



طراحی و اجرای الگوریتم آدابوست عارضه‌مبنا مبتنی بر یادگیری فعال به منظور 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 فتاوری 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، بهدلیل جزئیات بسیار، دارای واریانس درون کلاسی زیاد و واریانس بین کلاسی انداز، ازین رو استخراج اطلاعات پوشش زمین از آنها به فرایندی چالش‌برانگیز تبدیل شده است. در این تصاویر، تفسیر بصری زمان بر 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 عارضه‌مبنا تصویر که به مورفلوژی صحنه تصویر حساس است، بهویژه در مطالعه‌ای شهری که تراکم ساختارهای شکل‌گرفته به دست 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 پیکسل مبنا کاهش می‌یابد و مزیت این امر افزایش سرعت محاسبات است. در عین حال به دلیل اندازه متنوع اشیای تصویری، طبقه‌بندی نظرات شده عارضه‌مبنا در ایجاد مجموعه آموزشی بھینه با چالش‌هایی مواجه است. در تحقیق حاضر، به منظور طبقه‌بندی عارضه‌مبنا، از الگوریتم آدابوست استفاده شده است. برای غلبه بر مشکل فقدان تناسب فضای ویژگی ناشی از تعداد انداز نمونه‌های آموزشی و توزیع نامناسب آنها در مقایسه با ابعاد بالای فضای ویژگی (شامل ویژگی‌های طیفی، مکانی و هندسی)، دو رویکرد 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 و هینگکن کشور آلمان اجرا و نتایج حاصل از آن با طبقه‌بندی پیکسل مبنا مقایسه شده است. به‌منظور بررسی معنی‌داری اختلافهای حاصل شده در نتایج ارزیابی‌ها نیز، آزمون آماری مکنمار به کار رفته است. نتایج تجربی نشان دادند که رویکرد عارضه‌مبنا پیشنهادی، در قیاس با رویکرد پیکسل مبنا، به طور متوسط ۷۶٪ دقت کلی و ۷٪ ضریب کاپا را بهبود داده است. همچنین سرعت محاسبات در روش آدابوست عارضه‌مبنا پیشنهادی، در مقایسه با رویکرد پیکسل مبنا 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.

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 حداستانه^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 قادر تحلیل و ارزیابی جامع با هدف دستیابی به نتیجه‌گیری مورد اطمینان است. در مطالعه‌ای دیگر، به منظور طبقه‌بندی داده لیدار تلفیق شده با تصویر هوایی، الگوریتم AdaBoost.MH^{۱۱} و پس‌پردازش BFS^{۱۲} استفاده شد (& Prasvita, 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 گستره‌ای، 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. با این حال افزایش تعداد ویژگی‌ها، به دلیل ایجاد مشکلاتی همچون (۱) آموزش بیش از حد 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 گستره‌ای در طبقه‌بندی داده‌های سنجش از دور داشته‌اند. این الگوریتم‌ها امپای 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 آن جاکه این روش همزمان با طبقه‌بندی دارای قابلیت انتخاب ویژگی است، بهره‌مندی از آن به ویژه در مواجهه با انبوه داده‌ها، گزینه مناسبی به شمار 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. به طور کلی الگوریتم‌های انتخاب ویژگی متفاوت، از نظر دقت و تعداد ویژگی‌های انتخابی، نتایج متفاوتی برای طبقه‌بندی عارضه‌مینا فراهم می‌کنند؛ از این‌رو هیچ روش استانداردی درمورد انتخاب ویژگی در OBIA وجود ندارد و این مسئله همچنان چالش‌برانگیز است.

اصلی‌ترین و مهم‌ترین نکته، در طبقه‌بندی عارضه‌مینای آدابوست، انتخاب ویژگی ناصحیح و طبقه‌بندی نامناسب ناشی از نبود تناسب فضای ویژگی است که به‌دلیل تعداد اندک و توزیع نامتناسب قطعات آموزشی رخ می‌دهد. یکی از راه حل‌های مطرح شده در زمینه 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 برای تفسیر هندسی آدابوست در فضای نسخه^{۱۲} انتخاب شده و تحقیق لی^{۱۳} و همکاران (۲۰۰۴)، با توجه به کارآمدی‌بودن نتایج آن، ایهام‌بخش پژوهش پیش رو بوده است. از این‌رو در تحقیق حاضر، به‌منظور طبقه‌بندی عارضه‌مینای آدابوست، براساس مکانیسم یادگیری فعال، معیار آنتروپی برای انتخاب نمونه‌های بهینه با بیشترین عدم قطعیت پیشنهاد شده است که نزدیک‌ترین نمونه‌ها به

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

^۳ Ma و همکاران (۲۰۱۷) بررسی جامعی، در زمینهٔ تحقیقات سنجش از دوری، روی فرایند طبقه‌بندی نظارت‌شدهٔ عارضه‌مینا 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؛ در حالی که 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 عارضه‌مینا، 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؛ در حالی که روش دوم می‌تواند مستقیماً به زیرمجموعهٔ ویژگی‌های بهینه دست یابد. Laliberte^۴ و همکاران (۲۰۱۲) سه روش انتخاب ویژگی شامل ^۵JM، ^۶CTA و ^۷FSO را به‌منظور طبقه‌بندی عارضه‌مینا با ^۸KNN، روی پنج تصویر مطالعاتی ارزیابی کردند. طبق نتایج ارزیابی آنها، روش JM درمورد سه تصویر و روش CTA درمورد 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؛ در حالی که در روش JM فقط فواصل تفکیک کلاس‌ها

1. Artificial Neural Network
2. Naïve 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 نرمال‌سازی شده و تصویر واقعیت زمینی آنها نشان داده شده است. به منظور طبقه‌بندی 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 ویژگی‌های کارآمد نیز، تصویر هوایی و داده ارتفاعی منطقه تلفیق شده‌اند.

