



سنجش از دور

GIS ایران



سنجش از دور و GIS ایران سال چهاردهم، شماره دوم، تابستان ۱۴۰۱
Vol.14, No. 2, Summer 2022 Iranian Remote Sensing & GIS

۱۹-۳۶
مقاله پژوهشی

طراحی و اجرای الگوریتم آدابوست عارضه‌مبنا مبتنی بر یادگیری فعال به‌منظور طبقه‌بندی پوشش زمین در تصاویر با حد تفکیک مکانی بالا

مینا حمیدی^۱، حمید عبادی^۲، عباس کیانی^{۳*}

۱. کارشناس ارشد سنجش از دور، دانشکده نقشه‌برداری، دانشگاه خواجه نصیرالدین طوسی
۲. استاد دانشکده مهندسی نقشه‌برداری، عضو قطب علمی فناوری اطلاعات مکانی، دانشگاه صنعتی خواجه نصیرالدین طوسی
۳. استادیار دانشکده عمران، دانشگاه صنعتی نوشیروانی بابل

تاریخ پذیرش مقاله: ۱۴۰۰/۰۸/۱۶

تاریخ دریافت مقاله: ۱۳۹۹/۱۰/۲۴

چکیده

با بهبود حد تفکیک مکانی تصاویر سنجش از دور، اطلاعات دقیق‌تری از صحنه تصویر همچون ساختارهای بافت، فراهم شده است. این منابع داده، به دلیل جزئیات بسیار، دارای واریانس درون‌کلاسی زیاد و واریانس بین‌کلاسی اندک‌اند؛ از این رو استخراج اطلاعات پوشش زمین از آنها به فرایندی چالش‌برانگیز تبدیل شده است. در این تصاویر، تفسیر بصری زمان‌بر و پرهزینه است و تفسیر اتوماتیک آنها لزوماً به دقت بالا منجر نمی‌شود و رسیدن به دقت تفسیر مطلوب نیازمند طراحی الگوریتم‌های اتوماتیک است؛ به‌صورتی که توانایی مقابله با مشکلات ناشی از پیچیدگی صحنه تصویر را داشته باشند. برای غلبه بر این مشکل، روش آنالیز عارضه‌مبنای تصویر که به مورفولوژی صحنه تصویر حساس است، به‌ویژه در مطالعه‌های شهری که تراکم ساختارهای شکل‌گرفته به‌دست انسان بالاست، ممکن است کارآمد باشد. در طبقه‌بندی عارضه‌مبنا، پیکسل‌های بیانگر یک عارضه در ترکیب با یکدیگر، تجزیه و تحلیل می‌شوند؛ در نتیجه، فضای مسئله به‌نسبت طبقه‌بندی پیکسل‌مبنا کاهش می‌یابد و مزیت این امر افزایش سرعت محاسبات است. در عین حال به دلیل اندازه متنوع اشیای تصویری، طبقه‌بندی نظارت‌شده عارضه‌مبنا در ایجاد مجموعه آموزشی بهینه با چالش‌هایی مواجه است. در تحقیق حاضر، به‌منظور طبقه‌بندی عارضه‌مبنا، از الگوریتم آدابوست استفاده شده است. برای غلبه بر مشکل فقدان تناسب فضای ویژگی ناشی از تعداد اندک نمونه‌های آموزشی و توزیع نامتناسب آنها در مقایسه با ابعاد بالای فضای ویژگی (شامل ویژگی‌های طیفی، مکانی و هندسی)، دو راهبرد دنبال شده است. در یک رویکرد برای تولید مجموعه آموزشی بهینه، مکانیسم یادگیری فعال با الگوریتم آدابوست ادغام شده و در رویکردی دیگر به‌منظور کاهش ابعاد فضای ویژگی، براساس همبستگی بین ویژگی‌ها (افزونگی) و همبستگی بین ویژگی‌ها و کلاس‌ها (مطابقت)، زیرمجموعه ویژگی منتخب استخراج شده است. روش پیشنهادی روی مجموعه داده استاندارد وهینگن کشور آلمان اجرا و نتایج حاصل از آن با طبقه‌بندی پیکسل‌مبنا مقایسه شده است. به‌منظور بررسی معنی‌داری اختلاف‌های حاصل‌شده در نتایج ارزیابی‌ها نیز، آزمون آماری مک‌نمار به‌کار رفته است. نتایج تجربی نشان دادند که رویکرد عارضه‌مبنای پیشنهادی، در قیاس با رویکرد پیکسل‌مبنا، به‌طور متوسط ۶٪ دقت کلی و ۷٪ ضریب کاپا را بهبود داده است. همچنین سرعت محاسبات در روش آدابوست عارضه‌مبنای پیشنهادی، در مقایسه با رویکرد پیکسل‌مبنا افزایش چشمگیری یافته است. این نتایج بیانگر عملکرد بهینه رویکرد پیشنهادی، هم از نظر دقت و هم از نظر سرعت محاسبات است.

کلیدواژه‌ها: طبقه‌بندی، تصاویر حد تفکیک بالا، آدابوست، عارضه‌مبنا، یادگیری فعال.

* نویسنده مکاتبه‌کننده: دانشکده عمران، دانشگاه صنعتی نوشیروانی بابل. تلفن: ۰۹۱۱۳۲۰۲۶۳۶

۱- مقدمه

ترکیب با چند نوع الگوریتم یادگیری متفاوت، استفاده کرد (Chen et al., 2017). آنالیز دقیق آدابوست را می‌توان در پژوهش‌های فروند^۲ و شاپیر^۳ (۱۹۹۷)، دافی^۴ و هلمبولد^۵ (۲۰۰۰) میسن^۶ و همکاران (۲۰۰۰) یافت.

تحقیقات در زمینه مطالعه آدابوست، در سنجش از دور نیز، کارآمدی آن را گزارش کرده‌اند. در پژوهش آگراوال^۷ و نگوتشی^۸ (۲۰۱۶)، با قطعه‌بندی حدآستانه^۹، تصویر دارای حد تفکیک مکانی بالا به دو بخش عوارض طبیعی و مصنوعی تقسیم و با استفاده از آدابوست، طبقه‌بندی شده است. نتایج ارزیابی‌ها، در مقایسه با طبقه‌بندی ماشین بردار پشتیبان^{۱۰}، بهبود صحت را نشان می‌دهد اما این تحقیق فاقد تحلیل و ارزیابی جامع با هدف دستیابی به نتیجه‌گیری مورد اطمینان است. در مطالعه‌ای دیگر، به‌منظور طبقه‌بندی داده‌لیدار تلفیق شده با تصویر هوایی، الگوریتم AdaBoost.MH^{۱۱} و پس‌پردازش BFS^{۱۲} استفاده شد (Prasvita & Arymurthy, 2017). این تحقیق، در مقایسه با پژوهش مشابه خود با استفاده از روش RF^{۱۳}، افزایش دقت متوسط از ۹۰/۴٪ به ۹۴/۹۶٪ را گزارش کرده است. در تحقیق دو^{۱۴} و همکاران (۲۰۱۸)، الگوریتم طبقه‌بندی چندگانه براساس آدابوست^{۱۵} روی تصویر چندطیفی پیشنهاد شده است که طی آن، درخت تصمیم C4.5،

سنجش از دور در زمینه‌های گسترده‌ای، همچون مدیریت شهری و پایش محیط‌زیست، کاربرد دارد (Jia, 2015). طبقه‌بندی تصاویر سنجش از دور حوزه اصلی تحقیقات نقشه‌برداری اتوماتیک است. در چند دهه اخیر، با ظهور تصاویر با حد تفکیک مکانی بالا، آنالیز عارضه‌مبنای تصویر^۱ رشد چشمگیری داشته است (Bui et al., 2019). در تصویر دارای وضوح بالا، پیکسل‌ها بسیار کوچک‌تر از عارضه‌اند؛ بنابراین با تغییر پیکسل‌ها به اشیای تصویری، فضای مسئله کاهش می‌یابد (Kiani et al., 2019). از سویی، در این تصاویر، استفاده صرف از اطلاعات طیفی به طبقه‌بندی‌های نامطلوب منجر می‌شود (Momeni et al., 2016)؛ بنابراین باید ویژگی‌های مکانی مؤثر و داده‌های کمکی در تلفیق با اطلاعات طیفی به کار روند. باین‌حال افزایش تعداد ویژگی‌ها، به دلیل ایجاد مشکلاتی همچون (۱) آموزش بیش‌ازحد الگوریتم طبقه‌بندی ناشی از حضور ویژگی‌های زائد، (۲) ساخت مدل‌های پیچیده و (۳) نیاز به ذخیره‌سازی و پردازش اضافی داده‌ها، ممکن است تأثیراتی منفی در عملکرد طبقه‌بندی داشته باشد (Huang & Zhang, 2012; Georganos et al., 2018). برای غلبه بر این مشکلات، کاهش ابعاد از جمله انتخاب ویژگی، گامی اساسی است (Tamimi et al., 2017).

در دهه‌های اخیر، روش‌های یادگیری ماشین کاربرد گسترده‌ای در طبقه‌بندی داده‌های سنجش از دور داشته‌اند. این الگوریتم‌ها امضای کلاس‌های پیچیده را مدل می‌کنند، داده‌های ورودی گوناگون را می‌پذیرند و فرض‌های مربوط به توزیع داده‌ها را دخیل نمی‌کنند (Maxwell et al., 2018). آدابوست از جمله روش‌های یادگیری ماشین است که ابزار مدل‌سازی ساده و تفسیرپذیری را ارائه می‌دهد و در بسیاری از کاربردها موفق بوده است (Prasvita & Arymurthy, 2017; Viola & Jones, 2004; Heo & Yang, 2014). از آن‌جاکه این روش هم‌زمان با طبقه‌بندی دارای قابلیت انتخاب ویژگی است، بهره‌مندی از آن به‌ویژه در مواجهه با انبوه داده‌ها، گزینه مناسبی به‌شمار می‌رود. همچنین می‌توان آن را در

1. Object Based Image Analysis (OBIA)
2. Freund
3. Schapire
4. Duffy
5. Helmbold
6. Mason
7. Agrawal
8. Nagwanshi
9. Thresholding segmentation
10. Support Vector Machine (SVM)
11. Adaptive Boosting Multi-class Hamming trees
12. Breadth First Search
13. Random Forest (RF)
14. Dou
15. Multiple Classification Algorithm-based AdaBoost (MCA-AdaBoost)

ارزیابی می‌شود. به‌طور کلی الگوریتم‌های انتخاب ویژگی متفاوت، از نظر دقت و تعداد ویژگی‌های انتخابی، نتایج متفاوتی برای طبقه‌بندی عارضه‌مبنا فراهم می‌کنند؛ از این رو هیچ روش استاندارد در مورد انتخاب ویژگی در OBIA وجود ندارد و این مسئله همچنان چالش‌برانگیز است.

