

تشخیص و تدقیق پهنه‌های آبی به کمک رویکرد حد‌آستانه‌گذاری محلی با استخراج ویژگی از تصاویر ماهواره‌ای راداری (مطالعه موردی: دریاچه‌های زریبار و چیتگر)

فرزانه نعیمی اصل^۱، مهدی آخوندزاده هنزائی^{۲*}

^۱ دانشجوی کارشناسی ارشد دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

farzanenaeimi@ut.ac.ir

^۲ دانشیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

makhonz@ut.ac.ir

(دریافت: تیر ۱۴۰۳، تصویب: مرداد ۱۴۰۳)

چکیده

کمبود آب به وجود آمده در اثر خشکسالی‌های اخیر، تغییرات اقلیمی، رشد جمعیت و مصرف بیش‌ازحد منابع آبی، تأثیرات گسترده‌ای بر زندگی انسان‌ها، حیوانات و گیاهان داشته است. کشور ایران، به دلیل موقعیت جغرافیایی، تغییرات آب و هوایی و کمبود منابع آبی، در آستانه قرارگیری در یک بحران آبی است. آب‌های سطحی مانند دریاچه‌ها نیز تحت تأثیر این بحران قرار گرفته‌اند. از این‌رو، نظارت، کنترل مناسب و مدیریت صحیح منابع آب امری ضروری است. این نظارت می‌تواند به‌طور سریع و دقیق از طریق به‌کارگیری تصاویر ماهواره‌ای ممکن شود و به‌طور مداوم وضعیت منابع آب سطحی را گزارش کند. در این پژوهش، با استفاده از تصاویر ماهواره‌ای راداری، سطح بدنه آبی دریاچه زریبار در استان کردستان از طریق یک رویکرد حد‌آستانه‌گذاری محلی تعیین شد. این رویکرد شامل سه گام اصلی در عملیات پیاده‌سازی می‌باشد. در گام اول، تحت یک فرآیند استخراج ویژگی، ۴ دسته‌ویژگی مجزا اعم از: ویژگی‌های بافت، ریاضی، هندسی و پلاریمتریک از تصویر رادار اولیه استخراج شدند. سپس، فرآیند طبقه‌بندی به کمک ۴ مدل طبقه‌بندی یادگیری ماشین انجام شد و یک تصویر طبقه‌بندی اولیه از منطقه به دست آمد. در گام دوم، با اعمال حد‌آستانه سراسری بر تصویر رادار منطقه، خوشه آب اولیه منطقه نیز به دست می‌آید. در گام نهایی، به‌منظور بهبود و تدقیق خوشه آب اولیه، فرآیند حد‌آستانه‌گذاری محلی انجام می‌شود. در این فرآیند، با تکیه بر خصوصیات منطقه، نوع، تعداد و مکان قرارگیری کاربری‌های موجود و با محاسبه توابع چگالی احتمال (PDF)، حد‌آستانه‌های محلی برای هر خوشه از منطقه به‌طور مجزا تعیین می‌گردد. با اعمال حد‌آستانه‌های محلی و سپس اعمال یک سری محدودیت‌های هیدرولوژی، نقشه نهایی آب سطحی به دست می‌آید. نتایج حاصل از رویکرد پیشنهادی این پژوهش نشان می‌دهد که حد‌آستانه‌گذاری محلی با کسب دقت‌های ۹۵/۴۴٪ و ۹۸/۲۷٪ به ترتیب مربوط به معیارهای AUC و امتیاز F1 موفق به تشخیص و بهبود محدوده آب سطحی بوده است. همچنین آزمایش تشخیص تغییرات دریاچه چیتگر به منظور به چالش کشیدن قدرت رویکرد ارائه‌شده، پیاده‌سازی و اجرا شد. نتایج حاصل از این آزمایش با کسب دقت ۹۴/۵۵ و ۹۶/۶۵ به ترتیب مربوط به معیارهای AUC و امتیاز F1، بر کارایی رویکرد پیشنهادی صحت گذاشت.

واژگان کلیدی: سنجنش از دور راداری، استخراج ویژگی، یادگیری ماشین، حد‌آستانه‌گذاری محلی، تابع چگالی احتمال (PDF).

* نویسنده رابط

۱- مقدمه

پهنه‌های آبی شامل هر انباشت قابل توجهی از آب بر روی سطح زمین است از این‌رو منابع آب‌های سطحی شامل رودخانه‌ها، دریاچه‌ها، باتلاق‌ها و اقیانوس‌ها، همچنین انباشت‌های کوچک‌تری از آب مانند تالاب‌ها، آبگیرها، چاله‌های آب و سطوح سیلابی نیز در دسته پهنه‌های آبی قرار می‌گیرند [۱].

افزایش جمعیت و مصرف مداوم منابع آب، نیاز به نظارت بیشتر بر حجم و کیفیت آب را به همراه دارد. از آنجاییکه منابع آب سطحی از مهم‌ترین مؤلفه‌های حیات سرزمین و از عوامل توسعه پایدار به شمار می‌روند، مطالعه توزیع مکانی و زمانی منابع آب‌های سطحی به‌ویژه در مناطق پرجمعیت و در معرض تغییرات اقلیمی و آب و هوایی بسیار حیاتی است [۲]. با شناسایی و بررسی ابعاد سطوح آبی می‌توان درک بهتری از توزیع و گستردگی مکانی این پدیده به دست آورد. نتایج به‌دست‌آمده در انتها بینش بهتری نسبت به دینامیک پوشش آب ارائه می‌دهد و امکان نظارت بر تغییرات مربوط به آب‌وهوا و یا تغییرات اقلیمی را فراهم می‌سازد.

روش‌های سنتی نقشه‌برداری علی‌رغم دارا بودن دقت بالا در تهیه اطلاعات زمینی، زمان‌بر و هزینه‌بر بوده و امکان استفاده از آن در مقیاس بزرگ و مناطق با دسترسی سخت و صعب‌العبور ناممکن است. از این‌رو سنجش از دور با گردآوری اطلاعات مناسب در کمترین زمان، به‌عنوان ابزاری کارآمد جهت شناسایی و پایش عوارض زمین به استفاده متخصصان درآمده است [۳].

با افزایش تعداد ماهواره‌های رصدکننده زمین که تنوع زیادی از داده‌های سطح زمین را ارائه می‌کنند، نظارت بر آب‌های سطحی از مقیاس منطقه‌ای تا جهانی قابل انجام است. با این‌حال و باوجود مطالعات متعدد گذشته پیرامون تشخیص سطوح و پهنه‌های آبی گوناگون، این حوزه همچنان با کمبودها و محدودیت‌هایی روبروست. نقشه‌برداری از آب‌های سطحی همواره چالش‌برانگیز بوده و تأمین دقت موردنیاز برای طیف وسیعی از زمینه‌ها و کاربردها دشوار است. به علت پوشش‌های گوناگون زمین و کاربری مختلف مناطق، دقت الگوریتم‌های تشخیص به‌شدت متفاوت است.

درحالی‌که تصاویر نوری^۱ در شرایط وجود ابر و یا تصویربرداری در شب با محدودیت مواجه هستند، تصاویر ماهواره‌ای راداری از جمله تصاویر SAR^۲، با داشتن منبع روشنایی فعال می‌توانند در اکثر شرایط آب و هوایی از جمله وجود ابر و در همه ساعات شبانه‌روز مورد استفاده قرار گیرند. همچنین به دلیل داشتن طول‌موج بالاتر (۳ تا ۷۵ سانتی‌متر) دارای عمق نفوذ بیشتری می‌باشند از این‌رو می‌توانند اطلاعات گسترده و دقیق‌تری در اختیار قرار دهند [۴].

مطالعه انجام‌شده توسط لیانگ و همکاران [۵] در سال ۲۰۱۹، با کار روی تصاویر SAR به بررسی و مقایسه چندین روش حدآستانه‌گذاری سراسری و محلی پرداختند. آن‌ها با استفاده از الگوریتم ISODATA تصویر موجود را ناحیه‌بندی کرده و هر ناحیه را به‌صورت مجزا آستانه‌گذاری کردند. نتایج این تحقیق نشان داد حدآستانه‌گذاری محلی که به کمک توزیع احتمال پیاده‌سازی شده است نسبت به سایر روش‌ها نتیجه دقیق‌تری ارائه می‌کند.

در مطالعه‌ای دیگر در سال ۲۰۱۸، ژانگ و همکاران [۶] یک روش طبقه‌بندی دو مرحله‌ای برای طبقه‌بندی تالاب‌ها با داده‌های SAR توسعه داده شد. ابتدا، یک استراتژی آماری جدید برای استخراج و انتخاب ویژگی با توجه به تفاوت‌های بین انواع مختلف پوشش زمین پیشنهاد شد. سپس طبقه‌بندی‌کننده جنگل تصادفی (RF) برای ارزیابی ترکیب‌های مشخصه برای طبقه‌بندی تالاب استفاده شد. دقت کلی و ضرایب کاپا (κ) به ترتیب بالاتر از ۸۹/۷۹٪ و ۰/۸۸ نشان داد که تکنیک ارائه‌شده در برخورد با فضای ویژگی‌های با ابعاد بالا مؤثر بوده و منجر به بهبودهای قابل‌توجهی در طبقه‌بندی شده است.

تحقیقات کلمنت و همکاران [۷] در سال ۲۰۱۸ در منطقه یورکشایر انگلستان نشان داد که از نظر تئوری با به‌کارگیری شاخص‌هایی از قبیل MNDWI می‌توان برای شناسایی مناطق آب اقدام کرد، با این‌حال، تفاوت‌ها در پارامترهای جذب حسگر و ویژگی‌های تصویر جغرافیایی می‌تواند طیف متفاوتی از مقادیر را ایجاد کند که نیاز به آستانه‌گذاری تک تصویر را ضروری می‌کند.

^۱ optic

^۲ Synthetic aperture radar

با توجه به مطالعات پیشین، روش‌های تشخیص و طبقه‌بندی تصویر را می‌توان در این دسته‌بندی خلاصه کرد: (الف) روش‌های آستانه‌مبنا؛ (ب) روش‌های شاخص‌مبنا؛ (ج) روش‌های یادگیری‌مبنا و (د) روش‌های تغییرمبنا [۸].

روش‌های شاخص‌مبنا در قالب استفاده از شاخص‌های طیفی برای افزایش تشخیص بدنه‌های آبی توسعه یافته‌اند. این شاخص‌ها ترکیب‌های ریاضی از باندهای طیفی مختلف از تصاویر ماهواره‌ای هستند که برای برجسته‌سازی ویژگی‌های خاص طراحی شده‌اند. علیرغم کارایی و سرعت دستیابی به نتیجه، این روش قادر به تمایز بین اجسام سایه، تاریک و آب نبوده و در برخی مناطق بازتابی یا چالش‌برانگیز طیف مثبت کاذب تشکیل می‌دهد [۹]. روش‌های طبقه‌بندی یادگیری‌مبنا شامل الگوریتم‌هایی است که الگوها، روابط را در داده‌ها شناسایی می‌کند و به آن اجازه تعمیم داده‌ها و عملکرد متناسب روی داده‌های جدید و نادیده را می‌دهد. یادگیری عمیق نیز به‌عنوان یک زیرمجموعه گسترده از یادگیری ماشین در دهه اخیر توسعه زیادی داشته و در قالب مدل‌ها و معماری‌های گوناگون معرفی شده‌است. علیرغم قدرت تشخیص بالای این روش‌ها، زمان‌بر بودن مرحله آموزش، نیاز به داده‌های آموزشی قابل‌توجه و همچنین متکی بودن عملکرد آن‌ها به کیفیت و بازنمایی نمونه‌های آموزشی، از محدودیت‌های این روش‌ها به شمار می‌رود [۱۰]. از دهه‌های گذشته تاکنون، روش‌های تغییرمبنا یا تشخیص تغییرات شامل: شاخص نسبی، شاخص لگاریتم، شاخص اختلافی، شاخص تغییر نرمال‌شده و .. نیز جهت تشخیص و طبقه‌بندی تغییرات بکار گرفته شده‌اند و عملکرد قابل قبولی از خود نشان داده‌اند، بااین‌حال در برخی موارد مستعد نویز بوده و به کیفیت داده‌ها و وضوح تصویر حساس است [۸].