۲-۲- قطعه‌بندی تصویر

هدف از قطعه‌بندی تقسیم تصویر به نواحی یکنواخت بدون همپوشانی با یکدیگر است؛ به این نواحی، در Fan et al., (2005). برای قطعه‌بندی تصاویر، الگوریتم‌های متنوعی وجود دارد که در این تحقیق، برای ایجاد قطعات همگن با استفاده از نرم‌افزار Cognition^e از الگوریتم قطعه‌بندی چندسطحی^۵ بهمنزله یکی از مناسب‌ترین روش‌ها استفاده شده است. یکی از اهداف این روش ارائه همزمان اشیای تصویری با مقیاس‌های متفاوت است. تمامی ویژگی‌های اشیای تصویری، از جمله رنگ (طیف)، بافت یا شکل، تا حدودی به مقیاس بازمی‌گردد. عدد مقیاس ابعاد شیوه‌های تصویری را کنترل می‌کند که مقدار بزرگ آن سبب کاهش تعداد شیوه‌های تصویری و افزایش مساحت آنها می‌شود. (Baatz, 2000; Definiens, 2007)

۳-۲- تولید ویژگی

در این تحقیق، به دلیل پیچیدگی‌های ساختاری و طیفی صحنۀ تصویر و حد تفکیک بالای داده مورد استفاده، لزوم به کارگیری ویژگی‌های طیفی، مکانی، هندسی و ارتفاعی به منظور طبقه‌بندی دقیق تصویر احساس می‌شود. یکی از ویژگی‌های مکانی که در کنار

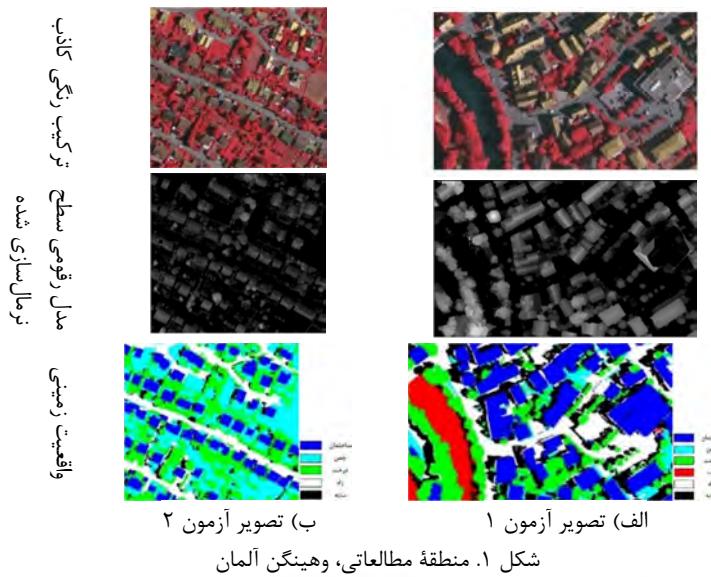
1. Candidate Feature Subset (CFS)
2. Redundancy
3. Relevance
4. Wehingen
5. Multi-Resolution Segmentation

مرز تصمیم‌گیری آدابوست محسوب می‌شوند. در رویکردی دیگر نیز، برای کاهش ابعاد فضای ویژگی، راهبرد تولید زیرمجموعۀ ویژگی منتخب^۱ مبتنی بر همبستگی بین ویژگی‌ها (افزونگی)^۲ و همبستگی بین ویژگی‌ها و کلاس‌ها (مطابقت)^۳ پیشنهاد شده است. سپس بین نتایج این دو رویکرد و نیز شرایط اولیۀ مسئله، مقایسه‌ای صورت گرفته است. افزون‌براین رویکرد پیکسل مبنا نیز، به منظور فراهم‌سازی ارزیابی مقایسه‌ای، بررسی و آزموده شده است. نتایج بیان می‌کند روش عارضه‌مبنا پیشنهادی، ضمن افزایش دقت، سرعت مطلوبی نیز دارد.

۲- مواد و روش‌ها

۲-۱- مشخصات داده‌های مورد استفاده

مجموعه داده مورد استفاده در تحقیق داده اپتیک با حد تفکیک مکانی بالا و داده ارتفاعی منطقه و هیینگن^۴ در آلمان است که از سوی کمیسیون سه گروه کاری چهار جامعۀ بین‌المللی فتوگرامتری و سنجش از دور، آماده شده است (2013 ISPRS). تصاویر هوایی منطقه با استفاده از دوربین دیجیتالی Intergraph/ZI DMC با فاصلۀ کانونی ۱۲۰ میلی‌متر، از ارتفاع نهصدمتری گرفته شده‌اند که حد تفکیک مکانی ۸ سانتی‌متر و سه باند طیفی مادون قرمز IR، قرمز R و سبز G دارند. از روی تصاویر هوایی اصلی، مدل رقومی سطح و ارتوتوموزائیک واقعی نیز تهیه شده است. در تهیۀ این دو نوع داده، از شبکه‌ای با دقت مکانی ۹ سانتی‌متر استفاده شده است. این دو مجموعه داده، به منظور استفاده یک‌جا از آنها، زمین‌مرجع و هم‌مرجع شده‌اند و نیازی به تصحیحات هندسی و رادیومتریکی ندارند. داده ارتفاعی به کاررفته در این تحقیق، مدل رقومی سطح نرمال‌سازی شده (nDSM) است که همین گروه آن را تهیه کرده است. به منظور سنجش دقت روش پیشنهادی، به داده مرتع نیاز است که گروه مورد نظر آن را به صورت دستی برچسب‌گذاری معنایی کرده است. در شکل ۱، تصاویر هوایی محدوده مطالعاتی،



