF و BFF (حدود ۸۳٪) کسب شده است. البته، ثبات نتایج روش‌های RF و RoF بیشتر از دو روش پیشنهادی شد (جدول ۴). با ویژگی‌های O_2R_2 ، میانگین OA روش‌های BFF و CFF


حدود ۱٪ تا ۴٪ بیشتر از مقادیر نظیر همه‌ی روش‌های MCS درختی کلاسیک شد. با این حال، جدول ۴ نشان داد که مجدداً ثبات نتایج مربوط به روش‌های کلاسیک کمی بیشتر از روش‌های پیشنهادی شد. سرانجام، در ویژگی‌های OR، میانگین OA روش BFF از همه‌ی روش‌های کلاسیک بیشتر شد، اما مقدار نظیر روش CFF از روش‌های TBa و RoF بیشتر و حدود ۱٪ کمتر از روش RF شد. در این مورد، ثبات نتایج روش‌های پیشنهادی نسبت به رقبایشان به‌ویژه روش RF بیشتر بود.

نتیجه‌ی دیگر در مورد عملکرد روش‌های MCS درختی در nTreeهای مختلف با ترکیب ویژگی‌هاست: در میان روش‌های کلاسیک، روش TBa و روش RF با افزایش تعداد درخت، دقتشان افزایش یافت و لذا جزو سیستم‌های جمعی بزرگ محسوب می‌شود. اما برخلاف نتایج قبلی این پژوهش، روش RoF در همان nTreeهای کوچک، دقت بالایی کسب کرد. بنابراین می‌توان بیان داشت هنگامی که عدم توازن بین نمونه‌های آموزشی کلاس‌ها برقرار است در یک فضای ویژگی ابعاد بزرگ، روش RoF یک سیستم جمعی کوچک محسوب می‌شود. این نتیجه با ادعای پژوهش‌های قبلی سازگار بود. در مورد روش‌های پیشنهادی BFF و CFF نیز شکل‌های ۸ الف، ب و پ (پایین) نشان داد که سطح هرس درختان در تعداد درخت بالا (برای حالت آخر از تعداد درخت ۵۰ به بالا) افزایش یافت. این افزایش سطح هرس در مقایسه با نمونه‌ی آموزشی متوازن خیلی بیشتر شد به‌ویژه برای روش CFF. این موضوع بار دیگر موید کم‌بار و کم‌حجم بودن روش‌های پیشنهادی بود.

نتایج F-score روش‌های MCS درختی با نمونه‌ی آموزشی نامتوازن (شکل ۹) کمی متفاوت با نتایج آن‌ها با نمونه‌ی آموزشی متوازن (شکل ۶) بود. از شکل ۹، میانگین دقت F-score روش BFF روی کلاس‌ها در تمام nTreeها از مقادیر نظیر تمام روش‌های کلاسیک بیشتر شد (همانند قبل). به‌طور جزء به جزء، عملکرد روش BFF نسبت به روش‌های کلاسیک در شناسایی کلاس‌های اقلیت حتی در مقایسه با نتایج نمونه‌ی آموزشی متوازن بهتر شده است. برای مثال، دقت F-score کلاس Br روش BFF تا حدود ۷۵٪ در برخی nTreeها از مقادیر نظیر روش‌های کلاسیک بیشتر شد. مقدار F-score کلاس Br روش‌های کلاسیک (به‌ویژه دو روش TBa و RF) بین ۱۰٪ تا حداکثر ۴۰٪ در nTreeهای مختلف بود. حتی در $nTree = 25$ که

روش TBa کمی بالاتر از مقدار نظیر روش BFF بود اما باز در همین n Tree ها، دقت F -score کلاس Br روش BFF خیلی بیشتر از مقادیر نظیر RF و TBa شد.

روش RF دارای مقدار OA بیشتری از روش BFF بود، دقت F -score کلاس Pe و Br آن حدود ۵٪ و ۵۵٪ کمتر از مقادیر نظیر روش BFF شد. اگرچه در برخی n Tree ها (۵۰ به بالا) مقدار F -score کلاس Pe روش RF (و گاهی اوقات



شکل ۹- نمودار دقت F -score روش های MCS درختی کلاسیک و پیشنهادی در کلاس های مختلف و میانگین دقت ها (Ave.) با نمونه آموزشی ۵٪، ۱۰۰، ۲۵۰، ۵۰۰، ۱۰۰۰ و ویژگی های OR در تعداد درخت: (الف) ۵، (ب) ۲۵، (پ) ۵۰، (ت) ۱۰۰، (ث) ۲۵۰، (ج) ۵۰۰ و (چ) ۱۰۰۰


شد. به طور جزئی نیز اگر به مقادیر دقت F -score کلاس های اقلیت حاصل از روش CFF بنگریم در می یابیم که اگرچه دقت کلاس Br آن نسبتاً بیشتر از مقادیر نظیر روش های کلاسیک شده اما نسبت به روش BFF اختلاف آن با مقادیر سایر روش ها چندان زیاد نیست. حتی در n Tree = 50 مقدار آن حدود ۴٪ کمتر از روش RF و ۳۵٪ کمتر از روش RoF شد. با این حال در مقایسه با روش TBa برتری خیلی محسوس تری داشت ضمن آن که هنوز انحراف معیار دقت F -score آن نسبت به روش های MCS درختی کلاسیک کمتر شد.