روش‌های آستانه‌مبنا شامل تنظیم یک مقدار شدت پیکسل است که مقادیر بالاتر و پایین‌تر از آن به‌عنوان کلاس‌های مجزا طبقه‌بندی می‌شوند. شناخته‌شده‌ترین روش حدآستانه‌گذاری در سال ۱۹۷۹ توسط اُتسو (Otsu) [۱۱] مطرح شد که حدآستانه را از طریق بیشینه‌سازی واریانس بین کلاس‌ها تعیین می‌کرد. سایر روش‌های آستانه‌گذاری شامل روش حدآستانه آنتروپی [۱۲، ۱۳] و روش هیستوگرام دو مدی [۱۴] هستند.


در بسیاری از روش‌های آستانه‌مبنا، حدآستانه‌گذاری به صورت سراسری انجام می‌شود به این معنا که تنها یک مقدار حدآستانه واحد جهت تقسیم‌بندی و تفکیک عوارض تصویر در نظر گرفته می‌شود. یک آستانه کوچک‌تر معمولاً وسعت آب را با اطمینان بالاتر مشخص می‌کند، در مقابل آستانه بزرگ‌تر باعث افزایش اطمینان در شناسایی زمین‌های خشک می‌شود [۱۵]. علیرغم اینکه اینگونه روش‌ها از نظر محاسباتی زمان‌بر نبوده و دقت مطلوبی را ارائه می‌کند بااین‌حال، حدآستانه‌گذاری سراسری با طبقه‌بندی تصویر به دو کلاس آب و غیرآب و قراردادن تمامی کلاس‌های خشکی ممکن از جمله: زمین کشاورزی، تپه‌های تنک، مناطق جلگه‌ای، شهری و ... در یک کلاس غیرآب، تمایز میان کلاس‌های گوناگون را از بین می‌برد و منجر به دست‌کم گرفتن^۱ کلاس آب می‌شود [۵]. این موضوع یکی از چالش‌های جدی به خصوص در مناطقی است که دارای تعدد در کلاس‌های خشکی هم‌مرز با آب هستند. به عبارت دیگر مناطقی که در آنها کلاس آب با کلاس‌های خشکی متعددی در تماس است، در نظر گرفتن حدآستانه واحد منجر به خطایی ملموس می‌شود.

در این تحقیق به منظور در نظر گرفتن تمایز میان کلاس‌ها یا خوشه‌های موجود در منطقه، بر توجه به خصوصیات منطقه‌ای تاکید شده‌است. این خصوصیات در قالب دو جنبه در بخش‌های استخراج ویژگی و حدآستانه‌گذاری محلی در نظر گرفته شده‌است. در بخش استخراج ویژگی، ویژگی‌هایی نظیر بافت می‌تواند گویای خصوصیتی از منطقه مانند نوع کاربری باشد که طی فرآیند طبقه‌بندی منجر به تفکیک مناسب بین نواحی و کاربری‌های منطقه می‌گردد. همچنین با پیاده‌سازی حدآستانه‌گذاری به صورت محلی و مجزا در هر ناحیه، بر تاثیر و اهمیت تحلیل هر ناحیه با تکیه بر خصوصیات آن ناحیه به صورت مجزا تاکید شده است.

عمرانی و همکاران [۱۶] در مطالعه خود در سال ۲۰۱۸، ویژگی‌های مبتنی بر الگوریتم HOG^۲ را از تصاویر SAR استخراج کردند. سپس با استفاده از الگوریتم K-means یک تصویر خوشه‌بندی اولیه تولید کردند.

۱ Underestimation

۲ Histogram of Oriented Gradients (HOG)



شکل ۱- موقعیت منطقه مورد مطالعه

توجه به خصوصیات منطقه‌ای و تفکیک خوشه‌های غیرآبی از یکدیگر، با استفاده از رویکرد استخراج ویژگی و سپس بکارگیری روش‌های طبقه‌بندی، یک تصویر طبقه‌بندی‌شده اولیه تولید می‌شود. این فرآیند با هدف تفکیک نواحی کلی منطقه از یکدیگر و ایجاد خوشه‌های اولیه انجام می‌شود. از این رو کلیت این فرآیند را با توجه به هدف تعریف‌شده، خوشه‌بندی می‌نامیم. در بخش دوم به‌منظور بهبود و اصلاح خوشه‌های اولیه و بازیابی آن بخش از طبقات به‌اشتباه تخصیص‌یافته، روش حدآستانه‌گذاری محلی بر مبنای توزیع احتمال بکار گرفته می‌شود و در آن برای هر خوشه غیرآبی در تماس با آب، حدآستانه‌ای منحصر به فرد تعریف می‌شود. بدین ترتیب مرز اولیه بین طبقات اصلاح‌شده و طبقه‌بندی بهبود می‌یابد.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

دریاچه زریبار، واقع در فاصله ۳ کیلومتری غرب شهر مریوان، شهرستان مریوان، استان کردستان در غرب ایران، یک عارضه طبیعی بسیار مهم است (شکل ۱). این دریاچه در طول جغرافیایی $46^{\circ}08'$ و عرض جغرافیایی $35^{\circ}32'$ با ارتفاع ۱۲۸۵ متر، طول ۵ کیلومتر، حداکثر عرض ۱.۶ کیلومتر، حداکثر عمق ۶ متر، مساحت ۸.۹ کیلومترمربع و

قنبری و همکاران [۱۷] در سال ۲۰۱۹، با استخراج ویژگی‌های پلاریمتریک فشرده^۱ (CP) از قبیل: پارامتر مکانیسم پراکندگی، نسبت پلاریزاسیون دایره‌ای، ضریب انطباق، ضریب همبستگی RH^۲ و RV^۳ و ... و ترکیب آن با الگوریتم تقسیم‌بندی بدون نظارت IRGS^۴ اقدام به طبقه‌بندی تصاویر RADARSAT مربوط به تنگه بارو، واقع در نزدیکی جزیره سامرست در شمال کانادا کردند.

سایر مطالعات دربرگیرنده دیگر ویژگی‌های ممکن قابل استخراج از تصاویر راداری هستند. در این مطالعه کلیه ویژگی‌های ممکن بررسی و بکارگرفته شد. این ویژگی‌های در ۵ دسته‌بندی: طیفی، بافت، ریاضی، هندسی و پلاریمتریک تقسیم‌بندی می‌شوند.

هدف کلی این مطالعه، توسعه رویکردی کارآمد جهت تشخیص و تدقیق پهنه‌های آب سطحی با استفاده از تصاویر ماهواره‌ای راداری و با تمرکز بر خصوصیات منطقه‌ای است. در این تحقیق به منظور برطرف ساختن چالش ذکرشده در روش‌های حدآستانه‌گذاری سراسری، یک رویکرد آستانه‌گذاری محلی توسعه داده شده‌است که شامل دو بخش کلی می‌باشد. در بخش اول به جهت لزوم

^۱ Compact Polarimetric (CP)

^۲ Right-Handed Circular Polarization

^۳ Vertical-Horizontal Polarization

^۴ Iterative Region Growing using Semantics (IRGS)

حجم تقریبی ۳۰ میلیون مترمکعب، از نظر ابعاد یکی از بزرگترین دریاچه‌ها در منطقه است [۱۸]. آب دریاچه زیربار از بارندگی‌های فصلی (که میانگین آن ۶۵۰ میلی‌متر در سال است) و چشمه‌های زیرآبی کف دریاچه تأمین می‌شود. محیط دریاچه حدود ۵/۲۲ کیلومتر، رطوبت نسبی برابر ۵۸/۴ درصد و متوسط تبخیر سالانه ۱۹۰۰ میلی‌متر می‌باشد [۱۹].

منطقه دریاچه زیربار توسط یک مجموعه زیستگاهی مرطوب، کوهستان‌ها، جنگل‌ها و زمین‌های کشاورزی احاطه شده‌است. بخش‌های زیادی از منطقه توسط مزارع آبی و زمین‌های کشاورزی دیم (به نسبت ۶۰ درصد)، جنگل‌های بلوط (به نسبت ۲۳ درصد) و مراتع (به نسبت ۱۷ درصد) پوشانده شده‌اند [۲۰]. در سال‌های اخیر، عوامل مختلف از جمله رشد جمعیت، ورود رسوبات، آلودگی به فاضلاب و رشد جلبک‌ها در اثر نزارها و سیلاب‌های وسیع در اطراف دریاچه باعث تغییرات کمی و کیفی و مشکلات زیست‌محیطی در آب سطح دریاچه شده‌است [۲۱].

۲-۲- داده‌ها و پیش‌پردازش

در این پژوهش، تصاویر ماهواره‌ای مختلف به‌عنوان مواد اولیه موردنیاز جهت پیشبرد بخش‌های گوناگون تحقیق از طریق سامانه گوگل ارث انجین در دسترس قرار گرفت. این تصاویر شامل تصویر راداری سنتینل-۱ منطقه با فرمت GRD جهت انجام پردازش اصلی و داده SRTM (۹۰ متر) به‌منظور دستیابی به توپوگرافی منطقه جهت انجام پس‌پردازش لازم است. استان کردستان در ناحیه کوهستانی و در معرض وزش باد قرار دارد [۲۲]. وزش باد منجر به آشفته‌گی و زبری سطح آب می‌گردد. در این وضعیت استفاده از پلاریزاسیون‌های عمودی VV می‌تواند تأثیرات زبری آب را در نظر بگیرد. همچنین پلاریزاسیون VH که شامل سیگنال‌های قطبی افقی در برگشت بوده و حساس‌تر به سطوح حجمی می‌باشد به‌علاوه تصویر میانگین دو پلاریزاسیون VH و VV می‌تواند اطلاعات قابل‌توجهی از سطح آب در اختیار قرار دهد

این پلاریزاسیون‌ها در قالب سه باند مختلف تصویر راداری برای منطقه مورد مطالعه اخذ شدند که در شکل ۲ نمایش داده شده‌است. تصویر اخذشده با توان تفکیک ۱۰ متر و ابعاد ۸۰۰ × ۵۰۰ پیکسل می‌باشد و دربرگیرنده کل محدوده مطالعاتی است. تاریخ اخذ تصویر مربوط به ۴

آوریل ۲۰۲۳ معادل با ۲۰ فروردین ۱۴۰۲ با مد برداشت IW و جهت عبور صعودی^۱ می‌باشد. در این پژوهش، پیش‌پردازش‌های لازم که عبارتند از: تصحیح مداری، تصحیحات کالیبراسیون، حذف نویز و تبدیل به دسی‌بل به کمک سامانه GEE بر روی تصویر راداری منطقه انجام پذیرفت.

حذف نویز یکی از مراحل حیاتی پیش‌پردازش در تجزیه و تحلیل تصاویر SAR می‌باشد. به دلیل نویز لکه‌ای ذاتی در داده‌ها که از ماهیت منسجم سیگنال رادار ناشی می‌شود، کیفیت تصویر را کاهش پیدا می‌کند. این نویز اطلاعات زیربنایی را مبهم می‌کند و مانع از انجام پردازش‌های بعدی می‌شود. این نویز ضربی که با ظاهر دانه‌ای مشخص می‌شود، کنتراست تصویر را کاهش می‌دهد، پراکنده‌های ضعیف را سرکوب می‌کند و جزئیات جعلی را معرفی می‌کند. کاهش موثر لکه برای افزایش تفسیرپذیری تصویر، بهبود استخراج ویژگی، و تسهیل استخراج اطلاعات دقیق برای تمامی کاربردها از جمله: طبقه بندی پوشش زمین، تشخیص تغییر و شناسایی هدف ضروری است.