اصلی‌ترین و مهم‌ترین نکته، در طبقه‌بندی عارضه‌مبنای آدابوست، انتخاب ویژگی ناصحیح و طبقه‌بندی نامناسب ناشی از نبود تناسب فضای ویژگی است که به دلیل تعداد اندک و توزیع نامتناسب قطعات آموزشی رخ می‌دهد. یکی از راه‌حل‌های مطرح‌شده در زمینهٔ بینایی ماشین^۹ ادغام مکانیسم یادگیری فعال^{۱۰} با الگوریتم آدابوست، به‌منظور بهبود عملکرد طبقه‌بندی هنگام مواجهه با نمونه‌های آموزشی نامتناسب است (Li et al., 2004). در تحقیق حاضر، راهبرد انتخاب نمونه‌های بهینه و توسعهٔ مجموعهٔ آموزشی براساس نزدیک‌ترین نمونه به ابرصفحهٔ بهینه^{۱۱} آدابوست پیشنهاد شده است. این راهبرد برپایهٔ تفسیر هندسی آدابوست در فضای نسخه^{۱۲} انتخاب شده و تحقیق لی^{۱۳} و همکاران (۲۰۰۴)، با توجه به کارآمد بودن نتایج آن، الهام‌بخش پژوهش پیش رو بوده است. از این رو در تحقیق حاضر، به‌منظور طبقه‌بندی عارضه‌مبنای آدابوست، براساس مکانیسم یادگیری فعال، معیار آنتروپی برای انتخاب نمونه‌های بهینه با بیشترین عدم قطعیت پیشنهاد شده است که نزدیک‌ترین نمونه‌ها به

ANN^۱ و NB^۲ به‌منزلهٔ یادگیرنده‌های پایهٔ آدابوست به‌کار رفتند. نتایج نشان داد که این روش، به‌دلیل استفاده از یادگیرنده‌های پایهٔ متنوع، انعطاف‌پذیرتر از آدابوست اصلی است اما احتمالاً هزینهٔ محاسباتی بالایی داشته باشد.

ما^۳ و همکاران (۲۰۱۷) بررسی جامعی، در زمینهٔ تحقیقات سنجش از دوری، روی فرایند طبقه‌بندی نظارت‌شدهٔ عارضه‌مبنا انجام داده‌اند. طبق این بررسی‌ها، بین دقت طبقه‌بندی و اندازهٔ مجموعهٔ آموزشی همبستگی قدرتمندی وجود دارد. بدین ترتیب مرحلهٔ انتخاب مجموعهٔ آموزشی گام مهمی در فرایند طبقه‌بندی نظارت‌شده می‌باشد؛ درحالی‌که از میان ۲۵۴ منطقهٔ مطالعاتی مورد بررسی، فقط ۸۸ مورد به بیان روش نمونه‌برداری پرداخته‌اند. نتایج نشان می‌دهد که به این مرحله از پردازش، ضمن تحقیقات در زمینهٔ طبقه‌بندی نظارت‌شدهٔ عارضه‌مبنا، توجه کافی نشده است. علاوه‌براین به بهینه‌سازی قطعات آموزشی نمونه‌برداری‌شده بسیار کم پرداخته شده است (Dronova et al., 2011; Pérez-Ortiz et al., 2016). ایشان، در بررسی مطالعات از منظر انتخاب ویژگی نیز، مشاهده کردند که روش‌های انتخاب ویژگی بیشتر شامل ارزیابی اهمیت ویژگی‌ها و زیرمجموعهٔ ویژگی می‌شود. در روش نخست، می‌توان ویژگی‌ها را طبق اهمیت آنها رتبه‌بندی کرد؛ درحالی‌که روش دوم می‌تواند مستقیماً به زیرمجموعهٔ ویژگی‌های بهینه دست یابد. لالیبرت^۴ و همکاران (۲۰۱۲) سه روش انتخاب ویژگی شامل JM^۵، CTA^۶ و FSO^۷ را به‌منظور طبقه‌بندی عارضه‌مبنا با KNN^۸، روی پنج تصویر مطالعاتی ارزیابی کردند. طبق نتایج ارزیابی آنها، روش JM در مورد سه تصویر و روش CTA در مورد دو تصویر دقت‌های بالایی حاصل کردند اما روش CTA در زمینهٔ کاربرد خاص این تحقیق بهترین شیوه بود زیرا مزایایی چون سهولت استفاده و قابلیت رتبه‌بندی دارد؛ درحالی‌که در روش JM فقط فواصل تفکیک کلاس‌ها

1. Artificial Neural Network
2. Naive Bayes
3. Ma
4. Laliberte
5. Jeffreys–Matusita distance
6. Classification Tree Analysis
7. Feature Space Optimization
8. K-Nearest Neighbor
9. Computer Vision
10. Active Learning
11. Optimal Hyperplane
12. Version Space
13. Li

مدل رقومی سطح نرمال سازی شده و تصویر واقعیت زمینی آنها نشان داده شده است. به منظور طبقه بندی پوششی، در تصویر آزمون ۱ (شکل ۱-الف)، شش کلاس هدف و در تصویر آزمون ۲ (شکل ۱-ب)، پنج کلاس در نظر گرفته شده است. برای تولید ویژگی های کارآمد نیز، تصویر هوایی و داده ارتفاعی منطقه تلفیق شده اند.

۲-۲- قطعه بندی تصویر

هدف از قطعه بندی تقسیم تصویر به نواحی یکنواخت بدون هم پوشانی با یکدیگر است؛ به این نواحی، در اصطلاح، شیء تصویری گفته می شود (Fan et al., 2005). برای قطعه بندی تصاویر، الگوریتم های متنوعی وجود دارد که در این تحقیق، برای ایجاد قطعات همگن با استفاده از نرم افزار eCognition، از الگوریتم قطعه بندی چندسطحی^۵ به منزله یکی از مناسب ترین روش ها استفاده شده است. یکی از اهداف این روش ارائه هم زمان اشیای تصویری با مقیاس های متفاوت است. تمامی ویژگی های اشیای تصویری، از جمله رنگ (طیف)، بافت یا شکل، تا حدودی به مقیاس بازمی گردد. عدد مقیاس ابعاد شیء های تصویری را کنترل می کند که مقدار بزرگ آن سبب کاهش تعداد شیء های تصویری و افزایش مساحت آنها می شود (Batz, 2000; Definiens, 2007).

۲-۳- تولید ویژگی

در این تحقیق، به دلیل پیچیدگی های ساختاری و طیفی صحنه تصویر و حد تفکیک بالای داده مورد استفاده، لزوم به کارگیری ویژگی های طیفی، مکانی، هندسی و ارتفاعی به منظور طبقه بندی دقیق تصویر احساس می شود. یکی از ویژگی های مکانی که در کنار


مرز تصمیم گیری آدابوست محسوب می شوند. در رویکردی دیگر نیز، برای کاهش ابعاد فضای ویژگی، راهبرد تولید زیرمجموعه ویژگی منتخب^۱ مبتنی بر همبستگی بین ویژگی ها (افزونگی)^۲ و همبستگی بین ویژگی ها و کلاس ها (مطابقت)^۳ پیشنهاد شده است. سپس بین نتایج این دو رویکرد و نیز شرایط اولیه مسئله، مقایسه ای صورت گرفته است. افزون بر این رویکرد پیکسل مینا نیز، به منظور فراهم سازی ارزیابی مقایسه ای، بررسی و آزموده شده است. نتایج بیان می کند روش عارضه مبنای پیشنهادی، ضمن افزایش دقت، سرعت مطلوبی نیز دارد.

۲- مواد و روش ها

۲-۱- مشخصات داده های مورد استفاده

مجموعه داده مورد استفاده در تحقیق داده ایتیک با حد تفکیک مکانی بالا و داده ارتفاعی منطقه وهینگن^۴ در آلمان است که از سوی کمیسیون سه گروه کاری چهار جامعه بین المللی فتوگرامتری و سنجش از دور، آماده شده است (ISPRS, 2013). تصاویر هوایی منطقه با استفاده از دوربین دیجیتالی Intergraph/ZI DMC و با فاصله کانونی ۱۲۰ میلی متر، از ارتفاع نهصدمتری گرفته شده اند که حد تفکیک مکانی ۸ سانتی متر و سه باند طیفی مادون قرمز IR، قرمز R و سبز G دارند. از روی تصاویر هوایی اصلی، مدل رقومی سطح و ارتوفتوموزائیک واقعی نیز تهیه شده است. در تهیه این دو نوع داده، از شبکه ای با دقت مکانی ۹ سانتی متر استفاده شده است. این دو مجموعه داده، به منظور استفاده یک جا از آنها، زمین مرجع و هم مرجع شده اند و نیازی به تصحیحات هندسی و رادیومتریکی ندارند. داده ارتفاعی به کاررفته در این تحقیق، مدل رقومی سطح نرمال سازی شده (nDSM) است که همین گروه آن را تهیه کرده است. به منظور سنجش دقت روش پیشنهادی، به داده مرجع نیاز است که گروه مورد نظر آن را به صورت دستی برچسب گذاری معنایی کرده است. در شکل ۱، تصاویر هوایی محدوده مطالعاتی،

1. Candidate Feature Subset (CFS)
2. Redundancy
3. Relevance
4. Wehingen
5. Multi-Resolution Segmentation



شکل ۱. منطقه مطالعاتی، وهینگن آلمان

شبه‌عمیق نام دارد (Tokarczyk et al., 2015). مجموعه شبه‌عمیق شامل ویژگی‌های گسترده‌ای است و از طریق پنجره‌ای متحرک، به منزله واحد پایه، تولید می‌شود که پیکسل به پیکسل روی تصویر جابه‌جا می‌شود. ابعاد پنجره متحرک را می‌توان از 3×3 تا 25×25 در نظر گرفت که به قدرت تفکیک تصویر و اندازه اشیای تصویری بازمی‌گردد. این مجموعه ویژگی، به‌طور طبیعی، قادر است طیف وسیع مقیاس‌ها و فرکانس‌های بافت را پوشش دهد. این شیوه از مزایای اطلاعات رنگ، از طریق اختلاف یا نسبت بین باندهای طیفی، بهره می‌برد (Hamidi et al., 2018).