شکل ۱. منطقه مطالعاتی، وهینگن آلمان

شبده عمیق نام دارد (Tokarczyk et al., 2015). شبهه عمیق شامل ویژگی‌های گستردگی است و از طریق پنجره‌ای متحرک، به منزله واحد پایه، تولید می‌شود که پیکسل به پیکسل روی تصویر جابه‌جا می‌شود. بعد از پنجره متحرک را می‌توان از 3×3 تا 25×25 در نظر گرفت که به قدرت تفکیک تصویر و اندازه اشیای تصویری بارمی‌گردد. 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).

بعلاوه، 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 تقاضا، طول مرز، تناسب مستطیلی، فشرده‌گی و نیز ده ویژگی طیفی اشیا شامل میزان روشنایی، بیشترین اختلاف مقادیر باندهای

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

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 هم رخداد 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 به تازگی 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

طبقه‌بندی کننده‌های پایه، به درستی طبقه‌بندی شده و مقدار حاشیه ۱- نشان دهنده طبقه‌بندی اشتباہ است. حاشیه طبقه‌بندی کننده‌ها در تکرارهای آدابوست 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 i ، y_i بیانگر برچسب واقعی نمونه i ، T تعداد تکرار آدابوست، h_j طبقه‌بندی کننده ضعیف در تکرار j و وزن α_j وزن طبقه‌بندی کننده j است. نظریه آدابوست ابتدا در مورد مسئله دوکلاسه مطرح شد. شاپیر و سینگر^۱ (۱۹۹۹)، با ارائه توسعه چندکلاسه با نام MH، موفقیت شایان توجهی به داشت آوردن. هدف الگوریتم MH یافتنتابع تمایز برداری^۲ با مینیمم تابع ضرر همینگ^۳ بهنحوی است که خطای وزن دار حاشیه مینا^۴ حداقل شود. رابطه (۲) تابع ریسک نمایی الگوریتم MH را نشان می‌دهد.

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

الگوریتم MH تابع تمایز نهایی را با استفاده از جمع طبقه‌بندی کننده‌های پایه $R^k: X \rightarrow R^k$ به صورت رابطه (۳) ایجاد می‌کند.

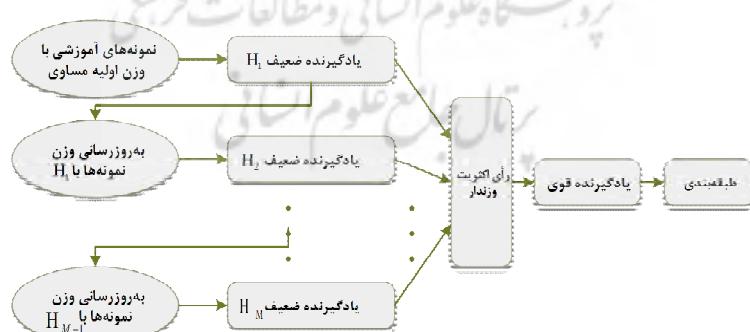
$$f^T(x) = \sum_{t=1}^k h^t(x) \quad (3)$$

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

۴-۲- الگوریتم آدابوست

روش آدابوست (بوستینگ تطبیقی) محبوب‌ترین شیوه از میان انواع بوستینگ است. بوستینگ، با هدف بهبود دقت طبقه‌بندی، گروهی از طبقه‌بندی کننده‌های ضعیف را به طبقه‌بندی کننده‌ای قوی (با دقت بالا) تبدیل می‌کند. آدابوست 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 وزن دار برای تشکیل یادگیرنده قوی ترکیب می‌شوند (Freund & Schapire, 1997). در شکل ۲، ساختار گرافیکی الگوریتم آدابوست نشان داده شده است.

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



شکل ۲. ساختار گرافیکی الگوریتم آدابوست

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

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

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 $\varphi(x): x \rightarrow \{\pm 1\}^k$ طبقه‌بندی کننده اسکالر است. در طبقه‌بندی چندکلاسه، ممکن است $\varphi(x)$ با برخی از برچسب کلاس‌های y_l همبسته^۶ و با برخی دیگر همبسته معکوس^۷ 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 طبقه‌بندی کننده $\varphi(x)$ است که با توجه به میزان خطای وزن دار $\varphi(x)$ ، به طور یکنواخت کاهش می‌یابد (هم‌ارز با این مفهوم، با توجه به لبه^۸، $v \varphi(x)$ به طور یکنواخت افزایش می‌یابد). میزان خطای وزن دار هر کلاس طبق رابطه (۸) و میزان طبقه‌بندی صحیح وزن دار 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 طبقه‌بندی کننده مطابق با رابطه (۱۰) محاسبه می‌شود.