فرآیند حذف نویز در این بخش پیش‌پردازش این تحقیق به کمک فیلتر پایین‌گذر boxcar در بستر سامانه GEE انجام گردید. فیلتر boxcar که به عنوان فیلتر میانگین متحرک یا فیلتر یکنواخت نیز شناخته می‌شود، یک تکنیک ساده و در عین حال موثر هموارسازی و کاهش نویز استفاده می‌شود. در ابتدا یک هسته^۲ مستطیلی یا مربعی با ابعاد مناسب تعریف می‌گردد. این هسته با میانگین کردن مقادیر پیکسل در همسایگی تعریف شده در اطراف هر پیکسل در تصویر عمل می‌کند. این فیلتر به طور موثر تأکید بیشتری بر مقدار میانگین پیکسل‌های اطراف دارد و در عین حال نوسانات ناشی از نویز لکه‌ای را در تصاویر رادار کاهش می‌دهد. اندازه هسته از نظر ابعاد متفاوت بوده و میزان صاف شدن را تعیین می‌کند.

۲-۳- روش تحقیق


پس از آماده‌سازی و پیش‌پردازش تصویر SAR محدوده مطالعاتی که شامل مناطق مختلف خشکی و آب است، از یک رویکرد حد‌آستانه‌گذاری محلی به‌عنوان یک

۱ ASCENDING

۲ Kernel

رویکرد بهینه برای بهبود حدآستانه‌گذاری سراسری استفاده شود. این رویکرد با تأکید بر خصوصیات منطقه‌ای و تقسیم‌بندی تصویر به انواع مختلف خشکی، حدآستانه‌های محلی منحصربه‌فردی را برای جداسازی پیکسل‌های آب از پیکسل‌های مختلف زمین تعیین

می‌کند. یکی از پیش‌نیازهای انجام حدآستانه‌گذاری محلی در این پژوهش، آماده‌سازی یک تصویر خوشه‌بندی اولیه جهت شناسایی تعداد و محل خوشه‌های مختلف خشکی در منطقه مورد مطالعه و به‌کارگیری آن‌ها جهت تعیین حد آستانه‌ها است.



شکل ۲- نمایش پلاریزاسیون‌های اخذشده از تصاویر سنتینل-۱؛ (الف) باند پلاریزاسیون ۷۷؛ (ب) باند پلاریزاسیون ۷۸؛ (ج) باند میانگین پلاریزاسیون‌های ۷۷ و ۷۸.


منظور از خوشه‌بندی در این مرحله انجام ناحیه‌بندی و تعریف زون‌های کوچک‌تر با خصوصیات منطقه‌ای یکسان جهت انجام مراحل بعدی پردازش است.

بدین ترتیب یک فرآیند ویژگی‌مبنا و یادگیری‌مبنا جهت تخمین تصویر خوشه‌بندی بکار گرفته می‌شود. در این فرآیند ابتدا ویژگی‌های خاص تصویر از جمله: ویژگی‌های طیفی، شکل، بافت و پلاریتریک، استخراج می‌شوند. توجه به نوع پوشش و خصوصیات فیزیکی هر زون از منطقه مورد مطالعه، از دلایل ضرورت ناحیه‌بندی در این مرحله از پردازش است. در نظر نگرفتن اختلاف نوع پوشش، تغییرات توپولوژی و ویژگی‌های طبیعی هر ناحیه منجر به بروز خطایی قابل توجه می‌شود.

خوشه‌بندی یا ناحیه‌بندی تصویر و تفکیک مناطق با خصوصیات یکسان به منظور قادر ساختن مدل جهت تعریف حدآستانه محلی مناسب در هر منطقه، برای مراحل بعدی تحقیق ضروری است. در این مرحله ویژگی‌های انتخابی مرحله پیش به یک طبقه‌بندی‌کننده مناسب داده می‌شوند و تصویر خوشه‌بندی تولید می‌گردد. طبقه‌بندی‌کننده‌ها،

یک دسته از الگوریتم‌های یادگیری ماشین هستند که برای تشخیص و طبقه‌بندی الگوها و داده‌های ورودی به طبقات مختلف استفاده می‌شوند. این الگوریتم‌ها به صورت متنوعی طراحی شده‌اند و می‌توانند از مدل‌های ساده تا پیچیده‌تر مانند: ماشین‌های بردار پشتیبان (SVM)، جنگل تصادفی (RF)، K-نزدیک‌ترین همسایگی (KNN) و درخت تصمیم (Descion Tree) را شامل شوند. در این تحقیق، طبقه‌بندی‌کننده‌های مختلف با یکدیگر مقایسه شده و بهترین آن‌ها انتخاب می‌گردد.

علاوه بر تصویر خوشه‌بندی منطقه از روش حدآستانه‌گذاری سراسری جهت تخمین خوشه آب اولیه استفاده می‌شود. خوشه آب اولیه ناگزیر شامل خطاهایی در مرز خود با سایر خوشه‌ها می‌باشد که این خطا در مراحل بعد و به کمک حدآستانه‌گذاری محلی بهبود می‌یابد. در گام نهایی آستانه‌های محلی در هر زیرمجموعه از خوشه خشکی که با خوشه آب جفت می‌شود، با برازش تابع چگالی احتمال در هر زیرمجموعه تخمین زده می‌شود.



شکل ۳-فلوچارت کلی مراحل پژوهش.

در این پژوهش، در مجموع ۱۵۵ ورودی شامل ۳ بانده اصلی تصویر راداری (VH، VV و میانگین VH و VV) به علاوه ۱۵۲ ویژگی گوناگون متعلق به ۴ دسته کلی شامل ویژگی‌های: (۱) بافتی، (۲) ریاضی، (۳) هندسی و (۴) پلاریمتریک استخراج شده است که لیست کلی آن در جدول ۱ قابل مشاهده است.

ویژگی‌های بافتی به الگوها، ساختارها یا ترتیبات بصری پیکسل‌ها در ارتباط با یکدیگر اشاره دارند. یک روش برای محاسبه بافت، استفاده از ماتریس هم‌وقوع سطح خاکستری^۱ (GLCM) است. GLCM توزیع مقادیر پیکسل‌های هم‌زمان در یک منطقه مشخص از یک تصویر را مشخص می‌کند و یک نمایش آماری از بافت مشتق شده از هیستوگرام تصویر را ارائه می‌دهد [۲۳]. ویژگی‌های GLCM که در این تحقیق استفاده شده است در جدول (۳-۱) آورده شده است.

سپس، محدوده‌های آب محلی در هر زیرمجموعه مشخص شده و با خوشه آب اصلی ادغام می‌گردند. به این ترتیب با به کارگیری آستانه گذاری محلی طبقات اولیه بهبود می‌یابند. در نهایت در مرحله پس پردازش نتیجه حاصل از حد آستانه گذاری محلی با وضع یک سری محدودیت‌های هیدرولوژی ارتقاء می‌یابد و نقشه نهایی آب سطحی بدست می‌آید. شکل ۳ فلوچارت پژوهش حاضر را نمایش می‌دهد. تمامی مراحل پیاده سازی در ادامه به تفصیل بیان می‌گردد.

۲-۳-۱- استخراج ویژگی

فرایند استخراج ویژگی اهمیت بسیاری در شناسایی الگوها، تفکیک کلاس‌ها و افزایش کارایی فرایندهای تحلیل تصویر دارد و به درک و تفسیر اطلاعات موجود در تصاویر رادار کمک می‌کند. ویژگی‌های مؤثر و مفید می‌توانند به طور قابل توجهی کارایی فرایند طبقه بندی را بهبود بخشند.

^۱ Gray-Level Co-occurrence Matrix

جدول ۱ - دسته‌بندی ویژگی‌های استخراج‌شده به علاوه باندهای اصلی تصویر اولیه راداری (اعداد داخل پرانتز بیانگر تعداد مشتقات گرفته‌شده از آن ویژگی است).

پارامتریک	هندسی	ریاضی	بافت	باندهای اصلی
Stokes parameters (4)	Shape index	erosion (4)	mean	VV
scattering mechanism	Canny	dilation (4)	std	VH
circular polarization ratio	Roberts	opening (4)	contrast	VV/2+VH/2
conformity coefficient (ellipticity)	Sobel	closing (4)	dissimilarity	
correlation coefficient	Scharr	moorphological gradient (4)	homogeneity	
relative phase angle	Prewitt	top hat (4)	ASM	
degree of polarizatio		black hat (4)	energy	
Shannon entropy, intensity (2)		hit or miss (4)	max	
degree of linear polar		thin lines removed (4)	Entropy (2)	
linear polarization ratio		molaplacian (4)	Gabor (32)	
orientation of the ellipse		white hat (4)	LBP	
axial ratio of the ellipse		skeleton	Hessian Determinant	
mchi decomposition (3)		adjusted	HOG	
m-delta decomposition (3)		lookup	structure tensor (3)	
		moaverage	Restoration	
		Gaussian (2)		
		DOG		
		LOG		
		Median		
		Variance		
		None local mean (2)		

ویژگی‌های ریاضی شامل مجموعه‌ای گسترده از ابزارهایی است که برای تجزیه و تحلیل، بهبود و استخراج اطلاعات از تصاویر از طریق محاسبات ریاضی بکار می‌روند. روش‌های شناخته‌شده شامل استفاده از فیلترهای میانه، واریانس، گوسین و مشتقات آن مانند فیلتر تفاضل گوسین (DOG) و فیلتر لاپلاسیان گوسین (LOG) که بارزکننده تغییرات شدید شدت بازپراکنش در تصویر است.

عملگرهای مورفولوژی از عملیات باز و بسته کردن عناصر ساختاری برای ساده‌سازی تصویر و استخراج ویژگی‌های مکانی در مقیاس‌ها و اشکال مختلف، استفاده می‌کنند. ویژگی دیگر مورد استفاده که بر اساس شباهت با پیکسل مرکزی، میانگین وزن دار مقادیر پیکسل‌های همسایه را جایگزین مقدار هر پیکسل می‌کند، میانگین غیرمحلی (NLM)^۴ (نام دارد).

دیگر ویژگی‌های اخذشده شامل فیلترهای پایین‌گذر بالاگذر و میان‌گذر است که با حفظ فرکانس‌های خاصی از تصویر به ترتیب منجر به افزایش وضوح تصویر، تشدید لبه‌های تصویر و حذف نویزها یا تشدید سیگنال‌های خاص تصویر می‌شوند.

روش دیگر برای استخراج ویژگی‌های بافت، استفاده از فیلتر گابور است. فیلتر گابور، بر اساس تابع گابور - موج مختلطی که توسط یک تابع گوسی مدوله می‌شود - امکان ضبط هم‌زمان اطلاعات فضایی و فرکانسی در یک تصویر را فراهم می‌کند [۲۴]. در این تحقیق، با تنظیم پارامترهای مختلف فیلتر گابور، شامل جهت (θ)، انحراف معیار گوسی (σ)، طول موج (λ) و نسبت فضایی جانبی (γ)، ۳۲ فیلتر گابور گسسته ایجاد شد و ۳۲ ویژگی بافتی متمایز را تشکیل داد. علاوه بر این، از تنسور ساختار^۱ برای تجزیه و تحلیل اطلاعات بافت استفاده می‌شود که یک نمایش آماری به شکل یک ماتریس است که خلاصه گرادیان‌های شدت تصویر را در سه جهت فراهم می‌کند [۲۵].

سایر ویژگی‌های بافتی استخراج‌شده شامل الگوی باینری محلی (LBP)^۲، دترمینان Hessian (شامل اطلاعات منحنی‌ها و شیب‌های محلی تصویر)، HOG^۳ (شامل جهت‌ها و شیب‌های مختلف در تصویر) و Restoration (بازیابی تصویر با کیفیت واقعی از داده‌های مشوش یا غیرواضح) می‌باشد.