به طور کلی، نتایج مقایسه ی روش های MCS درختی کلاسیک و پیشنهادی موید این مطلب بود که روش های کلاسیک چه با نمونه ی آموزشی متوازن (حاوی تعداد نمونه های یکسان برای هر کلاس) و چه با نمونه ی آموزشی نامتوازن (حاوی درصد نسبی نمونه های یکسان

روش RoF نیز دارای مقدار F -score خیلی پایین تر از روش BFF در این دو کلاس است. البته در n Tree = 1000 مقدار دقت کلاس Br روش RoF حدود ۲٪ بیشتر از روش BFF شد اما در مقابل، دقت کلاس Pe آن حدود ۴۵٪ کمتر شده است. همچنین مشابه نتایج حاصل از نمونه ی آموزشی متوازن، انحراف معیار دقت F -score حاصل از روش BFF خیلی کمتر از مقادیر نظیر روش های MCS درختی کلاسیک شد که نشان دهنده ی این موضوع بود که روش BFF دقتی تقریباً مساوی و با نوسانات کمتر برای همه ی کلاس ها کسب کرده است.

در مورد روش پیشنهادی CFF، نتایج نسبت به نمونه ی آموزشی متوازن کمی افت داشت. میانگین F -score آن از مقادیر نظیر روش های TBa و RoF در تمام n Tree ها بیشتر شد با این حال، در برخی n Tree ها (بزرگتر از ۵۰) مقدار آن از مقدار نظیر روش RF (حدود ۱٪ تا ۳٪ کمتر

حتی گاهی تا حدود ۱۰٪ بیشتر دست یابد و همچنین در شناسایی مطمئن و دقیق کلاس‌های اقلیت موفق‌تر باشد، یک موفقیت و ارزش ستودنی برای روش‌های پیشنهادی به‌عنوان جایگزینی مناسب و سریع روش مشهور RF محسوب می‌شود.



شکل ۱۰- نمودار زمان اجرای روش‌های MCS درختی کلاسیک و پیشنهادی در تعداد درخت ۵ تا ۱۰۰۰ با نمونه‌ی آموزشی ۰.۵٪ (الف) متوازن و (ب) نامتوازن

با استفاده از نمونه‌ی آموزشی نامتوازن، شکل ۱۰ ب نشان داد که شیب زمان اجرای روش‌های کلاسیک از جمله روش TBa و RF رشد بیشتری پیدا کرده به‌گونه‌ای که زمان اجرای روش TBa از زمان روش RoF نیز بیشتر شد (از $nTree = 25$ به بعد) و روش RF نیز همچنان طولانی‌ترین روند اجرایی را داراست.

زمان اجرای روش‌های پیشنهادی BFF و CFF نیز افزایش یافته است. اما اولاً این افزایش نسبت به روش‌های کلاسیک خیلی کمتر بود. ثانیاً برخلاف نتیجه‌ی قبلی، زمان اجرای روش‌های پیشنهادی تا قبل از $nTree = 100$ دارای شیب بیشتری نسبت به بعد از آن بود. در واقع بعد

برای هر کلاس یا به‌عبارتی تعداد نمونه‌های مختلف برای هر کلاس) قادر نبود تا دقت متناسب و کافی برای شناسایی کلاس‌های اقلیت کسب کند و لذا همواره خطای اضافه‌شدگی یا حذف‌شدگی این کلاس‌ها توسط این روش‌ها بالا بود. این مشکل روش‌های کلاسیک در نمونه‌ی آموزشی نامتوازن بیشتر مشاهده شد.

در مقابل، روش‌های پیشنهادی به‌ویژه روش BFF چه با نمونه‌ی آموزشی متوازن و چه با نمونه‌ی آموزشی نامتوازن کارآمدی بالایی در تشخیص دقیق و مطمئن همه‌ی کلاس‌ها به‌ویژه کلاس‌های اقلیت داشت. البته بایستی اعتراف نمود که روش پیشنهادی CFF به‌اندازه‌ی روش پیشنهادی BFF با نمونه‌ی آموزشی نامتوازن در تشخیص دقیق کلاس‌های اقلیت کارآمد نبود.