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

در نهایت، ضریب α از طریق رابطه (۱۱) به دست 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، برچسب کلاس هر نمونه به صورت برداری با k مؤلفه (برچسب کلاس مورد نظر $+1$ و بقیه کلاس‌ها -1) در نظر گرفته می‌شود؛ از این‌رو در مورد برچسب کلاس (۷) نمونه‌های آموزشی، ماتریسی با ابعاد $N \times k$ خواهیم داشت. علاوه بر این وزن نمونه‌های آموزشی (w) نیز، به صورت ماتریسی هم‌ابعاد با ماتریس برچسب، طبق رابطه (۴) تشکیل می‌شود. این ماتریس وزن، طی تکرارهای الگوریتم یادگیری، به روزرسانی می‌شود.

$$w_l = \begin{cases} \frac{1}{2} & \text{if } l = l(x) \\ \frac{1}{2(k-1)} & \text{if } l \neq l(x) \end{cases} (i \cdot e \text{ if } y_l = 1) \quad (4)$$

رابطه (۴)

در این رابطه، l بیانگر هریک 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 تصمیم^۹ نامیده می‌شود، متداول ترین انتخاب برای یادگیرنده پایه در آدابوست است. استامپ 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 وزن دهنده را جستجو 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، زاندیس ویژگی انتخابی و b حد آستانه تصمیم است. در چارچوب MH، درختان تصمیم برداری^{۱۰} برای بهینه‌سازی لبه چندکلاسه^{۱۱} مطرح شده است (Kégl, 2013). عنصر اصلی، در این روش، استامپ تصمیم برداری است که به برداری مستقل از ورودی^{۱۲} با طول k و طبقه‌بندی کننده اسکالر مستقل از برچسب^{۱۳} تقسیم می‌شود. هدف یادگیرنده پایه چندکلاسه حداقل سازی تابع هدف $Z(h, W)$ است که طبق رابطه (۶) انجام می‌شود. حداقل سازی این تابع هدف، در هر تکرار، معادل با حداقل سازی خطای وزن دار حاشیه‌مبنای بیان شده 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

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

1. Data Structure
 2. Priority Queue
 3. Optimal 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 توفّ حصول تعداد گره‌های تعیین شده 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

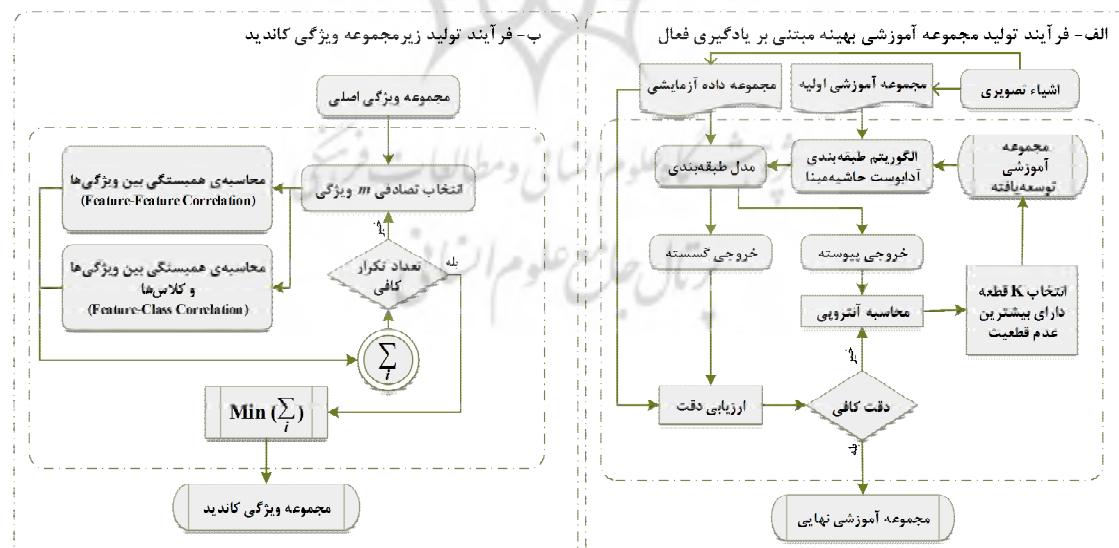
با توجه به اینکه در آدابوست، مینیمم مقدار خطای ماکریم لبه طبقه‌بندی کننده پایه معیار انتخاب ویژگی است، فرایند انتخاب ویژگی و انتخاب فرضیه ضعیف مستقیماً از نمونه‌های آموزشی تأثیر می‌پذیرد. از طرفی، ایده اصلی بوسینگ^۵ ترکیب یادگیرنده‌های ضعیف به منظور حصول یادگیرنده قوی است؛ با این فرض که یادگیرنده‌های ضعیف صرفاً کمی بهتر از حالت تصادفی باشند و بنابراین، در صورتی که این شرط برقرار نباشد، مدل طبقه‌بندی آدابوست به درستی ایجاد نخواهد شد. بر این اساس، طرح پیشنهادی طبقه‌بندی عارضه‌مبانی 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، طبقه‌بندی کننده

طبقه‌بندی کننده آدابوست حاشیه‌مبنا^۱ مطرح شده است. در نسخه اصلی آدابوست، معیار انتخاب ویژگی در هر تکرار براساس مینیمم مقدار خطای وزن دهی ایجاد شده از سوی فرضیه‌های ضعیف است. در این تحقیق، ایده انتخاب ویژگی بر مبنای ترکیب ماکریزم حداقل حاشیه و مینیمم مقدار خطای مطرح شده است. به عبارتی، در هر تکرار آدابوست، یک ویژگی از میان تمامی ویژگی‌ها به‌نحوی انتخاب می‌شود که هم‌زمان با کمینه‌کردن میزان خطای وزن دهی، 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 شو، ادامه می‌یابد. مثبت‌شدن حاشیه طبقه‌بندی کننده آدابوست بدین معنی است که تمامی نمونه‌ها به درستی طبقه‌بندی شده‌اند. هدف از این ایده حذف تک‌پارامتر تنظیمی آدابوست (تعداد تکرار) است که سطح اتوМАسیون و سرعت الگوریتم یادگیری را افزایش می‌دهد.