^۱ Structure Tensor

^۲ Local Binary Pattern (LBP)

^۳ Histogram of Oriented Gradients

^۴ None Local Mean (NLM)

ویژگی‌های هندسی به ویژگی‌های شکل عوارض در تصویر اشاره دارد و اطلاعاتی درباره شکل، ساختار و لبه‌های عوارض موجود در تصویر ارائه می‌دهند که منجر به تمایز بین اشیاء، تشخیص الگوها و شناسایی اجسام در تصویر می‌گردد. برخی از ویژگی‌های هندسی متداول که در این مطالعه استفاده شده‌است شامل شاخص شکل و فیلترهای تشخیص لبه است که در جدول ۱ قابل مشاهده است.

ویژگی‌های پلاریمتریک تصویر راداری اطلاعاتی درباره پلاریزاسیون‌های موجود در تصویر ارائه می‌دهد. این ویژگی‌ها معمولاً بر اساس خصوصیات سیگنال پلاریزه شده مانند قطبیت، زاویه پلاریزاسیون و شدت نور پلاریزه شده تعریف می‌شوند. ویژگی‌های پلاریمتریک در تحلیل تصاویر پلاریزه شده مفید هستند و می‌توانند به تمایز بین اجسام، تشخیص الگوها و تحلیل ساختارهای پلاریزه در تصویر کمک کنند.

قنبری و همکاران [۲۶] در سال ۲۰۱۹، ویژگی‌های پلاریمتریک به خصوصی را از داده‌های پلاریمتریک فشرده مناطق یخ‌زده قطبی به دست آوردند. آن‌ها در تحقیق خود از بردارهای استوکس^۱ به‌عنوان بردارهای اولیه برای محاسبه ویژگی‌های پلاریمتری استفاده کردند.

بردارهای استوکس برای نشان دادن خصوصیات پوشش و چرخش میدان برداری در تصاویر راداری استفاده می‌شوند. از آنجاکه تصاویر راداری اطلاعاتی در مورد جریان‌های هوا و امواج الکترومغناطیسی دریافت می‌کنند، بردارهای استوکس در تحلیل تصاویر راداری می‌تواند به بهبود کیفیت تحلیل‌ها و تفسیر داده‌ها کمک کند.

بردار استوکس تابعی از چهار پارامتر واقعی است که میدان بازپراکنش را به‌طور کامل مشخص می‌کند. این بردارها با استفاده از باندهای VH و VV تصویر راداری به‌صورت زیر محاسبه می‌شوند [۲۶]:

$$s_0 = |VV|^2 + |VH|^2 \quad (۱)$$

$$s_1 = |VV|^2 - |VH|^2 \quad (۲)$$

$$s_2 = 2 \times \text{Re}(VV \cdot \overline{VH}) \quad (۳)$$

$$s_3 = -2 \times \text{Re}(VV \cdot \overline{VH}) \quad (۴)$$

که در آن Re نماینده بخش حقیقی مقادیر خود می‌باشد.

علاوه بر اینکه بردارهای استوکس، خود به‌تنهایی جزء ویژگی‌های پلاریمتریک به شمار می‌روند، چندین ویژگی کمی دیگر که میدان بازپراکنش را مشخص می‌کنند از آن حاصل می‌شود. نسبت درجه‌ی قطبش (DoP)، نسبت قطبش دایره‌ای، فاز نسبی، ضریب هم‌پوشانی و ویژگی‌های تجزیه $m\text{-chi}$ از مثال‌های ویژگی‌های مشتق‌شده از بردار استوکس هستند.

۲-۳-۲- الگوریتم‌های طبقه‌بندی یادگیری مبنا

روش‌های یادگیری مبنا از جمله یادگیری ماشین با تکیه بر الگوریتم‌های پیچیده باعث ارتقاء قابلیت‌های تشخیص و دسته‌بندی تصاویر می‌شوند.

در این پژوهش، از چند مدل یادگیری نظارت‌شده جهت طبقه‌بندی تصویر استفاده می‌شود. درنهایت، پس از ارزیابی دقت هر مدل، بهترین مدل به‌عنوان مدل بهینه انتخاب می‌گردد و خروجی حاصل از آن به‌عنوان نماینده ناحیه‌بندی منطقه وارد بخش حد‌آستانه‌گذاری می‌شود.

الگوریتم جنگل تصادفی^۲ (RF) یکی از روش‌های پرکاربرد در حوزه یادگیری ماشین است که بر پایه ایده مجموعه‌ای از درخت‌های تصمیم استوار است. در مرحله پیش‌بینی، برای هر داده ورودی، خروجی تمام درخت‌های تصمیم محاسبه می‌شود و سپس با استفاده از رأی‌گیری (برای مسائل طبقه‌بندی) یا میانگین‌گیری (برای مسائل رگرسیون) خروجی نهایی تعیین می‌شود. با افزایش تعداد درخت‌های تصمیم، می‌توان دقت و عملکرد مدل را بهبود داد [۲۷].

ماشین بردار پشتیبان^۳ یا SVM یک الگوریتم یادگیری ماشین برای مسائل طبقه‌بندی و رگرسیون است و با ساخت یک صفحه تصمیم (برای مسائل دو کلاسه) یا یک فضای ابرصفحه (برای مسائل چند کلاسه) بهترین تفکیک را بین داده‌های ورودی انجام می‌دهد. این الگوریتم به خوبی با داده‌های بزرگ و پیچیده‌ی خطی و غیرخطی سازگاری دارد از این‌رو الگوریتمی کارا برای طبقه‌بندی داده‌ها در مسائل مختلف می‌باشد [۲۸].

^۲ Random Forest (RF)

^۳ Support Vector Machine (SVM)

^۱ Stokes vector

الگوریتم طبقه‌بندی K-نزدیکترین همسایه^۱ (KNN) بر اساس اصل همسایگی عمل می‌کند و برای هر نقطه از داده‌های آموزشی، k نقطه از نزدیک‌ترین همسایگان آن را پیدا می‌کند و بر اساس اکثریت کلاس آن‌ها، نقطه موردنظر را طبقه‌بندی می‌کند [۲۹].

الگوریتم درخت تصمیم^۲ (DT) به صورت یک ساختار درختی با گره‌ها و یال‌ها است که هر گره ویژگی خاصی از داده‌ها را نمایندگی می‌کند و هر یال به تقسیم داده‌ها بر اساس ویژگی‌های مختلف اشاره دارد. انتخاب ویژگی معمولاً بر اساس معیارهایی مانند آنتروپی یا بهبود انطباق داده محاسبه می‌شود. سپس بر اساس ویژگی انتخاب‌شده، داده‌ها به دو یا چند زیرمجموعه تقسیم می‌شوند و برای هر زیرمجموعه، یک گره جدید درخت ایجاد می‌شود که ویژگی مربوطه را نمایندگی می‌کند. این مراحل به صورت بازگشتی ادامه پیدا می‌کند تا تمام داده‌ها به صورت صحیح دسته‌بندی شوند [۳۰].

به کمک چهار مدل یادگیری معرفی‌شده، چهار تصویر طبقه‌بندی مختلف تولید می‌شود پس از ارزیابی دقت‌های حاصل‌شده در هر چهار تصویر، بهترین تصویر طبقه‌بندی‌شده انتخاب و خوشه‌های اولیه منطقه را مشخص می‌کند.

۲-۳-۳- حدآستانه‌گذاری سراسری

ایجاد خوشه آب اولیه (W) به عنوان یکی از پیش‌نیازهای پیاده‌سازی حائز اهمیت است. خوشه آب W صرفاً یک خوشه حدودی و اولیه بوده که در مرحله بعدی در حدآستانه‌گذاری محلی بهبود یافته و تدقیق می‌گردد. در حدآستانه‌گذاری سراسری، یک آستانه یکتا برای کل تصویر تعیین می‌شود که بر اساس آن پیکسل‌های تصویر به دو دسته‌ی مختلف (در اینجا آب و خشکی) تقسیم می‌شوند. اعمال حدآستانه‌گذاری سراسری در این تحقیق به دو منظور انجام می‌شود:

۱) ایجاد خوشه آب اولیه (W): یک آستانه‌گذاری اولیه جهت تمایز کلاس کلی آب انجام می‌شود تا در مراحل بعد به وسیله حدآستانه‌گذاری محلی تدقیق شود.

۲) ارزیابی نتایج روش‌های حدآستانه‌گذاری سراسری با روش حدآستانه‌گذاری محلی مقایسه و تحلیل می‌گردد.

در این مطالعه، حدآستانه‌گذاری سراسری با روش اُتسو [۱۱]، پیاده‌سازی می‌گردد و خوشه آب اولیه W، ایجاد می‌شود. در مقابل پیکسل‌های غیرآب به دست‌آمده از تصویر خوشه‌بندی در مرحله پیش، به n خوشه زمینی (L1, ..., Ln) تقسیم‌بندی شدند. هریک از n خوشه موجود شامل بخشی از خوشه آب W و یکی از خوشه‌های غیرآب Li است. این اتفاق در نتیجه وجود خطای دست‌کم برآورد شدن کلاس آب است که پیش‌تر ذکر شد.

به منظور حل این خطا و تدقیق خوشه آب، رویکرد آستانه‌گذاری محلی در هر یک از این n زیرمجموعه انجام می‌شود. برای هر زیرمجموعه (W + Li)، توزیع بازپراکنش راداری در هر پلاریزاسیون به عنوان مخلوطی از دو توزیع گاما (یکی برای آب و دیگری برای خشکی) تخمین زده می‌شود و تلاقی توزیع‌های دوحالتی حدآستانه‌ی محلی را برای هر زیرمجموعه تعیین می‌کند.

۲-۳-۴- حدآستانه‌گذاری محلی

در حدآستانه‌گذاری محلی، برای هر خوشه تعیین‌شده یک آستانه منحصر به فرد در نظر گرفته می‌شود. این کار منجر به تدقیق مرز واصل کلاس‌های خشکی و آب و تخصیص بخش کم‌برآوردشده به کلاس کلی آب می‌شود. با توجه به اینکه شدت بازپراکنش برای یک سطح همگن از توزیع گاما پیروی می‌کند [۳۱]، جهت تعیین حدآستانه‌ی بهینه در هر خوشه، می‌توان شدت پراکندگی برگشتی (σ^0) هر خوشه را به شکل توزیع گاما مدل‌سازی کرد. با در نظر گرفتن خوشه فرضی $c \in \{W, L_1, \dots, L_n\}$ ، تابع چگالی احتمال (PDF^3) به شکل زیر تعریف می‌شود:

$$f(\sigma^0|c) = \frac{1}{b^a \Gamma(a)} (\sigma^0)^{a-1} e^{-\frac{\sigma^0}{b}} \quad (5)$$

که در آن Γ تابع گاما، a پارامتر شکل و b پارامتر مقیاس است که با استفاده از روش تخمین بیشینه‌ی احتمال^۴ تعیین می‌شود.