به‌علاوه، با توجه به تصویر قطعه‌بندی شده و ویژگی‌های اشیای تصویری، ویژگی‌های هندسی تصاویر با استفاده از نرم‌افزار eCognition استخراج شد. در این تحقیق، یازده ویژگی شکل اشیای تصویری شامل مساحت، طول، عرض، نسبت طول به عرض، شاخص شکل، شاخص مرز، چگالی، نداشتن تقارن، طول مرز، تناسب مستطیلی، فشردگی و نیز ده ویژگی طیفی اشیای شامل میزان روشنایی، بیشترین اختلاف مقادیر باندهای

اطلاعات طیفی، می‌تواند باعث افزایش دقت طبقه‌بندی شود، ویژگی بافت است. بافت نحوه توزیع مکانی پیکسل‌های گوناگون است که برای استخراج آن از تصاویر، روش‌های متنوعی وجود دارد. ماتریس هم‌رخداد درجات خاکستری^۱ یک رویکرد آماری کلاسیک استخراج بافت است که در آن، بافت‌ها براساس روش‌های آماری توصیف می‌شوند. از جمله پرکاربردترین ویژگی‌های قابل استخراج از ماتریس GLCM، می‌توان به کنتراست، فقدان شباهت، آنتروپی، میانگین، واریانس، همگنی، وابستگی و ممان مرتبه دوم اشاره کرد (Haralick et al., 1973).

در چند سال اخیر، روش‌های یادگیری عمیق نتایج خوبی در کاربردهای گوناگون بینایی ماشین در پی داشته‌اند و به‌تازگی در حوزه سنجش از دور نیز وارد شده‌اند. یادگیری عمیق قادر است با انواع بافت سازگاری خودکار بیابد که در آن، استخراج‌گرهای ویژگی مستقیماً آموزش داده می‌شوند اما این روش، در برابر تنظیمات، شکننده است و اغلب نتایج آن، در مقایسه با بانک‌های فیلتر ساده، بهبود نمی‌یابد؛ از این‌رو روش مشابهی مطرح شد که همانند روش‌های عمیق، ویژگی‌ها را براساس پچ^۲ استخراج می‌کند و نیز مزیت سادگی بانک‌های فیلتر متداول را دارد. این روش

1. Gray Level Co-occurrence Matrix (GLCM)
2. Patch

طبقه‌بندی‌کننده‌های پایه، به‌درستی طبقه‌بندی شده و مقدار حاشیه ۱- نشان‌دهنده طبقه‌بندی اشتباه است. حاشیه طبقه‌بندی‌کننده‌ها در تکرارهای آداپوست طبق رابطه (۱) محاسبه می‌شود.

$$\text{Margin}(x_i, y_i) = \rho_i = \frac{y_i \sum_{j=1}^T \alpha_j \cdot h_j(x_i)}{\sum_{j=1}^T \alpha_j} \quad (1)$$

در این رابطه، ρ_i بیانگر مقدار حاشیه نمونه x_i ، y_i بیانگر برچسب واقعی نمونه x_i ، T تعداد تکرار آداپوست، h_j طبقه‌بندی‌کننده ضعیف در تکرار j ام و α_j وزن طبقه‌بندی‌کننده j ام است. نظریه آداپوست ابتدا در مورد مسئله دوکلاسه مطرح شد. شاپیر و سینگر^۱ (۱۹۹۹)، با ارائه توسعه چندکلاسه با نام MH، موفقیت شایان توجهی به‌دست آوردند. هدف الگوریتم MH یافتن تابع تمایز برداری^۲ با مینیمم تابع ضرر همینگ^۳ به‌نحوی است که خطای وزن‌دار حاشیه‌مینا^۴ حداقل شود. رابطه (۲) تابع ریسک نمایی الگوریتم MH را نشان می‌دهد.

$$\hat{R}_{exp}(f^T, w) = \frac{1}{N} \sum_{i=1}^N \sum_{l=1}^k w_{i,l} e^{-(f_i^T(x_i) y_{i,l})} \quad (2)$$

الگوریتم MH تابع تمایز نهایی را با استفاده از جمع طبقه‌بندی‌کننده‌های پایه $h^t: X \rightarrow R^k$ به‌صورت رابطه (۳) ایجاد می‌کند.

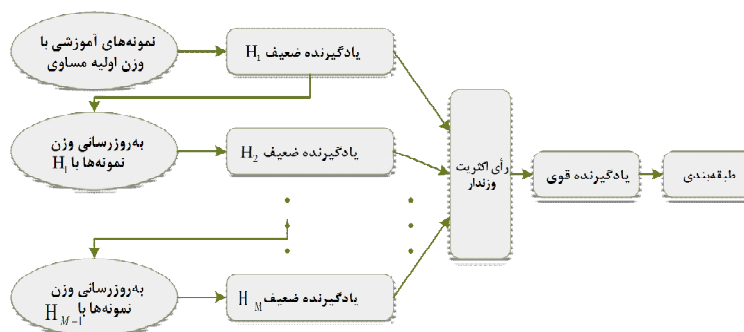
$$f^T(x) = \sum_{t=1}^T h^t(x) \quad (3)$$

طیفی، میانگین طیفی در چهار لایه (R, G, IR,) و انحراف معیار در چهار لایه نیز استفاده شد (Baatz et al., 2004).

۲-۴- الگوریتم آداپوست

روش آداپوست (بوستینگ تطبیقی) محبوب‌ترین شیوه از میان انواع بوستینگ است. بوستینگ، با هدف بهبود دقت طبقه‌بندی، گروهی از طبقه‌بندی‌کننده‌های ضعیف را به طبقه‌بندی‌کننده‌ای قوی (با دقت بالا) تبدیل می‌کند. آداپوست الگوریتم یادگیری پایه را به‌طور متوالی، به نسخه‌های وزن داده‌های آموزشی اعمال می‌کند تا مجموعه‌ای از توابع فرضیه، با نام یادگیرنده ضعیف تولید گردد که در نهایت، با استفاده از یک رأی اکثریت وزن‌دار برای تشکیل یادگیرنده قوی ترکیب می‌شوند (Freund & Schapire, 1997). در شکل ۲، ساختار گرافیکی الگوریتم آداپوست نشان داده شده است.

برای اشاره به اینکه نمونه‌ها تا چه حد صحیح یا اشتباه طبقه‌بندی شده‌اند، از مفهوم حاشیه طبقه‌بندی آداپوست استفاده می‌شود. مقادیر این حاشیه در بازه $[-1, +1]$ قرار دارد. مقدار حاشیه +۱ برای هر نمونه بیان می‌کند که آن نمونه، با استفاده از تمامی



شکل ۲. ساختار گرافیکی الگوریتم آداپوست

1. Singer
2. Vector-Valued Discriminant Function
3. Hamming Loss
4. Margin-Based

$$Z(h, W^t) = \sum_{i=1}^n \sum_{l=1}^k W_{i,l}^t e^{-h_i v_i y_{i,l}} \quad (6)$$

الگوریتم یادگیرنده پایه h با استفاده از رابطه (۷) حاصل می‌شود.

$$h(x) = \alpha v \varphi(x) \quad (7)$$

در این معادله، $\alpha \in \mathbb{R}^+$ بیانگر ضریب پایه، $v \in \{\pm 1\}^k$ نشان‌دهنده بردار رأی و $\varphi(x): x \rightarrow \{\pm 1\}^k$ طبقه‌بندی‌کننده اسکالر است. در طبقه‌بندی چندکلاسه، ممکن است $\varphi(x)$ با برخی از برجسب کلاس‌های y_l همبسته^۶ و با برخی دیگر همبسته^۷ معکوس باشد. این مفهوم با استفاده از آرای باینری $v_l \in \{\pm 1\}$ بیان می‌شود؛ بدین نحو که اگر $v_l = +1$ باشد، $\varphi(x)$ به کلاس l رأی موافق می‌دهد و اگر $v_l = -1$ باشد، رأی مخالف می‌دهد. α بیانگر کیفیت کلی طبقه‌بندی‌کننده $v \varphi(x)$ است که با توجه به میزان خطای وزن‌دار $v \varphi(x)$ ، به‌طور یکنواخت کاهش می‌یابد (هم‌ارز با این مفهوم، با توجه به لبه^۸، $v \varphi(x)$ به‌طور یکنواخت افزایش می‌یابد). میزان خطای وزن‌دار هر کلاس طبق رابطه (۸) و میزان طبقه‌بندی صحیح وزن‌دار هر کلاس با استفاده از رابطه (۹) تعیین می‌شود.

$$\mu_{l-} = \sum_{i=1}^n W_{i,l} I\{\varphi(x_i) \neq y_{i,l}\} \quad (8)$$

$$\mu_{l+} = \sum_{i=1}^n W_{i,l} I\{\varphi(x_i) = y_{i,l}\} \quad (9)$$

بر اساس دو رابطه پیشین، لبه کلی طبقه‌بندی‌کننده مطابق با رابطه (۱۰) محاسبه می‌شود.

$$\gamma = \sum_{l=1}^k \gamma_l = \sum_{l=1}^k v_l (\mu_{l+} - \mu_{l-}) = \sum_{i=1}^n \sum_{l=1}^k W_{i,l} v_l \varphi(x_i) y_{i,l} \quad (10)$$

در نهایت، ضریب α از طریق رابطه (۱۱) به‌دست می‌آید.