۸۰ و شکل (۱۰/۰ و ۰/۵) و با مقدار ثابت فشردگی ۵/۰ آزموده شد؛ در مورد تصویر آزمون ۱، تصویر قطعه‌بندی با مقدار مقیاس ۵۰ و شکل ۱/۰ و در مورد تصویر آزمون ۲، قطعه‌بندی با مقدار مقیاس ۵۰ و شکل ۳/۰ بهترین خروجی را دربر داشت. نمونه‌برداری از تصاویر نیز بدین گونه انجام شد که ۱٪ از داده واقعیت زمینی برای نمونه‌های آموزشی و ۹٪ آن بهمنزله داده آزمایشی در نظر گرفته شد. از سویی، با ادغام تمامی ویژگی‌ها در مورد هر دو تصویر مطالعاتی، ۵۸۵ ویژگی برای ورود به مرحله طبقه‌بندی آماده‌سازی شد. در اجراء، MH-Stump (نسخه Ada آدابوست)، (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 بدین گونه است که ابتدا طبقه‌بندی عارضه‌مبنا آدابوست با استفاده از مجموعه آموزشی اولیه انجام می‌شود. در این فرایند، ایده



شکل ۴. روند نمای 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.

$$CS = \frac{\sum_{(x_i, x_j) \in \Omega_{ML}} (f_{ri} - f_{rj})^2}{\sum_{(x_i, x_j) \in \Omega_{CL}} (f_{ri} - f_{rj})^2} \quad (13)$$

$$\rho(f_r, f_c) = \frac{\sum_i (f_{ri} - \bar{f}_r)(f_{ci} - \bar{f}_c)}{\sqrt{\sum_i (f_{ri} - \bar{f}_r)^2} \sqrt{\sum_i (f_{ci} - \bar{f}_c)^2}} \quad (14)$$

$$MI = -\frac{1}{2} \log(1 - \rho^2(f_r, f_c)) \quad (15)$$

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 کلاس‌های است. 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 درمورد ویژگی‌های موجود در یک زیرمجموعه ویژگی، از میان تمامی زیرمجموعه‌های تولید شده تصادفی، زیرمجموعه ویژگی منتخب

1. Pearson Correlation Coefficient

2. Mutual Information

پس از طبقه‌بندی اولیه به روش آدابوست حاشیه‌مینا، 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.

$$H(x) = -\sum_{i=1}^k P(x_i) \log_2 P(x_i) \quad (12)$$

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 بر عکس. از آنجاکه هدف الگوریتم یادگیری فعال بافتمن طبقه‌بندی کننده بهینه است، با درنظر گرفتن نمونه‌های دارای عدم قطعیت بالا که مرز تصمیم‌گیری طبقه‌بندی کننده ایجاد شده 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 بر حسب تعداد تکراری تعیین می‌شود که سیستم یادگیری می‌تواند بدون از دست دادن عملکرد بهینه‌اش، داشته باشد. این مقدار روی 50 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 فضای انتخاب می‌شود. مقدار n نیز به صورت تصادفی از بازه $\left[\sqrt{D}, \frac{D}{2}\right]$ تعیین می‌شود. سپس برای هر زیرمجموعه ویژگی تصادفی، ارتباط بین

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 F_1 در جدول ۲ اورده 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 در مرور 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 $k \log_2 k$ ضرب شده است.