^۳ Probability Density Function (PDF)

^۴ maximum likelihood estimation

^۱ K-Nearest Neighbor (KNN)

^۲ Decision Tree (DT)

ضروری است برای هر خوشه یک احتمال اولیه در نظر گرفته شود در اینجا نسبت پیکسل‌های هر خوشه نسبت به کل تصویر به عنوان احتمال اولیه در نظر گرفته می‌شود. در ادامه، احتمال پسین به صورت حاصل ضرب احتمال پیشین در تابع چگالی احتمال به دست می‌آید. با در نظر گرفتن P_W به عنوان احتمال پیشین خوشه آب و P_{Li} به عنوان احتمال پیشین خوشه خشکی i -ام، روابط زیر برای محاسبه احتمالات بعدی قابل تعریف است:

$$P(W|\sigma^0) = f(\sigma^0|W) \cdot P_W \quad (6)$$

$$P(L_i|\sigma^0) = f(\sigma^0|L_i) \cdot P_{L_i} \quad (7)$$

شدت بازپراکنش خوشه‌های آب و خشکی ترکیبی از دو توزیع گاما را تشکیل می‌دهند که تلاقی آن‌ها متناظر با حدآستانه محلی بهینه است [۳۲]. بنابراین، حدآستانه جداکننده پیکسل‌های آب (W) از پیکسل‌های خشکی i -ام (L_i)، در محل تلاقی دو توزیع احتمال پسین $P(W|\sigma^0)$ و $P(L_i|\sigma^0)$ از طریق رابطه زیر قابل دستیابی است:

$$\sigma^0_{t_i} = \arg \min \left| \frac{P(W|\sigma^0)}{P(L_i|\sigma^0)} - 1 \right| \quad (8)$$

تابع $\arg \min$ برای یک تابع مشخص، آرگومانی را برمی‌گزیند که مقدار تابع را کمینه کند. مقدار کمینه در رابطه (۸) زمانی حاصل می‌شود که احتمال پسین آب برابر با احتمال پسین خوشه L_i باشد.

محاسبات فوق برای هر خوشه به طور مجزا انجام می‌شود و حدآستانه‌ی محلی مربوط به هر خوشه (σ^0_{ti}) برای تعیین محدوده آب در آن خوشه، به دست می‌آید. اگر مقادیر σ^0 کوچک‌تر از حدآستانه σ^0_{ti} باشد، پیکسل‌ها در آن خوشه به عنوان کلاس آب طبقه‌بندی می‌شوند، در غیر این صورت در طبقه خشکی قرار می‌گیرند.


پس از آستانه‌گذاری و تعیین محدوده آب در هر خوشه، یک عملیات اتحاد برای ترکیب پیکسل‌های آب در تمام خوشه‌ها انجام می‌شود. عملیات اتحاد، پیکسل‌ها را

در صورتی که در حداقل یکی از خوشه‌ها شده‌اند، به عنوان آب طبقه‌بندی شده باشند، در کلاس نهایی آب قرار می‌دهد. این فرایند در شکل ۴ در یک شمای کلی با فرض وجود پنج خوشه مختلف نشان داده شده است.

همان‌طور که در بخش داده‌ها بررسی شد، تصویر راداری اخذشده در این تحقیق، شامل دو پلاریزاسیون اصلی (VH و VV) و یک پلاریزاسیون میانگین است. ترکیب پلاریزاسیون‌های مختلف می‌تواند اطلاعات بیشتری از سطح زمین را ارائه کند و تعیین محدوده آب را بهبود بخشد. بنابراین، ابتدا فرایند حدآستانه‌گذاری محلی در پلاریزاسیون‌های اصلی به طور مجزا اجرا شد و محدوده کلی آب مربوط به هریک مشخص گردید. سپس یک عملیات تقاطع برای ترکیب نقشه‌های آب به دست آمده از هر پلاریزاسیون اعمال شد. عملیات تقاطع یک پیکسل را در صورتی به عنوان آب علامت‌گذاری می‌کند که در پلاریزاسیون‌های مختلف در کلاس آب طبقه‌بندی شده باشد.

یکی از پس‌پردازش‌های اصلی در این پژوهش اعمال محدودیت‌های هیدرولوژیک است که قادر به بهبود طبقه‌بندی بر اساس تجمع جریان آب می‌باشد [۳۳]. وجود نویز اسپیکل در تصاویر SAR باعث تغییرات ناگهانی در شدت بازپراکنش پیکسل‌های مجاور می‌شود که بدون شک منجر به طبقه‌بندی نادرست می‌شود. خطاها به شکل ظهور یک پیکسل آب محاط در محله‌های خشک یا به عکس، یک پیکسل خشک محاط در محدوده آب است. به منظور برطرف‌سازی این دسته از خطاها، می‌توان به کمک اطلاعات توپوگرافی منطقه (DEM) محدودیت‌های هیدرولوژیک را بر نقشه آب سطحی به دست آمده اعمال کرد. با در نظرگیری این خاصیت بدیهی آب که از ارتفاع بالاتر به سمت ارتفاع پایین جریان پیدا می‌کند، اعمال محدودیت‌های هیدرولوژیک طبق حالات زیر انجام می‌شود:

مادامی که پیکسل خشکی محاط میان پیکسل‌های آب در ارتفاع پایین‌تری قرار داشته باشد، این پیکسل، به کلاس آب تخصیص می‌یابد.



شکل ۴- طرح شماتیک استخراج نقشه آب سطحی (W) با اعمال حدآستانه‌های محلی برای خوشه‌های L_1 تا L_5 ؛ الف) خوشه آب اولیه، ب) خوشه‌های اصلاح‌شده، ج) خوشه آب نهایی.

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

معیار $F1_score$ ، معیاری متوازن بین دقت و بازخوانی شناخته می‌شود که در نظر گرفتن هر دو جنبه از عملکرد مدل را در نظر دارد:

$$F1_score = 2 \left(\frac{Precision \times Recall}{Precision + Recall} \right) \quad (11)$$

معیار IoU (Intersection of Union): یک معیار اندازه‌گیری انطباق بین دو مساحت یا دامنه مختلف است و نسبت میان مساحت تلاقی دو منطقه به مجموع مساحت‌های آن‌ها را نشان می‌دهد. این معیار نمایانگر میزان هم‌خوانی پیش‌بینی‌های یک مدل با واقعیت است. معیار AUC (Area Under the Curve) معادل مساحت زیر منحنی مشخصه عملکرد و بیانگر توانایی تفکیک مدل بین دو کلاس مختلف است. این معیار نسبت به سایر معیارها سخت‌گیرانه‌تر می‌باشد.

معیار نرخ هشدار کاذب (P_{FA}) حاصل نسبت تمامی پیکسل‌های هشدار کاذب^۲ (مثبت کاذب یا FP) به تعداد کل پیکسل‌های غیر هدف است و به صورت درصد بیان می‌شود. نرخ هشدار از دست‌رفته (P_{MA}) حاصل نسبت تمامی پیکسل‌های هشدار از دست‌رفته^۳ (منفی کاذب یا FN) به تعداد کل پیکسل‌های هدف که به صورت درصد بیان می‌شود.

در صورتی که پیکسل آب محاط میان پیکسل‌های غیرآب در ارتفاع بالاتری قرار داشته باشد، این پیکسل، به‌عنوان غیرآب برچسب‌گذاری می‌شود.

در این مطالعه، محدودیت‌های هیدرولوژیک بر روی نقشه محدوده آب دودویی تولیدشده، در یک همسایگی 3×3 برای هر پیکسل اعمال می‌شود. خروجی حاصل به‌عنوان نقشه نهایی آب سطحی منطقه معرفی می‌گردد.

۲-۳-۵- نحوه ارزیابی نتایج

به‌منظور ایجاد امکان ارزیابی و صحت‌سنجی دقیق نتایج، تصاویر حقیقت زمینی بر اساس تصاویر گوگل ارث منطقه در زمان اخذ تصویر، به‌صورت دستی ترسیم و برچسب‌گذاری شد تصاویر حقیقت زمینی در این پژوهش شامل: (۱) تصویر کلاس آب/ غیرآب، (۲) تصویر خوشه‌بندی منطقه دربرگیرنده پنج طبقه کلی شامل آب، زمین کشاورزی، تپه‌های تنک و ساختمان است. ارزیابی میزان دقت رویکرد پیشنهادی به کمک ماتریس ابهام یا سردرگمی^۱ امکان‌پذیر است.

معیار دقت (Precision) که دقت مدل را در پیش‌بینی نتایج مثبت اندازه‌گیری می‌کند و به‌صورت زیر محاسبه می‌شود:

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

معیار Recall یا بازخوانی نشان‌دهنده توانایی مدل را در شناسایی صحیح تمام نمونه‌های مثبت، ازجمله نمونه‌هایی که از دست رفته‌اند، و مطابق زیر اندازه‌گیری می‌شود:


^۲ False alarm

^۳ Missed alarm

^۱ confusion matrix

جدول ۲- نتایج ارزیابی مدل‌های طبقه‌بندی (بالاترین دقت حاصل در هر معیار برجسته شده‌است).

مدل	دقت (%)	بازیابی (%)	معیار F1 (%)	حساسیت (%)	خاصیت (%)	IoU (%)
RF	۹۹/۶۰	۹۹/۰۱	۹۹/۳۰	۹۹/۰۱	۹۸/۷۲	۹۸/۶۱
SVM	۹۸/۶۵	۹۷/۰۸	۹۷/۸۶	۹۷/۰۸	۸۷/۰۷	۹۵/۸۱
KNN	۹۸/۸۰	۹۷/۰۹	۹۷/۹۴	۹۷/۰۹	۹۱/۶۱	۹۵/۹۶
DT	۹۸/۹۵	۹۹/۰۴	۹۹/۰۰	۹۹/۰۴	۹۶/۸۴	۹۸/۰۱



شکل ۵- تصاویر خوشه‌بندی ایجادشده توسط مدل‌های الف (RF، ب) SVM، ج) KNN، د) DT.

۳- نتایج و بحث

هدف این بخش ارائه نتایج، یافته‌ها و ملزومات به‌دست‌آمده از مرحله پیاده‌سازی است، که عملکرد و کارایی رویکرد توسعه‌یافته را محک می‌زند.

مطابق اولین گام پیاده‌سازی، ۱۵۵ ورودی مشتق‌شده از تصویر در قالب باندهای اصلی به علاوه ۴ دسته‌ویژگیافت، هندسی، ریاضی و پلاریمتریک به‌طور مجزا از باند میانگین تصویر راداری محاسبه و استخراج شد. با توجه به اثر تنظیم پارامترهای مختلف، برخی ویژگی‌ها در نسخه‌های بیشتری بازتولید شده‌اند. تفاوت نسخه‌های مختلف در تعریف پارامترها و یا کرنل‌های به‌کاررفته به هنگام محاسبه این ویژگی‌هاست. درنهایت، مجموعه ویژگی‌ها در یک مکعب داده با ابعاد $۸۰۰ \times ۵۰۰ \times ۱۵۵$ جمع‌آوری می‌شود و پس از نرمال‌سازی وارد فرآیند آموزش طبقه‌بندی‌کننده‌ها در مرحله بعدی پردازش می‌شود.

در تمامی طبقه‌بندی‌کننده‌های RF، SVM، KNN و DT، نسبت داده‌های تست به داده‌های آموزشی ۰/۴ در نظر

گرفته شده‌است. داده‌های آموزشی به‌طور تصادفی از مجموعه داده نمونه‌برداری شده‌اند. در طبقه‌بندی‌کننده RF، تعداد تخمین‌گرها (درخت‌های تصمیم) برابر با ۱۰۰ تنظیم شده‌است. در الگوریتم SVM، تعداد ۱۰۰ تکرار به‌عنوان حداکثر تکرار مجاز جهت همگرایی الگوریتم تعیین شده‌است. برای KNN، تعداد همسایگان اثرگذار برابر ۵۰ تنظیم شده‌است. شکل ۵ خوشه‌بندی حاصل از مدل‌های آموزش‌دیده را نشان می‌دهد. همچنین با استفاده از معیارهای ارزیابی معرفی‌شده، دقت حاصل از نتایج هر مدل در پیش‌بینی داده‌های تست محاسبه شده و در جدول ۲ آورده شده‌است.

با مشاهده نتایج مدل‌های طبقه‌بندی می‌توان دریافت که مدل RF در حداقل ۴ معیار Precision، F1_score، IoU و Specificity به ترتیب با کسب دقت‌های ۹۹/۶۰، ۹۹/۳۰، ۹۸/۷۲، ۹۸/۶۱ بهتر از سایر مدل‌ها عمل کرده‌است. بعدازآن، مدل DT در دو معیار Recall و Sensitivity که معیارهای مشابهی هستند، دقت ۹۹/۰۴ را به‌عنوان بالاترین دقت در این معیارها ارائه داده‌است.