$$\alpha = \frac{1}{2} \log \frac{1+\gamma}{1-\gamma} \quad (11)$$

1. Decision Stump
2. Vector-Valued
3. Multi-Class Edge
4. Input-Independent
5. Label-Independent
6. Correlated
7. Anti-Correlated
8. Edge

در این الگوریتم، با فرض وجود N نمونه آموزشی و k کلاس، برجسب کلاس هر نمونه به‌صورت برداری با k مؤلفه (برجسب کلاس مورد نظر $+1$ و بقیه کلاس‌ها -1) در نظر گرفته می‌شود؛ از این‌رو درمورد برجسب کلاس (۷) نمونه‌های آموزشی، ماتریسی با ابعاد $N \times k$ خواهیم داشت. علاوه‌براین وزن نمونه‌های آموزشی (W) نیز، به‌صورت ماتریسی هم‌ابعاد با ماتریس برجسب طبق رابطه (۴) تشکیل می‌شود. این ماتریس وزن، طی تکرارهای الگوریتم یادگیری، به‌روزرسانی می‌شود.

$$W_l = \begin{cases} \frac{1}{2} & \text{if } l = l(x) \text{ (i.e. if } y_l = 1) \\ \frac{1}{2(k-1)} & \text{if } l \neq l(x) \text{ (i.e. if } y_l = -1) \end{cases}$$

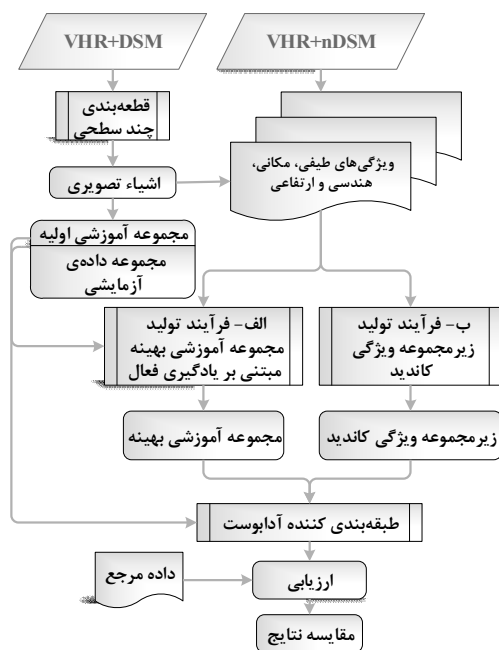
رابطه (۴)

در این رابطه، l بیانگر هر یک از k کلاس است. علت چنین تنظیم وزنی این است که توزیع وزن نمونه‌ها، در ابتدای الگوریتم، یکنواخت باشد. درخت طبقه‌بندی با یک گره و دو برگ که اصطلاحاً استامپ^۱ تصمیم‌نامیده می‌شود، متداول‌ترین انتخاب برای یادگیرنده پایه در آدابوست است. استامپ^۱ تصمیم، مطابق با رابطه (۵)، یک تصمیم‌گیری باینری برای تقسیم نمونه‌های آموزشی به دو کلاس $+1$ و -1 انجام می‌دهد. برای این کار، بهترین ویژگی و حد آستانه با کمترین میزان خطای وزن‌دهی را جست‌وجو می‌کند.

$$\varphi_{j,b}(x) = \begin{cases} 1 & \text{if } x^j \geq b \\ -1 & \text{otherwise} \end{cases} \quad (5)$$

در رابطه مورد اشاره، j اندیس ویژگی انتخابی و b حد آستانه تصمیم است. در چارچوب MH، درختان تصمیم برداری^۲ برای بهینه‌سازی لبه چندکلاسه^۳ مطرح شده است (Kégl, 2013). عنصر اصلی، در این روش، استامپ^۱ تصمیم برداری است که به برداری مستقل از ورودی^۴ با طول k و طبقه‌بندی‌کننده اسکالر مستقل از برجسب^۵ تقسیم می‌شود. هدف یادگیرنده پایه چندکلاسه حداقل‌سازی تابع هدف $Z(h, W)$ است که طبق رابطه (۶) انجام می‌شود. حداقل‌سازی این تابع هدف، در هر تکرار، معادل با حداقل‌سازی خطای وزن‌دار حاشیه‌مبنای بیان‌شده در رابطه (۲) است.

آدابوست در سطح عارضه، با استفاده از مجموعه آموزشی بهینه^۳، آموزش می‌بیند و پس از ارزیابی نتایج حاصل از این طبقه‌بندی با داده مرجع، نتایج این روش با شرایط اولیه مسئله (طبقه‌بندی با مجموعه آموزشی اولیه^۴) مقایسه می‌شود.



شکل ۳. مراحل کلی طرح پیشنهادی

علاوه‌براین، در رویکردی دیگر، از فضای ویژگی اولیه یک زیرمجموعه ویژگی برای معرفی به طبقه‌بندی‌کننده آدابوست انتخاب می‌شود که روند کلی آن در شکل ۴-ب نشان داده شده است. سپس طبقه‌بندی عارضه‌مبنای آدابوست، با استفاده از زیرمجموعه ویژگی منتخب، انجام می‌شود. در نهایت، بین این دو رویکرد ارزیابی مقایسه‌ای صورت می‌گیرد؛ بنابراین درمورد هر دو تصویر مطالعاتی، تصاویر

1. Data Structure
 2. Priority Queue
 3. Opimal Training Data set (OTD)
 4. Initial Training Data set (ITD)
- قطعه‌بندی با مقادیر متفاوت پارامترهای مقیاس (۵۰،

آموزش درخت طبقه‌بندی باینری با n گره داخلی را می‌توان، براساس مبحثی در ساختمان داده‌ها^۱ با عنوان صف اولویت^۲ انجام داد که نوعی حافظه ذخیره‌سازی و بازیابی اطلاعات است (Cormen et al., 2009). در این تحقیق، کلید مورد استفاده برای اولویت‌دهی به عناصر در گره ریشه، لبه درخت و در گره‌های بعدی، برپایه بهبود لبه کلی درخت است. شرط توقف حصول تعداد گره‌های تعیین‌شده از سوی کاربر است که روی سه گره تنظیم شد. اجرای آدابوست چندکلاسه با استفاده از آدابوست باینری نیز انجام شد که خروجی‌های اسکالر برای k مدل طبقه‌بندی مستقل از هم (k بیانگر تعداد کلاس) را در پی دارد.

۳- روش پیشنهادی

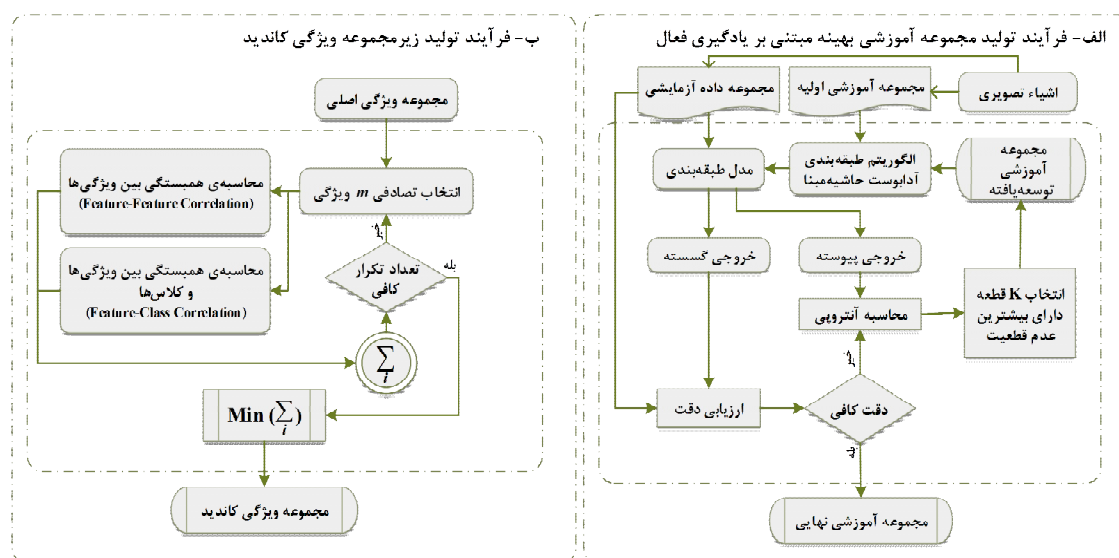
با توجه به اینکه در آدابوست، مینیمم مقدار خطا یا ماکزیمم لبه طبقه‌بندی‌کننده پایه معیار انتخاب ویژگی است، فرایند انتخاب ویژگی و انتخاب فرضیه ضعیف مستقیماً از نمونه‌های آموزشی تأثیر می‌پذیرد. از طرفی، ایده اصلی بوستینگ ترکیب یادگیرنده‌های ضعیف به‌منظور حصول یادگیرنده قوی است؛ با این فرض که یادگیرنده‌های ضعیف صرفاً کمی بهتر از حالت تصادفی باشند و بنابراین، در صورتی که این شرط برقرار نباشد، مدل طبقه‌بندی آدابوست به‌درستی ایجاد نخواهد شد. بر این اساس، طرح پیشنهادی طبقه‌بندی عارضه‌مبنای آدابوست طبق شکل ۳ ارائه شده است.