جدول ۱. تنظیمات پارامتر تعداد تکرار الگوریتم آدابوست

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

جدول ۲. نتایج ارزیابی آدابوست عارضه‌مبنا

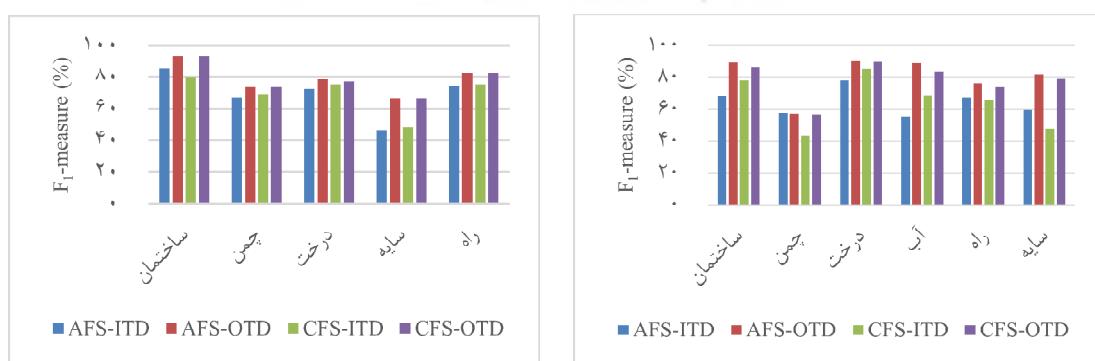
روش	نسخه	معیارهای ارزیابی	تصویر آزمون ۱								تصویر آزمون ۲										
			AFS				CFS				AFS				CFS						
			ITD	OTD	ITD	OTD	ITD	OTD	ITD	OTD	ITD	OTD	ITD	OTD	ITD	OTD	ITD	OTD			
آدابوست عارضه‌مبنا	Ada	O.A	۴۹/۸۶۶	۸۳/۳۳۸	۷۶/۲۸۶	۸۱/۳۳۸	۶۹/۹۶۳	۷۸/۰۵۱	۷۰/۹۸۱	۷۸/۰۲۹	آدابوست عارضه‌مبنا	MH-Stump	O.A	۵۸/۷۵۷	۸۲/۳۴۳	۵۹/۷۷۸	۷۸/۹۵۱	۷۳/۱۲۳	۷۷/۳۱۸	۶۹/۲۱۳	۷۶/۶۳۶
		K.C	۰/۳۸۶	۰/۷۹۰	۰/۷۰۶	۰/۷۶۵	۰/۶۱۳	۰/۷۱۱	۰/۶۱۵	۰/۷۱۰			K.C	۰/۵۰۲	۰/۷۷۸	۰/۵۰۹	۰/۷۳۷	۰/۶۴۵	۰/۷۰۰	۰/۵۹۴	۰/۶۹۱
		Q.P	۳۳/۵۷۳	۷۱/۹۲۲	۵۹/۳۳۴	۶۴/۷۹۲	۵۴/۶۵۲	۶۴/۷۷۴	۵۴/۵۲۲	۶۴/۶۵۸			Q.P	۴۳/۵۶۳	۷۰/۵۲۸	۴۳/۴۴۵	۶۶/۰۸۹	۵۷/۱۴۱	۶۳/۸۱۲	۵۳/۲۴۹	۶۲/۹۵۳
		F_1	۴۸/۲۷۹	۸۰/۸۸۷	۷۴/۷۸۷	۷۷/۸۱۵	۷۱/۰۱۷	۷۸/۱۲۹	۶۲/۹۰۷	۷۷/۵۸۱			F_1	۶۰/۷۶۷	۷۹/۲۹۱	۵۷/۹۳۸	۷۴/۷۲۹	۶۸/۲۶۲	۷۶/۵۲۴	۶۵/۳۷۵	۷۶/۲۶۸
آدابوست عارضه‌مبنا	MH-Tree	O.A	۵۸/۷۵۷	۸۲/۳۴۳	۵۹/۷۷۸	۷۸/۹۵۱	۷۳/۱۲۳	۷۷/۳۱۸	۶۹/۲۱۳	۷۶/۶۳۶			K.C	۰/۵۹۰	۰/۸۰۲	۰/۶۲۱	۰/۷۶۹	۰/۶۳۷	۰/۷۳۱	۰/۶۴۵	۰/۷۲۶
		K.C	۰/۵۰۲	۰/۷۷۸	۰/۵۰۹	۰/۷۳۷	۰/۶۴۵	۰/۷۰۰	۰/۵۹۴	۰/۶۹۱			Q.P	۵۰/۱۱۸	۷۳/۰۱۴	۵۳/۴۵۲	۶۹/۰۳۰۲	۵۷/۱۰۶	۶۶/۸۸۵	۵۷/۴۸۷	۶۶/۴۰۹
		F_1	۶۰/۷۶۷	۷۹/۲۹۱	۵۷/۹۳۸	۷۴/۷۲۹	۶۸/۲۶۲	۷۶/۵۲۴	۶۵/۳۷۵	۷۶/۲۶۸			O.A	۶۶/۵۶۷	۸۴/۲۳۷	۶۹/۷۹	۸۱/۵۹۵	۷۲/۲۶۹	۷۹/۶۳۷	۷۲/۸۵۳	۷۹/۲۶۲
		F_1	۶۶/۹۰۵	۸۱/۸۴۶	۶۶/۵۶۲	۷۸/۹۱۱	۶۹/۸۲۵	۷۹/۱۸۱	۷۰/۳۳۱	۷۸/۹۵۹			F_1	۶۰/۱۱۸	۷۳/۰۱۴	۵۳/۴۵۲	۶۹/۰۳۰۲	۵۷/۱۰۶	۶۶/۸۸۵	۵۷/۴۸۷	۶۶/۴۰۹

- Overall Accuracy (O.A)
- Kappa Coefficient (K.C)
- Quality Percent (Q.P)
- All Feature Set (AFS)