۴-۲- مقایسه‌ی زمان روش‌های MCS درختی

شکل ۱۰، نمودار زمان اجرای روش‌های MCS درختی کلاسیک و پیشنهادی با استفاده از نمونه‌ی آموزشی ۰.۵٪ متوازن و نامتوازن را در تعداد درخت ۵ تا ۱۰۰۰ نشان می‌دهد. این زمان در حین اجرای مراحل آموزش و آزمایش هر یک از روش‌ها روی تمام ۹ حالت ویژگی‌ها (O_1 تا O_R) محاسبه شده است.

مطابق با شکل ۱۰ الف، با استفاده از نمونه‌ی آموزشی متوازن، زمان اجرای تمام الگوریتم‌های MCS درختی (هم کلاسیک و هم پیشنهادی) با افزایش تعداد درختان، به صورت صعودی افزایش یافت. در بین همه‌ی روش‌ها، روش TBa از زمان کمتر و سرعت اجرای بیشتری برخوردار بود. ضمن آن‌که تا تعداد درخت ۲۵۰ یک سیر نسبتاً خطی افقی و پس از آن، یک سیر صعودی یا فزاینده داشت. روش RoF از همان تعداد درخت ۵ به بعد، سیر صعودی یا فزاینده‌ی زمان اجرای خود را با یک شیب نسبتاً ثابت پیش برد. در مقابل، زمان اجرای روش RF یک سیر صعودی شدید با شیب تند داشت به‌گونه‌ای که با افزایش تعداد درخت، اختلاف زمان اجرای این روش با سایر روش‌ها نیز به شدت افزایش یافت.

زمان اجرای روش‌های پیشنهادی BFF و CFF نیز با افزایش تعداد درختان، زیاد شد با این تفاوت که شیب افزایش تا قبل از $nTree = 100$ کمتر از شیب افزایش بعد از آن بود. این موضوع که روش‌های پیشنهادی با سرعتی ۶ برابر سرعت روش مشهور RF توانسته به دقتی برابر یا

شکل ۱۱ تأثیر اندازه‌های آموزشی از کم به زیاد ۰/۵٪، ۰/۱٪، ۰/۳٪، ۰/۵٪، ۰/۱۰٪، ۰/۳۰٪، ۰/۵۰٪، ۰/۷۰٪ و ۰/۹۰٪ (در حالت متوازن) را با استفاده از کل ویژگی‌های OR بر روی OA روش‌های DT و MCS درختی (با تعداد درخت ۵) نشان می‌دهد. همچنین میانگین (Ave.) و انحراف معیار (STD) مقادیر OA این روش‌ها در اندازه‌های مختلف نمونه‌ی آموزشی در جدول ۵ آورده شده است.

جدول ۵- Ave و STD مقادیر دقت کلی (٪) روش‌های MCS درختی
(nTree = 5) در اندازه‌های مختلف نمونه‌ی آموزشی

	پیشنهادهای			کلاسیک		منفرد
	CFF	BFF	RoF	RF	TBa	DT
Ave.	۸۶/۶۰	۸۴/۴۹	۸۲/۸۶	۸۳/۱۰	۸۵/۲۱	۶۷/۲۲
STD	۸/۲۵	۸/۷۷	۱۳/۷۴	۱۳/۱۰	۱۲/۴۲	۲۱/۶۹

از جدول ۵ مشاهده شد که متوسط OA روش DT کمتر از ۰/۷۰٪ و متوسط OA روش‌های MCS درختی بیشتر از ۰/۸۰٪ شده است. شکل ۱۱ نیز نشان داد، روش DT منفرد در اندازه‌های آموزشی کوچکتر (کمتر از ۰/۱۰٪)، دقت‌های کلی کمتر از ۰/۸۰٪ کسب کرد. در واقع میزان اختلاف دقت این روش با روش‌های MCS درختی در این اندازه‌های کوچک خیلی زیاد بود (حدود ۰/۴۰٪). هر قدر اندازه‌ی نمونه‌ی آموزشی بزرگتر شد، OA این روش منفرد افزایش و میزان اختلاف آن با OA روش‌های MCS درختی نیز کمتر شد. به گونه‌ای که مثلاً در اندازه‌ی نمونه‌ی آموزشی ۰/۹۰٪، این اختلاف به حدود ۳٪ تا ۴٪ (یک دهم اختلاف در اندازه‌ی نمونه‌ی آموزشی ۰/۵٪) تقلیل یافت. این موضوع از شیب بیشتر نمودار خطی روش DT و شیب نسبتاً کمتر نمودارهای خطی روش‌های MCS درختی نیز کاملاً مشهود بود. این نتایج و همچنین مقدار انحراف معیار بالای آن (حدود ۲۲) نشان داد که روش DT شدیداً به اندازه‌ی نمونه‌ی آموزشی حساس است. این بدان معناست که این روش با تعداد نمونه‌ی آموزشی ناکافی در یک فضای ویژگی ابعاد بالا شدیداً دچار مشکل می‌شود.