در این روش پیشنهادی، ابتدا تمامی ویژگی‌های فضای ویژگی اولیه (شامل ویژگی‌های طیفی، مکانی، هندسی و ارتفاعی) و نیز مجموعه نمونه‌های موجود در دو گروه آموزشی و آزمایشی وارد الگوریتم توسعه مجموعه آموزشی می‌شود که مراحل کلی آن در شکل ۴-الف نشان داده شده است. در این الگوریتم، از ایده یادگیری فعال بهره گرفته شده که هدف آن بهینه‌سازی مرز تصمیم‌گیری براساس انتخاب نمونه‌های آموزشی جدید (با عدم قطعیت بالا) در طول چرخه یادگیری است. پس از این مرحله، طبقه‌بندی‌کننده

طبقه‌بندی‌کننده آدابوست حاشیه‌مبنا^۱ مطرح شده است. در نسخه اصلی آدابوست، معیار انتخاب ویژگی در هر تکرار براساس مینیمم مقدار خطای وزن‌دهی ایجادشده از سوی فرضیه‌های ضعیف است. در این تحقیق، ایده انتخاب ویژگی بر مبنای ترکیب ماکزیمم حداقل حاشیه و مینیمم مقدار خطا مطرح شده است. به عبارتی، در هر تکرار آدابوست، یک ویژگی از میان تمامی ویژگی‌ها به نحوی انتخاب می‌شود که هم‌زمان با کمینه‌کردن میزان خطای وزن‌دهی، حداقل حاشیه طبقه‌بندی را بیشینه کند. همچنین، از حاشیه طبقه‌بندی آدابوست به‌منزله شرط توقف الگوریتم یادگیری بهره گرفته شده است؛ بدین صورت که الگوریتم یادگیری، تا زمانی که حاشیه طبقه‌بندی مثبت شود، ادامه می‌یابد. مثبت‌شدن حاشیه طبقه‌بندی‌کننده آدابوست بدین معنی است که تمامی نمونه‌ها به درستی طبقه‌بندی شده‌اند. هدف از این ایده حذف تک‌پارامتر تنظیمی آدابوست (تعداد تکرار) است که سطح اتوماسیون و سرعت الگوریتم یادگیری را افزایش می‌دهد.

۸۰ و ۱۰۰) و شکل (۰/۱، ۰/۳ و ۰/۵) و با مقدار ثابت فشردگی ۰/۵ آزموده شد؛ درمورد تصویر آزمون ۱، تصویر قطعه‌بندی با مقدار مقیاس ۵۰ و شکل ۰/۱ و درمورد تصویر آزمون ۲، قطعه‌بندی با مقدار مقیاس ۵۰ و شکل ۰/۳ بهترین خروجی را دربر داشت. نمونه‌برداری از تصاویر نیز بدین‌گونه انجام شد که ۰/۱ از داده واقعی زمینی برای نمونه‌های آموزشی و ۰/۹ آن به‌منزله داده آزمایشی در نظر گرفته شد. از سویی، با ادغام تمامی ویژگی‌ها درمورد هر دو تصویر مطالعاتی، ۵۸۵ ویژگی برای ورود به مرحله طبقه‌بندی آماده‌سازی شد. در اجرا، از سه نسخه Ada (نسخه اولیه آدابوست)، MH-Stump (یادگیرنده پایه: استامپ تصمیم) و MH-Tree (یادگیرنده پایه: درخت تصمیم) استفاده شده است.

طبق شکل ۴، فرایند تولید مجموعه آموزشی بهینه مبتنی بر یادگیری فعال طبقه‌بندی عارضه‌مبنای آدابوست با استفاده از مجموعه آموزشی اولیه انجام می‌شود. در این فرایند، ایده



شکل ۴. روندنمای کلی فرایند توسعه مجموعه آموزشی و فرایند تولید زیرمجموعه ویژگی منتخب، بنا به پیشنهاد تحقیق

1. Margin-Based AdaBoost

ویژگی‌ها و کلاس‌ها با استفاده از نمونه‌های درون کلاسی و بین کلاسی، طبق رابطه (۱۳) و همبستگی بین ویژگی‌ها، با استفاده از ضریب همبستگی پیرسون^۱ و اطلاعات متقابل^۲، طبق روابط (۱۴) و (۱۵) به دست می‌آید.

$$CS = \frac{\sum_{(x_i, x_j) \in \Omega_{ML}} (f_{ri} - f_{rj})^2}{\sum_{(x_i, x_j) \in \Omega_{CL}} (f_{ri} - f_{rj})^2} \quad \text{رابطه (۱۳)}$$

$$\rho(f_r, f_c) = \frac{\sum_i (f_{ri} - \bar{f}_r)(f_{ci} - \bar{f}_c)}{\sqrt{\sum_i (f_{ri} - \bar{f}_r)^2 \sum_i (f_{ci} - \bar{f}_c)^2}} \quad \text{رابطه (۱۴)}$$

$$MI = -\frac{1}{2} \log(1 - \rho^2(f_r, f_c)) \quad \text{رابطه (۱۵)}$$

در رابطه (۱۳)، صورت کسر بیانگر مجموع فاصله نمونه‌های متعلق به یک کلاس (درون کلاسی) از یکدیگر در فضای ویژگی و مخرج کسر بیانگر مجموع فاصله نمونه‌های متعلق به کلاس‌های متفاوت (بین کلاسی) از یکدیگر در فضای ویژگی است. با توجه به اینکه فضای ویژگی ایده‌آل فضایی است که در آن واریانس درون کلاسی پایین و واریانس بین کلاسی بالا باشد، در این رابطه، هرچه مقدار صورت کسر کوچک‌تر و مقدار مخرج کسر بزرگ‌تر باشد، به فضای ویژگی ایده‌آل نزدیک‌تر است؛ بنابراین هرچه مقدار این کسر کوچک‌تر باشد، نشان‌دهنده همبستگی و ارتباط بیشتر ویژگی‌ها و کلاس‌هاست. رابطه (۱۴) ضریب همبستگی پیرسون را بیان می‌کند که در آن، \bar{f}_r و \bar{f}_c به ترتیب به مقدار میانگین بردار داده مربوط به ویژگی r و c اشاره دارد. پس از محاسبه ضریب همبستگی بین دو ویژگی، با استفاده از رابطه (۱۵)، اطلاعات متقابل بین آنها تعیین می‌شود؛ هرچه مقدار آن کوچک‌تر باشد، یعنی وابستگی دو ویژگی به هم کمتر است. پس از محاسبه پارامترهای یادشده و میانگین‌گیری بین مقادیر به دست آمده در مورد ویژگی‌های موجود در یک زیرمجموعه ویژگی، از میان تمامی زیرمجموعه‌های تولیدشده تصادفی، زیرمجموعه ویژگی منتخب

پس از طبقه‌بندی اولیه به روش آدابوست حاشیه‌مبنا، مجموعه داده آزمایشی بر مدل طبقه‌بندی اعمال می‌شود؛ از خروجی گسسته آن به منزله معیار توقف چرخه یادگیری و از خروجی پیوسته آن به منظور انتخاب نمونه‌های آموزشی بهینه استفاده شده است. خروجی‌های پیوسته را می‌توان به صورت احتمال تعلق به هر کلاس تفسیر کرد. با استفاده از پارامترهای قابل استخراج از بردار احتمالات، می‌توان عدم قطعیت طبقه‌بندی اجزای تصویر را آنالیز کرد. در این پژوهش، از معیار آنتروپی (میزان تصادفی بودن پدیده‌ها) طبق رابطه (۱۲) استفاده شده است.

$$H(x) = -\sum_{i=1}^k P(x_i) \log_2 P(x_i) \quad \text{رابطه (۱۲)}$$

در این معادله، $P(x_i)$ احتمال تعلق به هر کلاس برای k کلاس را نشان می‌دهد. هرچه مقدار آنتروپی بیشتر باشد، میزان عدم قطعیت نیز بیشتر خواهد بود و برعکس. از آن‌جا که هدف الگوریتم یادگیری فعال یافتن طبقه‌بندی‌کننده بهینه است، با در نظر گرفتن نمونه‌های دارای عدم قطعیت بالا که مرز تصمیم‌گیری طبقه‌بندی‌کننده ایجادشده در تکرار پیشین را دچار تغییر می‌کنند، دستیابی به این هدف برای آن فراهم می‌شود. پس از آن، قطعات آموزشی منتخب از مجموعه داده آزمایشی به مجموعه آموزش قبلی افزوده می‌شوند. چرخه یادگیری در این سیستم، تا زمان رسیدن به دقت کافی، ادامه می‌یابد. دقت کافی برحسب تعداد تکراری تعیین می‌شود که سیستم یادگیری می‌تواند بدون ازدست‌دادن عملکرد بهینه‌اش، داشته باشد. این مقدار روی ۵۰ تنظیم شد. در نهایت، مجموعه آموزشی با بیشترین دقت طبقه‌بندی به منزله مجموعه آموزشی بهینه انتخاب می‌شود.

طبق شکل ۴-ب، در فرایند تولید زیرمجموعه ویژگی منتخب، با فرض اینکه ابعاد فضای ویژگی اصلی D باشد، به تعداد T تکرار، تعداد m ویژگی به صورت تصادفی از این فضا انتخاب می‌شود. مقدار m نیز به صورت تصادفی از بازه $\left[\sqrt{D}, \frac{D}{2}\right]$ تعیین می‌شود. سپس برای هر زیرمجموعه ویژگی تصادفی، ارتباط بین

1. Pearson Correlation Coefficient
2. Mutual Information

۴- ارزیابی و تحلیل نتایج

نتایج عملی کردن و ارزیابی‌های روش پیشنهادی روی دو تصویر مطالعاتی براساس معیارهای دقت کلی^۱، ضریب کاپا^۲، درصد کیفیت^۳ و معیار F₁ در جدول ۲ آورده شده است. در این جدول، AFS، CFS، ITD و OTD به ترتیب بیانگر مجموعه همه ویژگی‌ها^۴، زیرمجموعه ویژگی منتخب، مجموعه آموزشی اولیه و مجموعه آموزشی بهینه است.

به گونه‌ای انتخاب می‌شود که هم‌زمان، میانگین همبستگی بین ویژگی‌ها و کلاس‌ها و میانگین اطلاعات متقابل بین ویژگی‌ها را به حداقل برساند. در این تحقیق، تعداد زیرمجموعه ویژگی تصادفی روی ۲۰۰۰ تنظیم شد. تعداد تکرار الگوریتم آدابوست درمورد اجراهای متفاوت نیز در جدول ۱ آمده است. شایان ذکر است که در دو نسخه MH-Tree و MH-Stump، به دلیل آنکه تمامی کلاس‌ها را هم‌زمان برای آموزش در هر تکرار به کار می‌گیرند، تعداد تکرارهای انتخابی در فاکتور $k \log_2 k$ بیانگر تعداد کلاس‌ها) ضرب شده است.