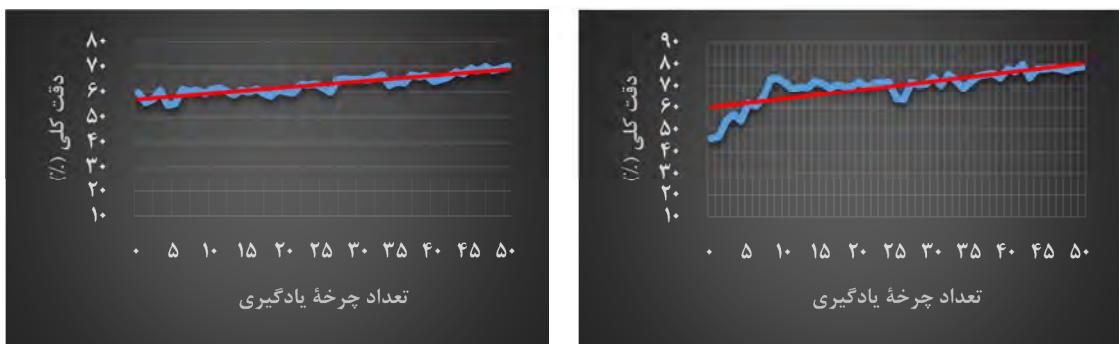
دو تصویر مطالعاتی برای چهار روش احرایی با نسخه MH-Tree مطابق نمودارهای شکل ۵، مشاهده می‌شود که کلاس‌های ساختمان، چمن و راه در تصویر ۲ و کلاس‌های درخت و سایه در تصویر ۱ دقتهای بالاتری حاصل کرده‌اند. این نتایج، براساس ویژگی‌های متفاوت دو تصویر، منطقی است زیرا از یکسو، ابعاد عوارض در تصویر ۱ بزرگ‌تر از تصویر ۲ است و از سوی دیگر، تعداد عوارضی مانند ساختمان و چمن در تصویر ۲ بیشتر از تصویر ۱ است. وجود کلاس آب در تصویر ۱ نیز موجب تفاوت طیفی آن با تصویر ۲ شده است. به طور کلی نتایج جدول ۲ و نمودارهای شکل ۵ نشان می‌دهد که در هر دو تصویر مطالعاتی، رویکرد پیشنهادی (CFS-OTD و AFS-OTD) سبب ایجاد بهبود چشمگیری در دقت طبقه‌بندی آدابوست عارضه‌منبا، در قیاس با شرایط اولیه مسئله شده است. به‌ویژه در تصویر تست ۱ و نسخه Ada، مشاهده می‌شود که با استفاده از مجموعه آموزشی بهینه، حدود ۳۴٪، ۴۱٪، ۳۸٪ و ۳۳٪ بهترین معيار دقت کلی، ضریب کاپا، درصد کیفیت و معيار F_1 ، افزایش داشته است. نمودارهای شکل ۶ دقتهای کلی مدل یادگیری فعال را به نسبت تعداد چرخه یادگیری در فرایند تولید مجموعه آموزشی بهینه، درمورد دو تصویر تست، نشان می‌دهد. در این نمودارها، همان‌طور که انتظار می‌رفت، روند بهبود دقت کلی با افزایش تعداد چرخه یادگیری مشاهده می‌شود.

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 احرایی، مشاهده می‌شود که روش AFS-OTD بیشترین دقتهای را دربر داشته است. همچنین مقایسه بین بیشترین دقتهای حاصل در هریک 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، به طور 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 صحنۀ تصویر است، عملکرد بهتری دارد. از سویی، پایین‌بودن اختلاف دقت این دو روش بیان می‌کند، با استفاده از زیرمجموعه ویژگی منتخب، بدون ازدست‌دادن مقدار معنایه اطلاعات می‌توان ابعاد فضای ویژگی را کاهش داد. علاوه بر این، با مقایسه دقت کلاس‌های پوششی در



شکل ۵. نمودار دقت کلاسی طبقه‌بندی عارضه‌منبا به روش MH-Tree براساس معيار ارزیابی F_1



شکل ۶. نمودار دقت کلی مدل یادگیری فعال بر حسب تعداد چرخه یادگیری

فلفل- نمکی موجود در خروجی طبقه‌بندی پیکسل مبنا، این بهبود دقت انتظار می‌رفت. در بررسی و قیاس روش‌های متفاوت طبقه‌بندی، یکی از رویکردهای تحلیلی بررسی روشنی 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 موضعی 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 به صورت دودویی با هم قیاس کرد و سطح وابستگی آماری بین آن دو را مورد تحلیل قرار داد؛ بنابراین به منظور بررسی معنی‌داری اختلاف‌های ذکر شده در نتایج، هریک از روش‌های مورد قیاس، با روش پیشنهادی در سطح معنی‌داری ۹۵٪ بررسی موردنی شد. نتایج این ارزیابی‌ها در جدول ۳ آمده است.

در جدول ۳، نتایج ارزیابی‌های الگوریتم آدابوست در حالت پیکسل مبنا، برای دو تصویر آزمون و با استفاده از مجموعه ویژگی‌های شبکه عمیق (۴۸۴ ویژگی) ادغام شده با سه ویژگی طیفی و یک ویژگی ارتفاعی، آمده است.

مقایسه بین نتایج این جدول با جدول ۲ و با درنظر گرفتن بیشترین دقت‌های این جدول‌ها، مربوط به نسخه MH-Tree، نشان می‌دهد که در تصویر ۱، رویکرد عارضه‌مبنای در قیاس با پیکسل مبنا حدود ۷٪، ۱۲٪ و ۹٪ به ترتیب دقت کلی، ضریب کاپا، درصد کیفیت و معیار F₁ را بهبود داده است. این نتایج بیان می‌کند رویکرد عارضه‌مبنای پیشنهادی، از نظر دقت طبقه‌بندی، عملکردی بسیار بهتر از حالت پیکسل مبنا دارد زیرا در رویکرد عارضه‌مبنای ویژگی‌های هندسی نیز، افزون بر دیگر ویژگی‌ها، در بهبود دقت طبقه‌بندی تأثیرگذار است. همچنین به دلیل حذف نویزهای

جدول ۳. نتایج ارزیابی آدابوست پیکسل مبنا؛ بیشینه مقادیر با زیرخط تمایز 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