در مقابل، روش‌های MCS درختی که از انحراف معیار پایین‌تری برخوردار است دارای کارایی و عملکرد مناسبی در فضای ویژگی ابعاد بالا حتی با اندازه‌های کوچک نمونه‌ی آموزشی است. در این میان، روش‌های MCS درختی پیشنهادی با STD کمتر دارای ثبات‌پذیری بیشتر نسبت به روش‌های MCS درختی کلاسیک است. بنابراین می-

از تعداد درخت ۱۰۰، زمان اجرای روش‌های پیشنهادی برخلاف پیش‌بینی کاهش یافته و حتی در تعداد درخت ۱۰۰۰ نزدیک یا کمتر از زمان اجرای روش‌های TBa و RoF شد. حصول دقت کلی تا ۱۰٪ بیشتر و همچنین حصول دقت‌های F-score بالا برای کلاس‌های اقلیت با سرعت اجرای نسبتاً برابر با این روش‌های کلاسیک، برگ زرین دیگری از موفقیت روش‌های پیشنهادی بود.

دلیل اینکه روش‌های پیشنهادی با نمونه‌ی آموزشی نامتوازن در تعداد درختان بزرگتر دارای شیب زمان کمتر نسبت به تعداد درختان کوچکتر شده را می‌توان از روی شکل ۸ (سطح هرس بهینه روش‌های پیشنهادی) توجیه نمود. با رجوع به این شکل‌ها، دیده شد که در ویژگی‌های نوری، راداری و ترکیبشان، میل روش‌های پیشنهادی به هرس درختان در nTree‌های بزرگتر افزایش چشم‌گیری یافته و همین باعث کم‌بار شدن و کوچک شدن این روش‌ها شده و بنابراین فرآیند آزمایش این روش‌ها نیز سریعتر انجام شده است.


بین دو روش MCS درختی پیشنهادی، عملکرد روش BFF در ۷ مورد از ۹ مورد (با استفاده از نمونه‌ی آموزشی متوازن) و در ۵ مورد از ۹ مورد (نامتوازن) بهتر از روش CFF بود (میانگین OA و F-score بالاتر). به علاوه، دقت شناسایی کلاس‌های اقلیت در BFF هم با نمونه‌ی آموزشی متوازن و هم با نمونه‌ی آموزشی نامتوازن نسبت به CFF بیشتر بود. همچنین، ثبات نتایج BFF در مجموع بیشتر از نتایج CFF بود. زمان اجرای BFF نیز خیلی کمتر از زمان اجرای CFF بود. دلیل سرعت بالاتر روش BFF نسبت به روش CFF را می‌توان به دلیل استفاده از ماتریس هزینه و یادگیری هزینه‌حساس در CFF دانست که باعث کند شدن روند اجرای فرآیند آموزش روش CFF نسبت به روش BFF می‌شود. به لطف این مزیت‌ها، روش BFF نسبت به روش CFF برای طبقه‌بندی زمین‌های کشاورزی منطقه‌ی مطالعاتی بیشتر قابل تحسین است.

۴-۳- تأثیر اندازه‌ی نمونه‌ی آموزشی روی دقت

جهت بررسی و مقایسه‌ی بهتر تأثیر اندازه‌های مختلف نمونه‌ی آموزشی روی دقت کلی روش‌های MCS درختی، از الگوریتم درخت تصمیم منفرد^۱ (DT) نیز استفاده شد.

^۱ Decision Tree

توان ادعا کرد که روش‌های MCS درختی پیشنهادی
نسبت به اندازه‌ی نمونه‌ی آموزشی حساسیت کمتری از
روش‌های MCS درختی کلاسیک دارد که یک امتیاز برای
روش‌های پیشنهادی محسوب می‌شود.




شکل ۱۱- تأثیر اندازه‌ی کم تا زیاد نمونه‌ی آموزشی روی دقت کلی روش‌های MCS درختی

۴-۴- مقایسه‌ی دقت روش‌های رأی‌گیری


با OMV و همچنین نتایج حاصل از روش CFF با MV و
CFF با WMV انجام دهیم.

شکل ۱۲ نمودار دقت روش‌های {MV} BFF و BFF
{OMV} در n Tree های ۵ تا ۱۰۰۰ با استفاده از نمونه‌ی
آموزشی ۰.۵٪ متوازن و نامتوازن و با ویژگی‌های OR را
نشان می‌دهد. همچنین، نمودار دقت روش‌های CFF
{MV} و {WMV} CFF در شکل ۱۳ مشاهده می‌شود.