جدول ۱. تنظیمات پارامتر تعداد تکرار الگوریتم آدابوست

تصاویر مطالعاتی	طبقه‌بندی عارضه‌مبنا					
	طبقه‌بندی پیکسل مبنا		مجموعه آموزشی اولیه		مجموعه آموزشی بهینه	
	Ada	MH	Ada	MH	Ada	MH
تصویر آزمون ۱	۵۰	۱۲۹	۱۰	۲۶	۱۰۰	۲۵۸
تصویر آزمون ۲	۵۰	۱۱۶	۱۰	۲۳	۲۰۰	۲۳۲

جدول ۲. نتایج ارزیابی آدابوست عارضه‌مبنا

روش	نسخه	معیارهای ارزیابی	تصویر آزمون ۱				تصویر آزمون ۲			
			AFS		CFS		AFS		CFS	
			ITD	OTD	ITD	OTD	ITD	OTD	ITD	OTD
آدابوست عارضه‌مبنا	Ada	O.A	۴۹/۸۶۶	۸۳/۳۳۸	۷۶/۳۸۶	۸۱/۳۳۸	۶۹/۹۶۳	۷۸/۰۵۱	۷۰/۹۸۱	۷۸/۰۲۹
		K.C	۰/۳۸۶	۰/۷۹۰	۰/۷۰۶	۰/۷۶۵	۰/۶۱۳	۰/۷۱۱	۰/۶۱۵	۰/۷۱۰
		Q.P	۳۳/۵۷۳	۷۱/۹۲۲	۵۹/۳۳۴	۶۴/۷۹۲	۵۴/۶۵۲	۶۴/۷۷۴	۵۴/۵۲۲	۶۴/۶۵۸
		F ₁	۴۸/۲۷۹	۸۰/۸۸۷	۷۴/۷۸۷	۷۷/۸۱۵	۷۱/۰۱۷	۷۸/۱۲۹	۶۲/۹۰۷	۷۷/۵۸۱
	MH-Stump	O.A	۵۸/۷۵۷	۸۲/۳۴۳	۵۹/۷۷۸	۷۸/۹۵۱	۷۳/۱۲۳	۷۷/۳۱۸	۶۹/۲۱۳	۷۶/۶۳۶
		K.C	۰/۵۰۲	۰/۷۷۸	۰/۵۰۹	۰/۷۳۷	۰/۶۴۵	۰/۷۰۰	۰/۵۹۴	۰/۶۹۱
		Q.P	۴۳/۵۶۳	۷۰/۵۲۸	۴۳/۴۴۵	۶۶/۰۸۹	۵۷/۱۴۱	۶۳/۸۱۲	۵۳/۲۴۹	۶۲/۹۵۳
		F ₁	۶۰/۷۶۷	۷۹/۲۹۱	۵۷/۹۳۸	۷۴/۷۲۹	۶۸/۲۶۲	۷۶/۵۲۴	۶۵/۳۷۵	۷۶/۲۶۸
	MH-Tree	O.A	۶۶/۵۶۷	۸۴/۲۳۷	۶۹/۷۹	۸۱/۵۹۵	۷۲/۲۶۹	۷۹/۶۳۷	۷۲/۸۵۳	۷۹/۲۶۲
		K.C	۰/۵۹۰	۰/۸۰۲	۰/۶۲۱	۰/۷۶۹	۰/۶۳۷	۰/۷۳۱	۰/۶۴۵	۰/۷۲۶
		Q.P	۵۰/۱۱۸	۷۳/۰۱۴	۵۳/۴۵۲	۶۹/۳۰۲	۵۷/۱۰۶	۶۶/۸۸۵	۵۷/۴۸۷	۶۶/۴۰۹
		F ₁	۶۶/۹۰۵	۸۱/۸۴۶	۶۶/۵۶۲	۷۸/۹۱۱	۶۹/۸۲۵	۷۹/۱۸۱	۷۰/۳۳۱	۷۸/۹۵۹


1. Overall Accuracy (O.A)
2. Kappa Coefficient (K.C)
3. Quality Percent (Q.P)
4. All Feature Set (AFS)

در جدول ۲، به‌ازای هر تصویر و هر نسخه از آدابوست، چهار نوع ارزیابی انجام شده است: (۱) AFS-ITD بیانگر مجموعه کل ویژگی‌ها و مجموعه آموزشی اولیه (شرایط اولیه مسئله)؛ (۲) AFS-OTD بیانگر مجموعه کل ویژگی‌ها و مجموعه آموزشی بهینه (روش پیشنهادی)؛ (۳) CFS-ITD نشان‌دهنده زیرمجموعه ویژگی منتخب و مجموعه آموزشی اولیه؛ (۴) CFS-OTD بیانگر زیرمجموعه ویژگی منتخب و مجموعه آموزشی بهینه است. با مقایسه نتایج ارزیابی تمامی حالات اجرایی، مشاهده می‌شود که روش AFS-OTD بیشترین دقت‌ها را دربر داشته است. همچنین مقایسه بین بیشترین دقت‌های حاصل در هر یک از نسخه‌های آدابوست نشان می‌دهد که نسخه MH-Tree عملکرد بهتری دارد. این بدان دلیل است که با استفاده از درخت طبقه‌بندی با سه گره داخلی، ارتباط بین ویژگی‌ها نیز در هر تکرار الگوریتم آدابوست، در نظر گرفته می‌شود.

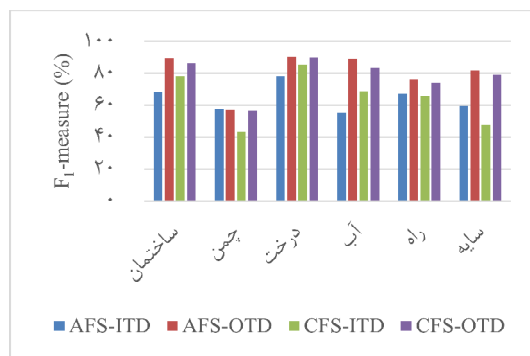
مقایسه بین دو روش AFS-OTD و CFS-OTD هم نشان می‌دهد که این دو روش، به‌طور میانگین، دارای ۲٪ اختلاف دقت‌اند. با توجه به اینکه درون الگوریتم آدابوست انتخاب ویژگی نیز انجام می‌شود، هنگام اجرا با تمامی ویژگی‌ها که حاوی اطلاعات بیشتری از صحنه تصویر است، عملکرد بهتری دارد. از سویی، پایین بودن اختلاف دقت این دو روش بیان می‌کند، با استفاده از زیرمجموعه ویژگی منتخب، بدون از دست دادن مقدار معتنا به اطلاعات می‌توان ابعاد فضای ویژگی را کاهش داد. علاوه‌براین، با مقایسه دقت کلاس‌های پوششی در

مقایسه بین دو روش AFS-OTD و CFS-OTD هم نشان می‌دهد که این دو روش، به‌طور میانگین، دارای ۲٪ اختلاف دقت‌اند. با توجه به اینکه درون الگوریتم آدابوست انتخاب ویژگی نیز انجام می‌شود، هنگام اجرا با تمامی ویژگی‌ها که حاوی اطلاعات بیشتری از صحنه تصویر است، عملکرد بهتری دارد. از سویی، پایین بودن اختلاف دقت این دو روش بیان می‌کند، با استفاده از زیرمجموعه ویژگی منتخب، بدون از دست دادن مقدار معتنا به اطلاعات می‌توان ابعاد فضای ویژگی را کاهش داد. علاوه‌براین، با مقایسه دقت کلاس‌های پوششی در

مقایسه بین دو روش AFS-OTD و CFS-OTD هم نشان می‌دهد که این دو روش، به‌طور میانگین، دارای ۲٪ اختلاف دقت‌اند. با توجه به اینکه درون الگوریتم آدابوست انتخاب ویژگی نیز انجام می‌شود، هنگام اجرا با تمامی ویژگی‌ها که حاوی اطلاعات بیشتری از صحنه تصویر است، عملکرد بهتری دارد. از سویی، پایین بودن اختلاف دقت این دو روش بیان می‌کند، با استفاده از زیرمجموعه ویژگی منتخب، بدون از دست دادن مقدار معتنا به اطلاعات می‌توان ابعاد فضای ویژگی را کاهش داد. علاوه‌براین، با مقایسه دقت کلاس‌های پوششی در




ب) تصویر آزمون ۲




الف) تصویر آزمون ۱

شکل ۵. نمودار دقت کلاسی طبقه‌بندی عارضه‌مبنا به روش MH-Tree براساس معیار ارزیابی F_1



ب) تصویر آزمون ۲



الف) تصویر آزمون ۱

شکل ۶. نمودار دقت کلی مدل یادگیری فعال برحسب تعداد چرخه یادگیری

فلفل- نمکی موجود در خروجی طبقه‌بندی پیکسل‌مبنا، این بهبود دقت انتظار می‌رفت.

در بررسی و قیاس روش‌های متفاوت طبقه‌بندی، یکی از رویکردهای تحلیلی بررسی روشی است که طبقه‌بندی را با صحت بیشتری انتخاب می‌کند؛ اما هر اختلافی معنی‌دار نیست و آنالیز آماری، به‌منظور سنجش معنی‌داری، مورد نیاز است. آزمون آماری مک‌نمار^۱ شاید بهترین روش برای مقایسه دقیق نقشه موضوعی باشد که برپایه تفاوتی باینری بین تخصیص کلاس‌های درست و نادرست است (Foody, 2004). مطابق این آزمون، می‌توان نتایج طبقه‌بندی با دو روش متفاوت را به‌صورت دودویی با هم قیاس کرد و سطح وابستگی آماری بین آن دو را مورد تحلیل قرار داد؛ بنابراین به‌منظور بررسی معنی‌داری اختلاف‌های ذکرشده در نتایج، هریک از روش‌های مورد قیاس، با روش پیشنهادی در سطح معنی‌داری ۰/۰۵ بررسی موردی شد. نتایج این ارزیابی‌ها در جدول ۴ آمده است.

در جدول ۳، نتایج ارزیابی‌های الگوریتم آدابوست در حالت پیکسل‌مبنا، برای دو تصویر آزمون و با استفاده از مجموعه ویژگی‌های شبه‌عمیق (۴۸۴ ویژگی) ادغام‌شده با سه ویژگی طیفی و یک ویژگی ارتفاعی، آمده است.