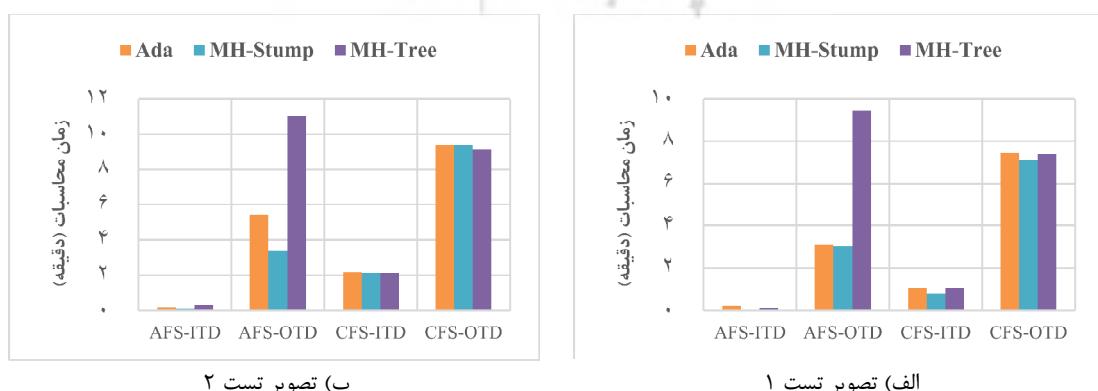
جدول ۴. نتایج ارزیابی روش پیشنهادی با سایر روش‌ها بر حسب آزمون آماری مکنمار

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 جستجو 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. به طور کلی طبق نمودارهای پیشین و با درنظر 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 می‌کند.

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 با روش 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، به نسبت دو نسخه دیگر آدابوست در روش AFS-OTD، در خور توجه است. این امر ناشی از آن است که با استفاده از درخت طبقه‌بندی با تعداد گره معین، به منزله یادگیرنده پایه آدابوست، لازم است در هر تکرار برای تشکیل هر گره داخلی درخت، تمامی



شکل ۷. نمودار ارزیابی زمان محاسبات مدل آدابوست عارضه‌مبنا

ماهیت تکرارشونده سبب ایجاد محدودیت زمانی نمی‌شوند زیرا ابعاد فضای مسئله، در سطح عارضه به‌نسبت سطح پیکسل، به‌شدت کاهش می‌یابد؛ بنابراین در این طرح پیشنهادی، نگرانی ناشی از محدودیت زمان محاسبات وجود ندارد. برای تحقیقات آتی، پیشنهاد این است که طرح بیان شده در این تحقیق، براساس ایدهٔ یادگیری نیمه‌نظرارت شده به‌منظور طبقه‌بندی عارضه‌مبنا 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.
- Baatz, 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).
- Baatz, M., Benz, U., Dehghani, S., Heynen, M., Höltje, 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.

۵- نتیجه‌گیری

در این تحقیق، به‌منظور طبقه‌بندی پوشش زمین در تصاویر با حد تفکیک مکانی بالا، ابتدا ویژگی‌های بافت با استفاده از استخراج‌گرهای ویژگی شبکه‌عمیق 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 طراحی شده مبتنی بر یادگیری فعال و نیز زیرمجموعهٔ ویژگی‌منتخب برپایه محاسبات همبستگی ویژگی‌ها تولید شد تا طبقه‌بندی عارضه‌مبنا آدابوست صورت پذیرد.

در طبقه‌بندی عارضه‌مبنا آدابوست، با تولید مجموعه آموزشی بهینه براساس یادگیری فعال و نیز تولید زیرمجموعهٔ ویژگی‌منتخب برپایه محاسبات همبستگی‌ها، در دو تصویر آرمون و سه نسخهٔ الگوریتم آدابوست، به‌طور میانگین بهبود در دقت کلی و ضریب کاپا مشاهده شد. میزان این بهبود به ترتیب ۲۶٪ / ۳۷٪ و ۷٪ / ۶٪ به‌نسبت طبقه‌بندی پیکسل‌مبنا آدابوست بوده است. علت آن ایجاد تناسب بین نمونه‌های آموزشی و ویژگی‌ها در فضای ویژگی مسئله است زیرا فرایند انتخاب ویژگی و انتخاب فرضیهٔ ضعیف در آدابوست مستقیماً از تعداد و توزیع نمونه‌های آموزشی در فضای ویژگی تأثیر می‌پذیرد. از این‌رو در این تحقیق، با استفاده از ایدهٔ یادگیری فعال، سیستمی هوشمند برای انتخاب نمونه‌های آموزشی مناسب طبقه‌بندی کننده آدابوست ایجاد شد و نتایج ارزیابی‌ها کارآمدی این طرح پیشنهادی را اثبات کردند. اما در این روش، با افزایش تعداد چرخهٔ یادگیری، زمان محاسبات افزایش می‌یابد که با انتخاب تعداد تکرار محدود و مناسب، می‌توان افزایش زمان محاسبات را کنترل کرد. در طرح تولید زیرمجموعهٔ ویژگی‌منتخب مبتنی بر همبستگی‌ها نیز، با انتخاب زیرمجموعهٔ ویژگی تصادفی به تعداد مناسب می‌توان در زمانی بهینه به دقت مطلوب رسید. با این اوصاف، در طبقه‌بندی عارضه‌مبنا، الگوریتم‌های دارای

- 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. & Hadid, 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.



سنجش از دور

، ایران GIS

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

19-36



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