همان‌طور که در بخش روش‌شناسی توضیح داده شد،
روش BFF از تکنیک رأی‌گیری هدفمند OMV و روش
CFF از تکنیک رأی‌گیری وزن‌دار WMV به‌جای MV در
ساختار خود استفاده کرد. در این بخش، قصد داریم تا
مقایسه‌ای بین نتایج حاصل از روش BFF با MV و BFF



شکل ۱۲- نمودار OA روش‌های {MV} BFF و {OMV} BFF با نمونه‌ی آموزشی ۰.۵٪ (الف) متوازن و (ب) نامتوازن



شکل ۱۳- نمودار OA روش‌های {MV} CFF و {WMV} CFF با نمونه‌ی آموزشی ۰.۵٪ (الف) متوازن و (ب) نامتوازن

همان‌طور که در شکل ۱۲ الف دیده می‌شود، تکنیک رأی‌گیری OMV توانسته حدود ۲٪ تا ۵٪ (متوسط ۳٪) دقت کلی روش BFF را نسبت به تکنیک رأی‌گیری MV با استفاده از نمونه‌ی آموزشی ۵٪/۰٪ متوازن افزایش دهد. همچنین وقتی از نمونه‌ی آموزشی نامتوازن استفاده شد (شکل ۱۲ ب)، افزایش دقت کلی بین ۲٪/۲٪ تا ۵٪/۵٪ (متوسط ۳٪/۶٪) بود. این افزایش دقت در تعداد درخت‌های پایین ($nTree < 100$) بیشتر و در تعداد درخت‌های بالاتر کمتر بود. پس می‌توان اظهار داشت که روش رأی‌گیری هدفمند OMV به دلیل به کارگیری دو ترفند اضافی، موفقیت بیشتری نسبت به تکنیک رأی‌گیری کلاسیک MV در روش BFF ایفا کرده است.

در مورد روش CFF، شکل ۱۳ الف نشان داد که تکنیک رأی‌گیری WMV حدود ۲٪ تا ۷٪ (متوسط ۳٪/۷٪) دقت کلی روش CFF را نسبت به تکنیک رأی‌گیری MV با استفاده از نمونه‌ی آموزشی متوازن افزایش داده است. این میزان افزایش نسبت به OMV حدود ۱٪ تا ۲٪ بیشتر شده است. با این حال، برخلاف روش OMV هنگام استفاده از نمونه‌ی آموزشی نامتوازن، میزان افزایش دقت روش WMV نسبت به MV کاهش یافته است (بین ۱٪/۸٪ تا ۵٪/۵٪ متوسط ۳٪/۲٪). پس به‌طور کلی می‌توان ادعا کرد تکنیک رأی‌گیری وزن‌دار WMV به دلیل استفاده از ماتریس هزینه و وزن‌های مختلف کلاسی در روش CFF نسبت به تکنیک رأی‌گیری ساده و کلاسیک MV ارجح و موفق‌تر است. همانند روش OMV، میزان افزایش دقت در تعداد درخت‌های پایین بیشتر و محسوس‌تر است و این موضوع بار دیگر موید این مطلب است که دو روش پیشنهادی این پژوهش یعنی روش‌های BFF و CFF جزو سیستم‌های طبقه‌بندی جمعی کوچک و کم‌حجم محسوب می‌شود.

۵- نتیجه‌گیری

این پژوهش به طبقه‌بندی زمین‌های کشاورزی یک منطقه‌ی محلی کانادا از تصاویر دوزمانه‌ی RapidEye و UAVSAR با استفاده از سیستم‌های طبقه‌بندی‌کننده‌ی چندگانه‌ی (MCS) درختی پرداخت. روش‌های MCS درختی کلاسیک شامل بگینگ درختی (TBa)، جنگل تصادفی (RF) و جنگل دورانی (RoF) با روش‌های MCS درختی نوین شامل جنگل پالایشی متوازن‌شده (BFF) و

جنگل پالایشی هزینه‌حساس (CFF) مقایسه شد. نتایج نشان داد که در طبقه‌بندی تصاویر نوری با نمونه‌ی آموزشی متوازن و طبقه‌بندی تصاویر راداری با نمونه‌ی آموزشی نامتوازن، کارایی و عملکرد روش‌های نوین خیلی بهتر از روش‌های کلاسیک بود. اما در طبقه‌بندی تصاویر نوری با نمونه‌ی آموزشی نامتوازن و طبقه‌بندی تصاویر راداری با نمونه‌ی آموزشی متوازن، کارایی هر دو دسته روش تقریباً یکسان بود. همچنین، در طبقه‌بندی ترکیب تصاویر نوری و راداری، هم با نمونه‌ی آموزشی متوازن و هم نامتوازن، کارایی، عملکرد و ثبات روش‌های نوین خیلی بهتر از روش‌های کلاسیک بود.