دقت سایر مدل‌ها با اختلاف کمی پایین‌تر از این دو مدل به دست آمده‌است. لازم به ذکر است حجم محاسبات و زمان صرف‌شده در آموزش مدل KNN حداقل سه برابر سایر مدل‌ها بوده‌است. با این وجود از لحاظ دقت‌های عددی به دست آمده در رتبه سوم ارزیابی مدل‌ها قرار می‌گیرد. بر اساس نتایج به دست آمده در این مرحله، تصویر طبقه‌بندی حاصل از مدل RF به عنوان تصویر خوشه‌بندی بهینه شناسایی می‌شود. این تصویر به عنوان داده ورودی در بخش حدآستانه‌گذاری محلی مورد استفاده قرار می‌گیرد. ویژگی‌های استخراج شده در درک بهتر جزئیات و توجه به ویژگی‌های خاص تصویر عملکرد به سزایی


داشته‌اند. برای بررسی اثربخشی این ویژگی‌ها و مقایسه آن‌ها با یکدیگر، از مدل RF، به عنوان بهترین طبقه‌بندی کننده، استفاده می‌شود. این مدل با محاسبه امتیاز هر ویژگی میزان تأثیر و اهمیت آن را تعیین می‌کند. این امتیازدهی با استفاده از معیار Gini انجام می‌شود که یک معیار اندازه‌گیری عدم تقارن یا عدم برابری توزیع یک متغیر است. کاهش انحراف Gini به میزان کاهش انسجام داده‌ها در یک درخت تصمیم است. کاهش انحراف Gini به منظور اندازه‌گیری خلوص یا انسجام داده‌های هر گره در یک درخت تصمیم استفاده می‌شود [۳۴].

جدول ۳- عملکرد دسته‌ویژگی‌ها بر اساس رتبه‌بندی Gini.

دسته	تعداد اعضا	درصد همکاری اعضا (%)	مجموع امتیاز دسته	درصد مجموع امتیاز دسته (%)	میانگین امتیاز دسته	درصد میانگین امتیاز دسته (%)
باند‌های طیفی	۳	۱/۹۴	۳/۵۰e-۰۲	۳/۵۳	۱/۱۷e-۰۲	۳۸/۷۴
بافت	۴۹	۳۱/۶۱	۱/۱۲e-۰۱	۱۱/۲۶	۲/۲۸e-۰۳	۷/۵۸
ریاضی	۷۵	۴۸/۳۹	۷/۲۶e-۰۱	۷۳/۱۴	۹/۶۹e-۰۳	۳۲/۱۵
هندسی	۶	۳/۸۷	۸/۵۵e-۰۳	۰/۸۶	۱/۴۲e-۰۳	۴/۷۳
پلاریمتریک	۲۲	۱۴/۱۹	۱/۱۱e-۰۱	۱۱/۲۲	۵/۰۶e-۰۳	۱۶/۸۱
مجموع	۱۵۵	۱۰۰	۹/۹۳e-۰۱	۱۰۰	۳/۰۱e-۰۲	۱۰۰

به طور خلاصه، امتیاز یک ویژگی گویای این است که آن ویژگی چقدر به کاهش انحراف Gini در گره‌های درختان در جنگل کمک می‌کند. امتیازهای تعیین شده در تمام درختان برای ویژگی مورد نظر میانگین‌گیری می‌شوند تا امتیاز نهایی آن ویژگی به دست آید. با استفاده از این روش، تمامی اعضا رتبه‌بندی و امتیازدهی شده‌اند. بر اساس رتبه‌بندی انجام شده، چهار مورد از بهترین ویژگی‌ها از ویژگی‌های مورفولوژی به دست آمدند و بالاترین امتیاز را کسب کردند. پس از آن، ویژگی‌های گوسین، و برخی از ویژگی‌های پایین‌گذر، بالاگذر و پلاریمتریک در رده‌های بعدی قرار گرفتند. در یک مقایسه کلی‌تر، عملکرد ویژگی‌ها در دسته‌ویژگی‌های مربوطه بررسی شده‌است. در جدول ۳ عملکرد تمامی ورودی‌ها آورده شده‌است. در این جدول تعداد اعضای هر دسته، درصد مشارکت اعضا، مجموع نمرات کسب شده در هر دسته و درصد آن‌ها، همچنین میانگین نمرات کسب شده به همراه درصد میانگین نمرات در هر دسته محاسبه شده‌است.

دسته‌ویژگی ریاضی با بیشترین تعداد ویژگی (۷۵ عدد ویژگی استخراج شده) بالاترین درصد مشارکت را داشته‌است. به عبارت دیگر، دسته‌ویژگی ریاضی ۴۸/۳۹ درصد ویژگی‌ها را به خود اختصاص داده‌است. همان‌طور که انتظار می‌رود جمع نمرات نیز در این دسته‌ویژگی بیشترین مقدار ممکن را داراست، اما از لحاظ میانگین نمرات اعضا در جایگاه دوم، پس از دسته‌ویژگی طیفی، قرار می‌گیرد. باند‌های اصلی تصویر علی‌رغم کمترین مشارکت و کسب کمترین مجموع امتیاز، بیشترین مقدار میانگین نمره را کسب کرده‌است. دسته‌ویژگی پلاریمتریک با مشارکت ۱۴/۱۹ درصدی، از نظر میانگین نمرات در جایگاه سوم قرار می‌گیرد. پس از آن ویژگی‌های بافت و هندسی به ترتیب در رتبه چهارم و پنجم را در ستون میانگین نمرات کسب کرده‌اند. در یک مقایسه جامع‌تر، در شکل ۶، نمودارهای درصد مشارکت، درصد مجموع نمرات و درصد میانگین نمرات برای هر دسته‌ویژگی به تفکیک ترسیم شده‌است. با استفاده از عملیات استخراج ویژگی و سپس طبقه‌بندی تصویر، خوشه‌بندی کلی منطقه مورد مطالعه تعیین شد.



شکل ۶- نمودار مقایسه عملکرد دسته‌ویژگی‌ها.

- حدآستانه‌های محلی باند VH: {۲۴/۱۳, ۲۴/۰۴, ۲۲/۸۶, ۲۱/۵۷, ۳/۶۸} -


با اعمال حدآستانه‌های محلی به‌دست‌آمده بر باند مربوط به خود، مرزهای جدید کلاس آب با هر یک از خوشه‌های خشکی تعیین می‌شود. سپس یک عملیات اتحاد بین خوشه آب اولیه و مناطق جدیداً تخصیص‌یافته به کلاس آب، برقرار می‌شود و کلاس آب در هر باند بهبود می‌یابد (شکل ۴). در نهایت، زیر نظر یک عملیات منطقی، پیکسل‌هایی که در هر دو باند VH و VV به‌عنوان پیکسل آب شناسایی شده باشند، در نقشه نهایی آب سطحی در کلاس آب قرار می‌گیرند. در نهایت، انجام اصلاحات هیدرولوژی، به‌عنوان یک پس‌پردازش مؤثر، نقشه نهایی آب سطحی مطابق شکل ۷ به دست می‌آید. در نقشه‌های آب سطحی شکل ۷ بدنه اصلی دریاچه زریبار به همراه چاله‌های آبی پیرامونی به رنگ سفید نمایش داده شده‌است. همان‌طور که مشخص است در آستانه‌گذاری محلی برخی نواحی حاشیه‌ای اصلاح شده‌اند و مقدار نویزهای پراکنده تصویر نسبت به خوشه آب اولیه کاهش یافته‌است. جهت ارزیابی و مقایسه دقیق‌تر، ارزیابی نتایج به‌صورت کمی بر اساس معیارهای ارزیابی دقت، در جدول ۴ آورده شده‌اند. مقایسه رویکردها نگرشی کلی نسبت به نحوه عملکرد دو رویکرد آستانه‌گذاری محلی و سراسری ارائه می‌دهند. اعداد برجسته‌شده نمایانگر بالاترین مقدار به‌دست‌آمده برای هر شاخص است.

مطابق گام بعدی پیاده‌سازی، خوشه آب اولیه به کمک حدآستانه‌گذاری سراسری آتسو، دست می‌آید. در گام نهایی پیاده‌سازی نیز به‌منظور بهبود و تدقیق خوشه آب موجود، فرآیند حدآستانه‌گذاری محلی بکار گرفته می‌شود. در منطقه مورد مطالعه، تعداد ۵ خوشه اصلی که نماینده کاربری‌های کلی منطقه هستند توسط فرآیند طبقه‌بندی تعیین شد. جهت تعیین مرز دقیق بین هریک از این خوشه‌ها با خوشه آب، نیاز به تعریف یک حدآستانه است. بنابراین، در مجموع ۵ حدآستانه در کل تصویر مورد نیاز است. از آنجایی که این حدآستانه‌ها به‌صورت غیرکلی و در مقیاس محلی تعیین می‌شوند، حدآستانه محلی نامیده می‌شوند.

مطابق آنچه شرح داده‌شد، حدآستانه‌های محلی با استفاده از تابع چگالی احتمال (PDF) و تخمین احتمالات بعدی به دست می‌آید. تخمین احتمالات بعدی تا رسیدن به حد بهینه و برابر شدن احتمال پسین آب با احتمال پسین خوشه خشکی ادامه می‌یابد. در نهایت حدآستانه محلی به کمک رابطه ۸ به دست می‌آید.

فرآیند فوق برای هریک از باندهای VH و VV به‌طور مجزا انجام شده و در مجموع ۱۰ حدآستانه محلی (۵ حدآستانه محلی برای باند VV و ۵ حدآستانه محلی برای باند VH) مطابق زیر تعیین شد.

- حدآستانه‌های محلی باند VV: {۱۹/۶۱, ۱۷/۶۰, ۱۶/۰۸, ۱۳/۹۸, ۵/۹۶}



شکل ۷- محدوده آب سطحی منطقه؛ الف) خوشه آب اولیه، ب) نقشه آب نهایی بدست آمده از حدآستانه‌گذاری محلی، ج) حقیقت زمینی منطقه.

رویکرد حدآستانه‌گذاری محلی در تمامی شاخص‌ها بالاترین مقادیر را به خود اختصاص داده‌است. اکثر پیکسل‌های آب سطح دریاچه بیشتر با یک نوع از کلاس‌های خشکی مجاورت دارند. این نکته باعث شده‌است که نتایج آستانه‌گذاری‌های سراسری و محلی به یکدیگر نزدیک باشد. میزان دقت رویکرد آستانه‌گذاری محلی بیش از ۹۹٪ و میزان F1_score بیش از ۹۸٪ است. همچنین میزان برآوردشده

معیار سخت‌گیرانه AUC، برای رویکرد حدآستانه‌گذاری محلی مقدار ۹۵/۴۴٪ برآورد شده‌است. بر اساس این معیار، رویکرد پیشنهادی نسبت به روش حدآستانه‌گذاری سراسری حدود ۱٪ بهبود داشته‌است. همچنین نتیجه حاصل از روش RF، به عنوان بهترین طبقه‌بندی‌کننده، به صورت دو کلاسه و با استفاده از نقشه حقیقت زمینی دقیق منطقه، ارزیابی شد و در جدول ۴ قرار گرفت.

جدول ۴- ارزیابی کمی نتایج به‌دست آمده از سه روش حدآستانه‌گذاری محلی، حدآستانه‌گذاری سراسری و روش جنگل تصادفی.