مقایسه بین نتایج این جدول با جدول ۲ و با در نظر گرفتن بیشترین دقت‌های این جدول‌ها، مربوط به نسخه MH-Tree، نشان می‌دهد که در تصویر ۱، رویکرد عارضه‌مبنا در قیاس با پیکسل‌مبنا حدود ۰/۷٪، ۰/۹٪، ۰/۱۲٪ و ۰/۷٪ به ترتیب دقت کلی، ضریب کاپا، درصد کیفیت و معیار F_1 را بهبود داده است. این نتایج بیان می‌کند رویکرد عارضه‌مبنای پیشنهادی، از نظر دقت طبقه‌بندی، عملکردی بسیار بهتر از حالت پیکسل‌مبنا دارد زیرا در رویکرد عارضه‌مبنا ویژگی‌های هندسی نیز، افزون بر دیگر ویژگی‌ها، در بهبود دقت طبقه‌بندی تأثیرگذار است. همچنین به‌دلیل حذف نویزهای

جدول ۳. نتایج ارزیابی آدابوست پیکسل‌مبنا؛ بیشینه مقادیر با زیرخط متمایز شده است

MH-Tree				MH-Stump				Ada				روش
F ₁	Q.P	K.C	O.A	F ₁	Q.P	K.C	O.A	F ₁	Q.P	K.C	O.A	معیار ارزیابی
۷۶/۶۲	۶۵/۳۶	۰/۷۳۴	۷۸/۶۵	۷۵/۶۹	۶۴/۲۳	۰/۷۲۶	۷۸/۰۱	۷۱/۶۷	۶۲/۵۶	۰/۷۰۵	۷۶/۴۸	تصویر ۱
۷۶/۸۰	۶۱/۲۱	۰/۶۸۶	۷۵/۸۶	۷۴/۵۴	۶۰/۱۲	۰/۶۷۲	۷۴/۷۹	۷۶/۰۹	۶۰/۸۰	۰/۶۸۲	۷۵/۵۶	تصویر ۲

1. McNemar Statistical Test

جدول ۴. نتایج ارزیابی روش پیشنهادی با سایر روش‌ها برحسب آزمون آماری مک‌نمار


Z-score	تصویر آزمون ۱				تصویر آزمون ۲			
	AFS-OTD				AFS-OTD			
	AFS-ITD	CFS-ITD	CFS-OTD	Pixel-Base	AFS-ITD	CFS-ITD	CFS-OTD	Pixel-Base
Ada	۱۲۲۳/۳	۴۲۶/۹۶	۱۸۸/۳۶	۳۸۵/۰۲	۵۱۱/۰۹	۴۲۶/۱۸	۲/۰۲	۱۵۳/۹۵
MH-Stump	۹۷۹/۱۴	۹۵۵/۸۹	۲۸۷/۳۷	۲۶۴/۱۹	۲۶۶/۱۹	۴۹۰/۶۳	۵۳/۰۵	۱۶۳
MH-Tree	۸۲۰/۶۵	۷۱۳/۳۶	۲۴۷/۰۱	۳۲۳/۰۹	۴۷۴/۰۵	۴۴۲/۸۰	۳۸/۵۲	۲۴۱

فضای مسئله جست‌وجو شود. به همین دلیل، تعداد نمونه‌های آموزشی و ابعاد فضای ویژگی تأثیر بسیاری در زمان محاسبات روش MH-Tree دارند؛ همچنین مطابق نمودارهای هر دو تصویر مطالعاتی، با استفاده از روش CFS-OTD، زمان محاسبات الگوریتم MH-Tree کاهش یافته زیرا ابعاد فضای ویژگی کاهش داشته است.


نکته شایان توجه دیگر این است که زمان محاسبات دو نسخه Ada و MH-Stump آدابوست، در روش CFS-OTD، بیشتر از روش AFS-OTD است زیرا ۲۰۰۰ تکرار برای انتخاب زیرمجموعه ویژگی تصادفی در نظر گرفته شده و در نتیجه، زیرمجموعه ویژگی منتخب تولید شده است. به‌طور کلی طبق نمودارهای پیشین و با در نظر گرفتن هر دو تصویر مطالعاتی، بیشترین زمان محاسبات آدابوست عارضه‌مبنای پیشنهادی کمتر از دوازده دقیقه است که در مقایسه با رویکرد پیکسل‌مبنا، سرعت محاسبات افزایش چشمگیری یافته است. این نتایج کارآمدی روش پیشنهادی را، هم از نظر دقت و هم از نظر سرعت محاسبات، اثبات می‌کنند.

با توجه به اینکه اختلاف عدم دقت در سطح معنی‌داری ۹۵٪ آزمایش شده است، اگر Z بزرگ‌تر از ۱/۹۶ باشد، یعنی بین نتایج وابستگی آماری وجود ندارد و اختلاف معناداری میان دو روش هست (Kiani et al., 2021). بدین ترتیب، طبق نتایج ارزیابی‌ها در جدول ۴، مشاهده می‌شود که تمامی روش‌های مورد قیاس باروش پیشنهادی مستقل از هم هستند و بیان می‌کند بهبود دقت‌های حاصل در روش پیشنهادی، در مقایسه با دقت نتایج دیگر روش‌های اجرایی، صحیح و مورد اطمینان است.

با توجه به زمان محاسبات روش‌های اجراشده در طرح پیشنهادی تحقیق، در هر دو تصویر مطالعاتی (نمودارهای شکل ۷)، با توسعه مجموعه آموزشی، طبعاً زمان محاسبات افزایش یافته است اما این افزایش زمان در نسخه MH-Tree، به‌نسبت دو نسخه دیگر آدابوست در روش AFS-OTD، درخور توجه است. این امر ناشی از آن است که با استفاده از درخت طبقه‌بندی با تعداد گره معین، به‌منزله یادگیرنده پایه آدابوست، لازم است در هر تکرار برای تشکیل هر گره داخلی درخت، تمامی



ب) تصویر تست ۲



الف) تصویر تست ۱

شکل ۷. نمودار ارزیابی زمان محاسبات مدل آدابوست عارضه‌مبنا

۵- نتیجه‌گیری

در این تحقیق، به منظور طبقه‌بندی پوشش زمین در تصاویر با حد تفکیک مکانی بالا، ابتدا ویژگی‌های بافت با استفاده از استخراج‌گرهای ویژگی شبه‌عمیق و ماتریس GLCM استخراج شد. هدف از این کار افزایش ابعاد فضای ویژگی و فراهم‌سازی اطلاعات نسبتاً جامع برای ورود به فرایند طبقه‌بندی بود. در ادامه، مجموعه آموزشی بهینه براساس سیستم طراحی‌شده مبتنی بر یادگیری فعال و نیز زیرمجموعه ویژگی منتخب برپایه محاسبات همبستگی ویژگی‌ها تولید شد تا طبقه‌بندی عارضه‌مبنای آدابوست صورت پذیرد.

در طبقه‌بندی عارضه‌مبنای آدابوست، با تولید مجموعه آموزشی بهینه بر مبنای یادگیری فعال و نیز تولید زیرمجموعه ویژگی منتخب برپایه محاسبات همبستگی‌ها، در دو تصویر آزمون و سه نسخه الگوریتم آدابوست، به طور میانگین بهبود در دقت کلی و ضریب کاپا مشاهده شد. میزان این بهبود به ترتیب ۲۶٪ و ۳۷٪ به نسبت شرایط اولیه مسئله و نیز ۶٪ و ۷٪ به نسبت طبقه‌بندی پیکسل مبنای آدابوست بوده است. علت آن ایجاد تناسب بین نمونه‌های آموزشی و ویژگی‌ها در فضای ویژگی مسئله است زیرا فرایند انتخاب ویژگی و انتخاب فرضیه ضعیف در آدابوست مستقیماً از تعداد و توزیع نمونه‌های آموزشی در فضای ویژگی تأثیر می‌پذیرد. از این رو در این تحقیق، با استفاده از ایده یادگیری فعال، سیستمی هوشمند برای انتخاب نمونه‌های آموزشی مناسب طبقه‌بندی‌کننده آدابوست ایجاد شد و نتایج ارزیابی‌ها کارآمدی این طرح پیشنهادی را اثبات کردند. اما در این روش، با افزایش تعداد چرخه یادگیری، زمان محاسبات افزایش می‌یابد که با انتخاب تعداد تکرار محدود و مناسب، می‌توان افزایش زمان محاسبات را کنترل کرد. در طرح تولید زیرمجموعه ویژگی منتخب مبتنی بر همبستگی‌ها نیز، با انتخاب زیرمجموعه ویژگی تصادفی به تعداد مناسب می‌توان در زمانی بهینه به دقت مطلوب رسید. با این اوصاف، در طبقه‌بندی عارضه‌مبنا، الگوریتم‌های دارای

ماهیت تکرارشونده سبب ایجاد محدودیت زمانی نمی‌شوند زیرا ابعاد فضای مسئله، در سطح عارضه به نسبت سطح پیکسل، به شدت کاهش می‌یابد؛ بنابراین در این طرح پیشنهادی، نگرانی ناشی از محدودیت زمان محاسبات وجود ندارد. برای تحقیقات آتی، پیشنهاد این است که طرح بیان‌شده در این تحقیق، براساس ایده یادگیری نیمه‌نظارت‌شده به منظور طبقه‌بندی عارضه‌مبنای آدابوست، توسعه داده شود.