مهمترین خصوصیت و قابلیت ممتاز روش‌های نوین به‌ویژه روش BFF نسبت به رقبایشان از جمله RF، عملکرد موفق‌تر و بهتر این روش‌ها در شناسایی بهتر همه-ی محصولات به‌ویژه کلاس‌های اقلیت کشاورزی هم با نمونه‌ی آموزشی متوازن و هم نامتوازن بود. نکته‌ی جالب-تر این‌که این روش‌ها حتی در تعداد درختان پایین به این نتیجه‌ی مهم دست یافت. در حالی‌که، روش‌های کلاسیک در شناسایی کلاس‌های اقلیت مخصوصاً در تعداد درختان پایین عملکرد ضعیفی از خود نشان داد. قابلیت‌های روش-های نوین جالب توجه‌تر خواهد بود هنگامی‌که متوجه می‌شویم این موفقیت‌ها با سرعتی حدود ۱۰ تا ۲۰ برابر سرعت رقیب اصلی‌شان RF به‌دست آمده است.

نتیجه‌گیری دیگر این پژوهش این بود که روش‌های نوین نسبت به اندازه‌ی نمونه‌ی آموزشی حساسیت کمتر و ثبات بیشتری از روش‌های کلاسیک داشت. به‌علاوه، نسبت به توازن/عدم توازن نمونه‌ی آموزشی، حساسیت روش‌های نوین خیلی کمتر از روش‌های کلاسیک بود.

روش‌های نوین برخلاف روش‌های کلاسیک، سیستم-های کوچک‌تر و کم‌حجم‌تر بود. این به دو معنا بود: روش-های نوین زمانی‌که تعداد ویژگی‌ها نسبتاً زیاد بود، در همان تعداد درخت پایین به دقت‌های بالا دست یافت. همچنین زمانی‌که تعداد ویژگی‌ها خیلی زیاد بود اگرچه دقت روش‌های نوین در تعداد درختان بالا افزایش یافت با این حال، به دلیل هرس شدن درختان باز روش‌های پیشنهادی کم‌حجم و کم‌بارتر شد. در واقع روش‌های نوین غالباً تمایل زیادی به کوچک‌تر کردن خود داشت.

به‌طور کلی می‌توان علل موفقیت‌های روش‌های MCS درختی نوین را در این موارد خلاصه نمود: ۱) بهبود دقت

کلی روش‌های نوین نسبت به رقبایشان به‌طور عمده‌ای به بخش ادغام تصمیم و بخش راهکارهای حل مسالیه داده‌های نامتوازن مرتبط می‌شد. (۲) بهبود دقت شناسایی کلاس‌های اقلیت در روش‌های نوین نسبت به رقبایشان به بخش راهکارهای حل مسالیه داده‌های نامتوازن در این روش‌ها مرتبط می‌شد. (۳) بهبود سرعت اجرای روش‌های

نوین نسبت به رقبایشان به‌طور عمده‌ای به بخش انتخاب ویژگی و سپس بخش هرس کردن مرتبط می‌شد. (۴) در نهایت، کم‌حجم شدن و کم‌بار شدن سیستم‌های جمعی روش‌های نوین به‌طور زیادی به بخش هرس کردن در این روش‌ها مرتبط می‌شد.