روش	هشدار کاذب		هشدار از دست رفته		دقت کلی (%)	دقت (%)	بازیابی (%)	معیار F1 (%)	AUC (%)
	پیکسل	P _{FA} (%)	پیکسل	P _{MA} (%)					
حدآستانه‌گذاری محلی	۶۹۲	۰/۲۳	۹۵۶۲	۸/۸۸	۹۷/۴۴	۹۹/۷۶	۹۶/۸۳	۹۸/۲۷	۹۵/۴۴
حدآستانه‌گذاری سراسری	۷۸۲	۰/۲۷	۱۱۱۴۶	۱۰/۳۵	۹۷/۰۱	۹۹/۷۳	۹۶/۳۲	۹۸/۰۰	۹۴/۶۹
جنگل تصادفی	۱۵۹	۰/۱۷	۱۵۳۴۶	۴/۹۹	۹۶/۱۲	۹۹/۷۴	۹۵/۰۱	۹۷/۴۱	۹۲/۸۴

علیرغم ارائه نرخ هشدار کاذب پایین‌تر در مقایسه با روش‌های آستانه‌گذاری، این روش در سایر معیارهای ارزیابی توانایی پایین‌تری از خود نشان داد. این روش در معیارهای F1_score و AUC به ترتیب دقت‌های ۹۷/۴۱٪ و ۹۲/۸۴٪ را ارائه کرد. در مجموع، رویکرد پیشنهادی ما نتایج قابل قبولی را ارائه کرده‌است و با بهبود یک روش

کلاسیک و رفع برخی محدودیت‌های آن موفق به ارتقاء این روش شده‌است.

آزمایش بیشتر: تشخیص تغییرات دریاچه چیتگر

به منظور بررسی چگونگی عملکرد مدل ارائه‌شده، آزمایشی دیگر که شامل پیاده‌سازی مدل در منطقه متفاوت

است، انجام می‌شود. برای این آزمایش نیز از تصویر راداری استفاده شده‌است اما نوع تصاویر و برخی مشخصات دیگر

متفاوت است. در ادامه، جزئیات داده‌ها و نتایج هر آزمایش بررسی می‌آید.




شکل ۸- تصاویر مربوط به دیتاست دریاچه چیتگر؛ (الف) تصویر اول مربوط به سال ۲۰۱۱؛ (ب) تصویر دوم مربوط به سال ۲۰۱۲ (ج) تصویر تغییر حقیقت زمینی (سفید: تغییر یافته، مشکی: بدون تغییر)

هدف از آزمایش بیشتر، به چالش کشیدن قدرت رویکرد پیشنهادی در یک مسئله پیچیده‌تر (مسئله تشخیص تغییرات) همچنین داده متفاوت (داده TerraSAR-X به جای Sentinel-1) می‌باشد. مجموعه داده در این آزمایش، از نوع تصاویر SAR دو زمانی مربوط به سنجنده TerraSAR-X محدود به منطقه جغرافیایی دریاچه مصنوعی چیتگر در تهران و تشخیص تغییرات آن طی بازسازی دریاچه می‌باشد. تصاویر شامل باند VV در ابعاد 550×450 با توان تفکیک ۳ متری در سال‌های ۲۰۱۱ (تصویر اول) و ۲۰۱۲ (تصویر دوم) می‌باشند که مربوط به سال‌های بازسازی دریاچه‌اند (شکل ۸).


مقیمی و همکاران [۳۵]، در سال ۲۰۱۷ با ارائه یک روش جدید که شامل ترکیب تکنیک نظارت‌نشده K-means و حدآستانه‌گذاری Otsu بود، تغییرات دریاچه چیتگر را با استفاده از این دیتاست بررسی کرده‌اند. در نتایج پژوهش آنها نرخ هشدار کاذب و نرخ هشدار از دست‌رفته به ترتیب ۱/۱۸٪ و ۹/۴۹٪ گزارش شده است.

در پژوهش حاضر، تمامی مراحل پیاده‌سازی برای دیتاست دریاچه چیتگر مطابق رویکرد ارائه‌شده می‌باشد، اما به دلیل لزوم ساخت تصویر تغییرات، در گام اولیه با استفاده از روش نسبت لگاریتم (log-ratio) تصویر اختلاف بین دو تصویر بدست می‌آید. روش log-ratio یک تکنیک ریاضی است که در محاسبه تفاوت تصاویر استفاده می‌شود. این روش شامل گرفتن لگاریتم نسبت بین مقادیر دو تصویر است و به جای تفاوت‌های مطلق، تغییرات نسبی در مقادیر پیکسل بین دو

تصویر را برجسته می‌کند. روش log-ratio به نرمال‌سازی داده‌ها و افزایش کنتراست در تصویر اختلافی کمک می‌کند. در گام بعدی با پیاده‌سازی مدل پیشنهادی بر روی این دیتاست که به ترتیب شامل محاسبه خوشه‌بندی منطقه (با استفاده از مدل RF)، ایجاد خوشه آب اولیه، اخذ تصویر DEM و نهایتاً تدقیق خوشه‌ها با استفاده از حدآستانه‌گذاری محلی است، نقشه تغییرات منطقه بدست می‌آید. شکل ۹ تصاویر اختلافی، طبقه‌بندی و DEM منطقه نمایش داده شده‌است. نتایج حاصل از اجرای مراحل در شکل ۱۰ آمده‌است. در این شکل تغییرات دریاچه در دو تاریخ متوالی قابل پیگیری است. همچنین نتایج کمی این پیاده‌سازی در جدول ۵ ارائه شده‌است. در جدول ۵ نیز مانند جدول ۴، روش‌های حدآستانه‌گذاری سراسری و طبقه‌بندی RF جهت مقایسه و بررسی بیشتر ارائه شده‌است. همانطور که مشاهده می‌شود نرخ هشدار کاذب در روش حدآستانه‌گذاری سراسری برابر با ۶/۰۳٪ می‌باشد که پایین‌ترین نرخ در میان مقایسات موجود بوده‌است. در معیار نرخ هشدار از دست‌رفته درصد‌های بدست‌آمده در روش آستانه‌گذاری محلی و روش طبقه‌بندی RF به یکدیگر نزدیک بوده و به ترتیب برابر ۴/۸۵ و ۴/۳۰ است. این نرخ در روش آستانه‌گذاری سراسری در پایین‌ترین مقدار و برابر با ۲/۵۶٪ بود. در سایر معیارهای ارزیابی، حدآستانه‌گذاری محلی دقت بهتری ارائه کرده‌است. بطور مثال در معیارهای F1-score و AUC مقادیر دقت بدست‌آمده به ترتیب برابر



شکل ۹- نتیجه آزمایش مدل پیشنهادی بر دیتاست دریاچه چیتگر؛ (الف) تصویر اختلافی؛ (ب) تصویر طبقه‌بندی؛ (ج) تصویر DEM منطقه.



شکل ۱۰- نتیجه آزمایش مدل پیشنهادی بر دیتاست دریاچه چیتگر؛ (الف) تصویر نقشه نهایی تغییرات، (ب) تصویر حقیقت زمینی تغییرات

جدول ۵- ارزیابی کمی نتایج به‌دست‌آمده از سه روش حدآستانه‌گذاری محلی، حدآستانه‌گذاری سراسری و روش جنگل تصادفی در دیتاست دریاچه چیتگر.

روش	هشدار کاذب		هشدار از دست‌رفته		دقت کلی (%)	دقت (%)	بازیابی (%)	معیار F1 (%)	AUC (%)
	پیکسل	P _{FA} (%)	پیکسل	P _{MA} (%)					
حدآستانه‌گذاری محلی	۱۳۶۴۰	۶/۰۳	۱۰۴۹	۴/۸۵	۹۴/۰۷	۹۳/۹۶	۹۹/۵۱	۹۶/۶۵	۹۴/۵۵
حدآستانه‌گذاری سراسری	۳۶۴۷۶	۱۶/۱۵	۵۵۴	۲/۵۶	۸۵/۰۴	۸۳/۸۵	۹۹/۷۰	۹۱/۰۹	۹۰/۶۴
جنگل تصادفی	۱۴۹۶۵	۶/۶۲	۹۳۱	۴/۳۰	۹۳/۵۷	۹۳/۳۷	۹۹/۵۶	۹۶/۳۶	۹۴/۵۳

مرتبط با دیتاست جدید از جمله تک‌باندی بودن مجموعه تصاویر، بر میزان مطلوبیت روش پیشنهادی اثرگذار بوده‌است. همانطور که پیش‌تر و در بخش روش بیان شد، روش این مطالعه از سه باند مختلف VV و VH و میانگین این دو باند در مراحل مختلف پیاده‌سازی استفاده می‌کند درحالی‌که در دیتاست چیتگر دسترسی به تنها یک باند (باند VV) امکان‌پذیر بود.

۹۶/۶۵٪ و ۹۴/۵۵٪ بوده‌است. در معیار recall، روش RF با اختلاف اندک پیشتر است. همچنین با مقایسه نتایج رویکرد فعلی با نتایج بدست آمده در تحقیق مقیمی و همکاران [۳۵] بر روی دیتاست مشابه، علیرغم مشاهده مقادیر نرخ هشدار کاذب بالاتر در رویکرد حدآستانه‌گذاری محلی، نرخ هشدار از دست‌رفته پایین‌تر با اختلاف حدود ۵ درصد بدست آمد. لازم به ذکر است برخی محدودیت‌های

بطور کلی با انجام آزمایشی پیچیده تر با نوع مسئله و جنس داده متفاوت، رویکرد پیشنهادی در چشم اندازی وسیع تر مورد ارزیابی قرار گرفت. در انتهای این آزمایش با توجه به اختلاف نمایان تر میان روش های آستانه گذاری سراسری و محلی میتوان نتیجه گرفت رویکرد آستانه گذاری محلی با تکیه بر ایده تفکیک نواحی قادر به بهبود این روش کلاسیک بوده است.

۴- نتیجه گیری و پیشنهادات

با تکیه بر سه رویکرد ویژگی مینا، یادگیری مینا و آستانه مینا، یک رویکرد کلی پیشنهادی جهت تشخیص بدنه آب سطحی معرفی شد. توجه به نوع منطقه و خصوصیات آن یکی از دلایل اصلی تمایز رویکرد پیشنهادی با سایر روش های به کار رفته است.

در بخش اصلی رویکرد پیشنهادی پژوهش، از یک رویکرد حد آستانه گذاری محلی استفاده شد. دلیل به کارگیری این رویکرد، بازگرداندن پیکسل های دست کم گرفته شده در روش آستانه گذاری سراسری به کلاس آب است. به منظور تعیین حد آستانه های محلی، علاوه بر تصویر رادار اصلی منطقه دو داده کمکی دیگر شامل خوشه آب اولیه و خوشه بندی کلی منطقه، مورد نیاز است. خوشه آب اولیه به وسیله روش آستانه گذاری سراسری تعیین شد. خوشه بندی کلی تصویر نیز توسط یک رویکرد ویژگی مینا-یادگیری مینا به دست آمد.

در این رویکرد، ابتدا طی یک فرآیند استخراج ویژگی ۱۵۲ ویژگی در قالب ۴ دسته ویژگی استخراج شدند. جامع بودن فرآیند استخراج ویژگی در این مطالعه، یکی دیگر از مشارکتهای بکار رفته در این تحقیق است.

در ادامه این رویکرد، خوشه بندی به وسیله ۴ مدل یادگیری ماشین انجام شد. نتایج حاصل از خوشه بندی نشان داد که مدل RF با اختلاف ناچیزی عملکرد بهتری نسبت به سایر مدل ها داشته است. بر این اساس، تصویر خروجی حاصل از آن به عنوان تصویر خوشه بندی بهینه انتخاب شد و مبنای تعیین حدود خوشه ها در روش حد آستانه گذاری محلی قرار گرفت.

در نتایج حاصل از آستانه گذاری، که بیانگر نتایج نهایی رویکرد پیشنهادی و تعیین کننده قدرت و دقت آن در برآورد نقشه آب سطحی منطقه هستند، مشاهده شد که

روش حد آستانه گذاری محلی قادر به بهبود حداقلی در تدقیق کردن مرزهای دریاچه بوده است.