۶- منابع

- Agrawal, M. & Nagwanshi, K., 2016, **High Resolution Image Classification with Edge Detection Based Segmentation and AdaBoost**, International Research Journal of Engineering and Technology (IRJET), 3(5), PP. 1844- 1847.
- Batz, M., 2000, **Multi Resolution Segmentation: An Optimum Approach for High Quality Multi Scale Image Segmentation**, In: Beutrage Zum AGIT-Symposium, Salzburg, Heidelberg, 2000 (PP. 12-23).
- Batz, M., Benz, U., Dehghani, S., Heynen, M., Hölte, A., Hofmann, P., Lingenfelder, I., Mimler, M., Sohlbach, M. & Weber, M., 2004, **eCognition Professional User Guide version 4.0. München: Definiens Imaging GmbH**.
- Bui, Q.-T., Pham Van, M., Hang, N.T.T., Nguyen, Q.-H., Linh, N.X., Hai, P.M., Tuan, T.A. & Van Cu, P. 2019, **Hybrid Model to Optimize Object-Based Land Cover Classification by Meta-Heuristic Algorithm: An Example for Supporting Urban Management in Ha Noi, Viet Nam**, International Journal of Digital Earth, 12, PP. 1118-1132.
- Chen, Y., Dou, P. & Yang, X., 2017, **Improving Land Use/Cover Classification with a Multiple Classifier System Using AdaBoost Integration Technique**, Remote Sensing, 9, P. 1055.
- Cormen, T.H., Leiserson, C.E., Rivest, R.L. & Stein, C., 2009, **Introduction to Algorithms**, MIT Press.

- Definiens, A., 2007, **Definiens Developer 7 Reference Book**, Definiens AG, München, PP. 21-24.
- Dou, P., Chen, Y. & Yue, H., 2018, **Remote-Sensing Imagery Classification Using Multiple Classification Algorithm-Based AdaBoost**, International Journal of Remote Sensing, 39, PP. 619-639.
- Dronova, I., Gong, P. & Wang, L., 2011, **Object-Based Analysis and Change Detection of Major Wetland Cover Types and Their Classification Uncertainty during the Low Water Period at Poyang Lake, China**, Remote Sensing of Environment, 115, PP. 3220-3236.
- Duffy, N. & Helmbold, D.P., 2000, **Potential Boosters?**, In: Advances in Neural Information Processing Systems (PP. 258-264).
- Fan, J., Zeng, G., Body, M. & Hacid, M.-S., 2005, **Seeded Region Growing: An Extensive and Comparative Study**, Pattern Recognition Letters, 26, PP. 1139-1156.
- Foody, G.M., 2004, **Thematic Map Comparison**, Photogrammetric Engineering & Remote Sensing, 70, PP. 627-633.
- Freund, Y. & Schapire, R.E., 1997, **A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting**, Journal of Computer and System Sciences, 55, PP. 119-139.
- Georganos, S., Grippa, T., Vanhuysse, S., Lennert, M., Shimoni, M., Kalogirou, S. & Wolff, E., 2018, **Less Is More: Optimizing Classification Performance through Feature Selection in a Very-High-Resolution Remote Sensing Object-Based Urban Application**, GIScience & Remote Sensing, 55, PP. 221-242.
- Hamidi, M., Ebadi, H. & Kiani, A., 2018, **Building Detection in Urban Areas from High-Resolution Remote Sensing Images Using the Developed AdaBoost Method and High-Level (Quasi-Deep) Features**, JGST., 8(2), PP. 35-52.
- Haralick, R.M., Shanmugam, K. & Dinstein, I., 1973, **Textural Features for Image Classification**, IEEE Transactions on Systems, Man, and Cybernetics, SMC-3, PP. 610-621.
- Heo, J. & Yang, J.Y., 2014, **AdaBoost Based Bankruptcy Forecasting of Korean Construction Companies**, Applied Soft Computing, 24, PP. 494-499.
- Huang, X. & Zhang, L., 2012, **An SVM Ensemble Approach Combining Spectral, Structural, and Semantic Features for the Classification of High-Resolution Remotely Sensed Imagery**, IEEE Transactions on Geoscience and Remote Sensing, 51, PP. 257-272.
- ISPRS, 2013, **Web Site of the ISPRS Test Project on Urban Classification and 3D Building Reconstruction**, Available: <http://www2.isprs.org/commissions/comm3/wg4/tests.html>.
- Jia, Y., 2015, **Object-Based Land Cover Classification with Orthophoto and Lidar Data**, In: Environmental Science, Mathematics.
- Kégl, B., 2013, **The Return of AdaBoost. MH: Multi-Class Hamming Trees**, LAL/LRI, University of Paris-Sud, CNRS, 91898 Orsay, France.
- Kiani, A., Ahmadi, F.F. & Ebadi, H., 2019, **Developing an Interpretation System for High-Resolution Remotely Sensed Images Based on Hybrid Decision-Making Process in a Multi-scale Manner**, Journal of the Indian Society of Remote Sensing, PP. 1-18.
- Kiani, A., Farnood Ahmadi, F. & Ebadi, H., 2021, **Correction of Training Process in Object-Based Image Interpretation via Knowledge Based System Capabilities**, Multimedia Tools and Applications, 80, PP. 24901-24924.
- Laliberte, A.S., Browning, D. & Rango, A., 2012, **A Comparison of Three Feature Selection Methods for Object-Based Classification of Sub-Decimeter Resolution UltraCam-L Imagery**, International Journal of Applied Earth Observation and Geoinformation, 15, PP. 70-78.

- Li, X., Wang, L. & Sung, E., 2004, **Improving Adaboost for Classification on Small Training Sample Sets with Active Learning**, Korea, Available: https://www.researchgate.net/publication/228849380_Improving_adaboost_for_classification_on_small_training_sample_sets_with_active_learning.
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P. & Liu, Y., 2017, **A Review of Supervised Object-Based Land-Cover Image Classification**, ISPRS Journal of Photogrammetry and Remote Sensing, 130, PP. 277-293.
- Mason, L., Baxter, J., Bartlett, P.L. & Frean, M.R., 2000, **Boosting Algorithms as Gradient Descent**, In: Advances in Neural Information Processing Systems (PP. 512-518).
- Maxwell, A.E., Warner, T.A. & Fang, F., 2018, **Implementation of Machine-Learning Classification in Remote Sensing: An Applied Review**, International Journal of Remote Sensing, 39, PP. 2784-2817.
- Momeni, R., Aplin, P. & Boyd, D.S., 2016, **Mapping Complex Urban Land Cover from Spaceborne Imagery: The Influence of Spatial Resolution, Spectral Band Set and Classification Approach**, Remote Sensing, 8, P. 88.
- Pérez-Ortiz, M., Peña, J.M., Gutiérrez, P.A., Torres-Sánchez, J., Hervás-Martínez, C. & López-Granados, F., 2016, **Selecting Patterns and Features for between-and within-Crop-Row Weed Mapping Using UAV-Imagery**, Expert Systems with Applications, 47, PP. 85-94.
- Prasvita, D.S. & Arymurthy, A.M., 2017, **Classification of LiDAR Images Fused with Aerial Optical Images Using Ensemble Classifier AdaBoost. MH and Post-processing BFS**, International Journal of Technology And Business, 1, PP. 10-16.
- Schapire, R.E. & Singer, Y., 1999, **Improved Boosting Algorithms Using Confidence-Rated Predictions**, Machine Learning, 37, PP. 297-336.
- Tamimi, E., Ebadi, H. & Kiani, A., 2017, **Evaluation of Different Metaheuristic Optimization Algorithms in Feature Selection and Parameter Determination in SVM Classification**, Arabian Journal of Geosciences, 10, P. 478.
- Tokarczyk, P., Wegner, J.D., Walk, S. & Schindler, K., 2015, **Features, Color Spaces, and Boosting: New Insights on Semantic Classification of Remote Sensing Images**, IEEE Transactions on Geoscience and Remote Sensing, 53, PP. 280-295.
- Viola, P. & Jones, M.J., 2004, **Robust Real-Time Face Detection**, International Journal of Computer Vision, 57, PP. 137-154.



Design and Implementation of an Object-Based AdaBoost Algorithm Based on Active Learning for Land-Cover Classification in High-Resolution Images

Hamidi M.¹, Ebadi H.², Kiani A.^{3*}

1. M.Sc. in Remote Sensing, Dep. of Surveying, K.N. Toosi University of Technology
2. Prof. of Faculty of Geomatics Engineering, Member of the Scientific Center of Spatial Information Technology, K.N. Toosi University of Technology
3. Assistant Prof., Faculty of Civil Engineering, Noshirvani University of Technology, Babol

Abstract

By improvement of the spatial resolution of remote sensing images, more accurate information are provided from the image scene such as texture structures. However, extraction of land cover information from these datas has become a challenging process due to the high spectral diversity and the heterogeneity of surface materials. Visual interpretation is costly and time consuming and automatic interpretation of images does not necessarily lead to high accuracy. Achieving optimal interpretation accuracy requires the design of automatic algorithms that are capable of dealing with the complexity of the image scene. To overcome this problem, object-based image analysis (OBIA) that is sensitive to the image scene morphology, can be particularly effective in an urban area where the density of man-made structures is high. In object-based classification, pixels of a segment are analyzed in combination with each other. So the dimensions of the problem space are reduced, in compared to the pixel-based method, which leads to increasing the computational speed. Meanwhile, due to the different sizes of image segments, supervised object-based classification faces challenges in creating an optimal training set. In this research, AdaBoost algorithm was selected for the object-based classification, to overcome the problem of feature space imbalance, due to the small number of training samples in comparison with the high dimensions of the feature space (including spectral, spatial and geometric features), two strategies were proposed. In the first approach an active learning mechanism was integrated with AdaBoost to produce optimal training data set (OTD) and in another approach based on the feature-to-feature correlation (redundancy) and the feature-to-class correlation (relevance), the candidate feature subset (CFS) was generated to reduce the size of the feature space. To evaluate the proposed method, the developed algorithm was performed on the standard dataset of Vaihingen in Germany and the results were compared with the pixel-based classification. In order to evaluate the signification of the results, the McNemar statistical test was used. The experimental results showed that the proposed object-based approach improved the overall accuracy by 6% and the kappa coefficient by 7% compared to the pixel-based approach. Also, the computational speed of proposed object-based AdaBoost was significantly increased compared to the pixel-based approach. These results indicate the superiority of the proposed approach both in terms of accuracy and processing speed.

Keywords: Classification, High spatial resolution images, AdaBoost, Object-Based, Active learning.

* Correspondence Address: Faculty of Civil Engineering, Noshirvani University of Technology, Babol. Tel: 09113202636
Email: a.kiani@nit.ac.ir