مراجع

- [1] Foody, G.M., M.B. Mcculloch, and W.B. Yates. 1994. "Crop Classification from C-Band Polarimetric Radar Data." *Int. J. Remote Sens.* 15(14), 2871–2885.
- [2] Huang, X., J. Wang, J. Shang, C. Liao, and J. Liu. 2017. "Application of Polarization Signature to Land Cover Scattering Mechanism Analysis and Classification Using Multi-Temporal C-band Polarimetric RADARSAT-2 Imagery." *Remote Sens. Environ.* 193, 11–28.
- [3] Joshi, N., M. Baumann, A. Ehammer, R. Fensholt, K. Grogan, P. Hostert, M.R. Jepsen, T. Kuemmerle, P. Meyfroidt, E.T.A. Mitchard, J. Reiche, C.M. Ryan, and B. Waske. 2016. "A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring." *Remote Sens.* 8(1), 70, 1–23.
- [4] Richards, J.A., and J.A. Richards. 1999. "Remote Sensing Digital Image Analysis." Vol. 3, Berlin et al.: Springer.
- [5] Peña-Barragán, J.M., M.K. Ngugi, R.E. Plant, and J. Six. 2011. "Object-Based Crop Identification Using Multiple Vegetation Indices, Textural Features and Crop Phenology." *Remote Sens. Environ.* 115(6), 1301–1316.
- [6] Ursani, A.A., K. Kpalma, C.C. Lelong, and J. Ronsin. 2012. "Fusion of Textural and Spectral Information for Tree Crop and Other Agricultural Cover Mapping with Very-High Resolution Satellite Images." *IEEE J. Selected Topics in App. Earth Observ. Remote Sens.* 5(1), 225–235.
- [7] Kim, H.O., and J.M. Yeom. 2014. "Effect of Red-Edge and Texture Features for Object-Based Paddy Rice Crop Classification Using RapidEye Multi-Spectral Satellite Image Data." *Int. J. Remote Sens.* 35(19), 7046–7068.
- [8] Khosravi, I., A. Safari, and S. Homayouni. 2018. "MSMD: Maximum Separability and Minimum Dependency Feature Selection for Cropland Classification from Optical and Radar Data." *Int. J. Remote Sens.* In Press.
- [9] Loosvelt, L., J. Peters, H. Skriver, B. De Baets, and N.E. Verhoest. 2012. "Impact of Reducing Polarimetric SAR Input on the Uncertainty of Crop Classifications Based on the Random Forests Algorithm." *IEEE Tran. Geosci. Remote Sens.* 50(10), 4185–4200.
- [10] Tamiminia, H., S. Homayouni, H. McNairn, and A. Safari. 2017. "A Particle Swarm Optimized Kernel-Based Clustering Method for Crop Mapping from Multi-Temporal Polarimetric L-band SAR Observations." *Int. J. App. Earth Observ. Geoinf.* 58, 201–212, 2017.
- [11] Bruzzone, L., M. Marconcini, U. Wegmüller, and A. Wiesmann. 2004. "An Advanced System for the Automatic Classification of Multitemporal SAR Images." *IEEE Tran. Geosci. Remote Sens.* 42, 1321–1334.
- [12] Lee, J.S., M.R. Grunes, and G. De Grandi. 1999. "Polarimetric SAR Speckle Filtering and Its Implication for Classification." *IEEE Tran. Geosci. Remote Sens.* 37(5), 2363–2373.
- [13] Villa, P., D. Stroppiana, G. Fontanelli, R. Azar, and P.A. Brivio. 2015. "In-Season Mapping of Crop Type with Optical and X-Band SAR Data: A Classification Tree Approach Using Synoptic Seasonal Features." *Remote Sens.* 7(10), 12859–12886.
- [14] McNairn, H., C. Champagne, J. Shang, D. Holmstrom, and G. Reichert. 2009a. "Integration of Optical and Synthetic Aperture Radar (SAR) Imagery for Delivering Operational Annual Crop Inventories." *ISPRS J. Photogrammetry and Remote Sens.* 64(5), 434–449.
- [15] Halder, D., and C. Patnaik. 2010. "Synergistic Use of Multi-Temporal Radarsat SAR and AWiFS Data for Rabi Rice Identification." *J. Indian Soc. Remote Sens.* 38(1), 153–160.
- [16] Torbick, N., W.A. Salas, S. Hagen, and X. Xiao. 2011a. "Monitoring Rice Agriculture in the Sacramento Valley, USA with Multitemporal PALSAR and MODIS Imagery." *IEEE J. Selected Topics in App. Earth Observ. Remote Sens.* 4(2), 451–457.

- [17] Inglada, J., A. Vincent, M. Arias, and C. Marais-Sicre. 2016. Improved Early Crop Type Identification by Joint Use of High Temporal Resolution SAR and Optical Image Time Series. *Remote Sens.* 8(5), 362.
- [18] Skakun, S., N. Kussul, A. Y. Shelestov, M. Lavreniuk, and O. Kussul. 2016. "Efficiency Assessment of Multitemporal C-band Radarsat-2 Intensity and Landsat-8 Surface Reflectance Satellite Imagery for Crop Classification in Ukraine." *IEEE J. Selected Topics in Appl. Earth Observ and Remote Sens.* 9(8), 3712–3719.
- [19] Ulaby, F.T., R.Y. Li, and K.S. Shanmugan. 1982. "Crop Classification Using Airborne Radar and Landsat Data." *IEEE Tran. Geosci. Remote Sens.* (1), 42–51.
- [20] Brisco, B., and R.J. Brown. 1995. "Multidate SAR/TM Synergism for Crop Classification in Western Canada." *Photogrammetric Eng. Remote Sens.* 61(8), 1009–1014.
- [21] Ban, Y. 2003. "Synergy of Multitemporal ERS-1 SAR and Landsat TM Data for Classification of Agricultural Crops." *Canadian J. Remote Sens.* 29 (4), 518–526.
- [22] Choudhury, I., and M. Chakraborty. 2004. "Analysis of Temporal SAR and Optical Data for Rice Mapping." *J. Indian Soc. Remote Sens.* 32(4), 373–385.
- [23] McNairn, H., J. Shang, X. Jiao, and C. Champagne. 2009b. "The Contribution of ALOS PALSAR Multipolarization and Polarimetric Data to Crop Classification." *IEEE Tran. Geosci. Remote Sens.* 47(12), 3981–3992.
- [24] Larrañaga, A., J. Álvarez-Mozos, and L. Albizua. 2011. "Crop Classification in Rain-Fed and Irrigated Agricultural Areas Using Landsat TM and ALOS/PALSAR Data." *Canadian J. Remote Sens.* 37(1), 157–170.
- [25] Hütt, C., W. Koppe, Y. Miao, and G. Bareth. 2016. "Best Accuracy Land Use/Land Cover (LULC) Classification to Derive Crop Types Using Multitemporal, Multisensor, and Multi-Polarization SAR Satellite Images." *Remote Sens.* 8(8), 684.
- [26] Waske, B., and S. Van Der Linden. 2008. "Classifying Multilevel Imagery from SAR and Optical Sensors by Decision Fusion." *IEEE Tran. Geosci. Remote Sens.* 46(5), 1457–1466.
- [27] Kussul, N., G. Lemoine, F. J. Gallego, S. V. Skakun, M. Lavreniuk, and A. Y. Shelestov. 2016. "Parcel-Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data." *IEEE J. Selected Topics in Appl. Earth Observ. and Remote Sens.* 9(6), 2500–2508.
- [28] Navarro, A., J. Rolim, I. Miguel, J. Catalão, J. Silva, M. Painho, and Z. Vekerdy. 2016. "Crop Monitoring Based on SPOT-5 Take-5 and Sentinel-1A Data for the Estimation of Crop Water Requirements." *Remote Sens.* 8(6), 525.
- [29] Park, S., and J. Im. 2016. "Classification of Croplands Through Fusion of Optical and SAR Time Series Data." *ISPRS-International Archives of the Photogrammetry, Remote Sens. Spa. Inf. Sci.* 703–704.
- [30] Wang, X.Y., Y.G. Guo, J. He, and L.T. Du. 2016b. "Fusion of HJ1B and ALOS PALSAR Data for Land Cover Classification Using Machine Learning Methods." *Int. J. App. Earth Observ. Geoinf.* 52, 192–203.
- [31] Polikar, R. 2006. "Ensemble Based Systems in Decision Making." *IEEE Circuits and Systems Mag.* 6(3), 21–45.
- [32] Du, P., J. Xia, W. Zhang, K. Tan, Y. Liu, and S. Liu. 2012. "Multiple Classifier System for Remote Sensing Image Classification: A Review." *Sens.* 12(4), 4764–4792.
- [33] Mountrakis, G., J. Im, and C. Ogole. 2011. "Support Vector Machines in Remote Sensing: A Review." *ISPRS J. Photogrammetry and Remote Sens.* 66(3), 247–259.
- [34] Khosravi, I., and M. Akhondzadeh. 2014. "The Use of Multiple Classifier Systems for Improving the Classification Accuracy of High-Dimensional Fully Polarimetric SAR Images." *Engineering Journal of Geospatial Information Technology*, 2(3), 69–84.
- [35] Blaes, X., L. Vanhalle, and P. Defourny. 2005. "Efficiency of Crop Identification Based on Optical and SAR Image Time Series." *Remote Sens. Environ.* 96(3), 352–365.
- [36] Forkuor, G., C. Conrad, M. Thiel, T. Ullmann, and E. Zoungrana. 2014. "Integration of Optical and Synthetic Aperture Radar Imagery for Improving Crop Mapping in Northwestern Benin, West Africa." *Remote Sens.* 6(7), 6472–6499.
- [37] Breiman, L. 2001. "Random forests." *Machine Learning* 45(1), 5–32.
- [38] Khosravi, I., A. Safari, S. Homayouni, and H. McNairn. 2017. "Enhanced Decision Tree Ensembles for Land Cover Mapping from Fully Polarimetric SAR Data." *Int. J. Remote Sens.* 38(23), 7138–7160.
- [39] Rodriguez, J.J., L.I. Kuncheva, and C.J. Alonso. 2006. "Rotation Forest: A New Classifier Ensemble Method." *IEEE Trans. Pattern Anal. Mach. Intell.* 28(10), 1619–1630.

- [40] Senliol, B., G. Gulgezen, L., Yu, and Z. Cataltepe. 2008. "Fast Correlation Based Filter (FCBF) with a Different Search Strategy." In Int. Symp. on Comp. Inf. Sci. 27–29.
- [41] McNairn, H., T. J. Jackson, G. Wiseman, S. Belair, A. Berg, P. Bullock, A. Colliander, M.H. Cosh, S.-B. Kim, R. Magagi, and M. Moghaddam. 2015. "The Soil Moisture Active Passive Validation Experiment 2012 (SMAPVEX12): Prelaunch calibration and validation of the SMAP soil moisture algorithms." IEEE Tran. Geosci. Remote Sens. 53(5), 2784–2801.
- [42] Schuster, C., M. Förster, and B. Kleinschmit. 2012. "Testing the Red Edge Channel for Improving Land-Use Classifications Based on High-Resolution Multi-Spectral Satellite Data." Int. J. Remote Sens. 33(17), 5583–5599.