برخی عوامل کلی در نتیجه آستانه گذاری محلی تأثیر مستقیم یا غیرمستقیم دارند. برای مثال نوع منطقه مطالعاتی، نوع و تعداد کاربری ها (خوشه ها)، نسبت مقدار مرز آب با انواع خشکی ها در میزان اثرگذاری و مقدار بهبود نتایج نقش اساسی دارند. نوع منطقه یا نوع خشکی در ارتباط با آب به طور قابل توجهی توانایی آستانه گذاری را برای تشخیص و تمایز آب از زمین تعیین می کند. همچنین، کیفیت داده های SAR می تواند توسط ویژگی های هندسی زمین تحت تأثیر قرار گیرد. بدین منظور در مناطق با تراکم های پیچیده، نیاز به اصلاح اضافی بازتاب یا در نظر گرفتن هندسه سطحی برای بهبود دقت نتایج می باشد.

وجود نویز اسپکل در تصاویر SAR که ممکن است منجر به تغییرات ناگهانی در شدت پیکسل در مناطق یکنواخت شود، منجر به بروز خطا در طبقه بندی پیکسل های آب می شود. این نویز اغلب با اعمال فیلترهای پایین گذر بر روی تصویر کاهش می یابد، اما فیلتر کردن اسپکل ممکن است وضوح تصویر را کاهش داده و مقدار پیکسل را نیز تغییر دهد. در عوض تأثیر نویز را با اعمال پردازش مورفولوژی، ترکیب دو پلاریزاسیون عمودی و افقی و اعمال محدودیت های هیدرولوژی می توان کاهش داد.

موارد پیشنهادی ما برای پژوهش های آتی حول موضوع مورد مطالعه این تحقیق، شامل بهره مندی از تصاویر تمام پلاریزه راداری با امکان تولید ویژگی های متنوع تر از طریق انجام روش های تجزیه مختلف، می تواند در بهبود نتایج مؤثر باشد. همچنین بهره گیری از تصاویر اپتیک جهت مقایسه و ارزیابی و یا تفسیر بصری نتایج می تواند کمک کننده باشد.

استفاده از روش های نیمه نظارت شده و یا نظارت نشده در خوشه بندی تصویر، به منظور کاهش نیاز به داده های برچسب گذاری شده می تواند قابلیت خودکار سازی رویکرد را افزایش دهد. به علاوه، مطالعه و بررسی پارامترهای اثرگذار طبیعی بر گسترش یا کاهش سطح دریاچه ها مانند جریان های آبی، بارش و تغییرات اقلیمی و در نظر گرفتن پارامترهای مربوط به آن در فرآیند پیاده سازی، در افزایش تفسیر پذیری نتایج مؤثر است. در نهایت، استفاده از داده های زمینی منطقه و همچنین داده های هواشناسی جهت ارتقاء رویکرد و یا ارزیابی دقیق تر آن مؤثر خواهد بود.

- [۱] C. Huang, Y. Chen, S. Zhang, and J. Wu, "Detecting, Extracting, and Monitoring Surface Water From Space Using Optical Sensors: A Review.," *Reviews of Geophysics*, vol. 56(2), pp. 333–360, 2018.
- [۲] S. C. Jinyue Chen, Rao Fu, Dan Li, Hao Jiang, Chongyang Wang, Yongshi Peng, Kai Jia, Brendan J. Hicks, "Remote Sensing Big Data for Water Environment Monitoring: Current Status, Challenges, and Future Prospects," *Earth's Future*, vol. 10, no. 2, p. 1029, 2022.
- [۳] J. Li, Y. Pei, S. Zhao, R. Xiao, X. Sang, and C. Zhang, "A Review of Remote Sensing for Environmental Monitoring in China," *Remote Sensing*, vol. 12, no. 7, p. 1130, 2020. [Online]. Available: <https://www.mdpi.com/2072-4292/12/7/1130>.
- [۴] S. Peña-Luque, S. Ferrant, M. C. R. Cordeiro, T. Ledauphin, J. Maxant, and J.-M. Martinez, "Sentinel-1&2 Multitemporal Water Surface Detection Accuracies, Evaluated at Regional and Reservoirs Level," *Remote Sensing*, vol. 13, no. 16, p. 3279, 2021. [Online]. Available: <https://www.mdpi.com/2072-4292/13/16/3279>.
- [۵] J. Liang and D. Liu, "A local thresholding approach to flood water delineation using Sentinel-1 SAR imagery," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 159, pp. 53-62, 2020.
- [۶] M. Zhang, F. Chen, B. Tian, and D. Liang, "Multi-temporal SAR image classification of coastal plain wetlands using a new feature selection method and random forests," *Remote Sensing Letters*, vol. 10, no. 3, pp. 312-321, 2019/03/04 2019, doi: 10.1080/2150704X.2018.1528397.
- [۷] M. A. Clement, C. G. Kilsby, and P. Moore, "Multi-temporal synthetic aperture radar flood mapping using change detection," *Journal of Flood Risk Management*, vol. 11, no. 2, pp. 152-168, 2018, doi: <https://doi.org/10.1111/jfr3.12303>.
- [۸] X. Shen, D. Wang, K. Mao, E. Anagnostou, and Y. Hong, "Inundation Extent Mapping by Synthetic Aperture Radar: A Review," *Remote Sensing*, vol. 11, no. 7, p. 879, 2019.
- [۹] C. Huang, Y. Chen, Wu, Li, and R. Liu, "An evaluation of Suomi NPP-VIIRS data for surface water detection," *Remote Sensing Letters*, vol. 6, 02/01 2015, doi: 10.1080/2150704X.2015.1017664.
- [۱۰] X. Luo, X. Tong, and Z. Hu, "An applicable and automatic method for earth surface water mapping based on multispectral images," *International Journal of Applied Earth Observation and Geoinformation*, vol. 103, p. 102472, 2021/12/01/ 2021, doi: <https://doi.org/10.1016/j.jag.2021.102472>.
- [۱۱] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, no. 1, pp. 62-66, 1979.
- [۱۲] T. Pun, "A new method for grey-level picture thresholding using the entropy of the histogram," *Signal Processing*, vol. 2, no. 3, pp. 223-237, 1980/07/01/ 1980, doi: [https://doi.org/10.1016/0165-1684\(80\)90020-1](https://doi.org/10.1016/0165-1684(80)90020-1).
- [۱۳] J. N. Kapur, P. K. Sahoo, and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," *Computer Vision, Graphics, and Image Processing*, vol. 29, no. 3, pp. 273-285, 1985/03/01/ 1985, doi: [https://doi.org/10.1016/0734-189X\(85\)90125-2](https://doi.org/10.1016/0734-189X(85)90125-2).
- [۱۴] P. K. Sahoo, S. Soltani, and A. K. C. Wong, "A survey of thresholding techniques," *Computer Vision, Graphics, and Image Processing*, vol. 41, no. 2, pp. 233-260, 1988/02/01/ 1988, doi: [https://doi.org/10.1016/0734-189X\(88\)90022-9](https://doi.org/10.1016/0734-189X(88)90022-9).
- [۱۵] V. Gstaiger, J. Huth, S. Gebhardt, T. Wehrmann, and C. Kuenzer, "Multi-sensoral and automated derivation of inundated areas using TerraSAR-X and ENVISAT ASAR data," *Remote Sensing*, vol. 33, pp. 7291-7304, 2012.
- [۱۶] M. Amrani, K. Yang, D. Zhao, X. Fan, and F. Jiang, "An Efficient Feature Selection for SAR Target Classification," in *Advances in Multimedia Information Processing – PCM 2017*, Cham, B. Zeng, Q. Huang, A. El Saddik, H. Li, S. Jiang, and X. Fan, Eds., 2018// 2018: Springer International Publishing, pp. 68-78.
- [۱۷] M. Ghanbari, D. A. Clausi, L. Xu, and M. Jiang, "Contextual Classification of Sea-Ice Types Using Compact Polarimetric SAR Data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 10, pp. 7476-7491, 2019, doi: 10.1109/TGRS.2019.2913796.
- [۱۸] V.-H. Nhu et al., "Daily Water Level Prediction of Zrebar Lake (Iran): A Comparison between M5P, Random Forest, Random Tree and Reduced Error Pruning Trees Algorithms," *ISPRS International Journal of Geo-Information*, vol. 9, no. 8, p. 479, 2020. [Online]. Available: <https://www.mdpi.com/2220-9964/9/8/479>.

- [۱۹] M. □, A. Bagheri, and M. Hashemi, "Analysis of the Issues of Lake Zrêbar in a Context of Integrated Water Iran-Water Resources Resources Management Using a Stakeholders' Participatory Approach in a Basin Scale .Research," *Iran-Water Resources Research*, vol. 12, pp. 1-12, 01/01 2016.
- [۲۰] I. Somaye, M. Delavar, and M. H. Niksokhan, "Identification of Nutrients Critical Source Areas with SWAT Model under Limited Data Condition," *Water Resources*, vol. 46, no. 1, pp. 128-137, 2019/01/01 2019, doi: 10.1134/S0097807819010147.
- [۲۱] M. e. a. Mohammadi, "Assessment of environmental factors affecting Zarivar Lake using multivariate statistical analysis," *Environmental Monitoring and Assessment*, vol. 190, no. 12, p. 736, 2018.
- [۲۲] B. Mohammadi, "Assessment of wind power in Kurdistan province," *Earth and space physics*, vol. 41, no. 2, pp. 323-335, 2015, doi: 10.22059/jesphys.2015.52817.
- [۲۳] L. Wentao, Y. Qiuze, and Y. Wenxian, "Water extraction in SAR images using GLCM and Support Vector Machine," in *IEEE 10th INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING PROCEEDINGS*, 24-28 Oct. 2010 2010, pp. 740-743, doi: 10.1109/ICOSP.2010.5655766.
- [۲۴] R. Mehrotra, K. R. Namuduri, and N. Ranganathan, "Gabor filter-based edge detection," *Pattern Recognition*, vol. 25, no. 12, pp. 1479-1494, 1992/12/01/ 1992, doi: [https://doi.org/10.1016/0031-3203\(92\)90121-X](https://doi.org/10.1016/0031-3203(92)90121-X).
- [۲۵] A. Akl and J. Iskandar, *Structure tensor regularization for texture analysis*. 2015, pp. 592-596.
- [۲۶] M. Ghanbari, D. A. Clausi, L. Xu, and M. Jiang, "Contextual Classification of Sea-Ice Types Using Compact Polarimetric SAR Data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, pp. 7476-7491, 2019.
- [۲۷] M. Belgiu and L. Drăguț, "Random forest in remote sensing: A review of applications and future directions," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 114, pp. 24-31, 2016/04/01/ 2016, doi: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- [۲۸] V. Vapnik, S. Golowich, and A. Smola, "Support vector method for function approximation, regression estimation and signal processing," *Advances in neural information processing systems*, vol. 9, 1996.
- [۲۹] S. Zhang, X. Li, M. Zong, X. Zhu, and R. Wang, "Efficient kNN Classification With Different Numbers of Nearest Neighbors," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 29, no. 5, pp. 1774-1785, 2018, doi: 10.1109/TNNLS.2017.2673241.
- [۳۰] B. Charbuty and A. Abdulazeez, "Classification Based on Decision Tree Algorithm for Machine Learning," *Journal of Applied Science and Technology Trends*, vol. 2, no. 01, pp. 20 - 28, 03/24 2021, doi: 10.38094/jastt20165.
- [۳۱] L. Giustarini et al., "Accounting for image uncertainty in SAR-based flood mapping," *International journal of applied earth observation and geoinformation*, vol. 34, pp. 70-77, 2015.
- [۳۲] H.-W. Chung, C.-C. Liu, I.-F. Cheng, Y.-R. Lee, and M.-C. Shieh, "Rapid Response to a Typhoon-Induced Flood with an SAR-Derived Map of Inundated Areas: Case Study and Validation," *Remote Sensing*, vol. 7, no. 9, pp. 11954-11973, 2015. [Online]. Available: <https://www.mdpi.com/2072-4292/7/9/11954>.
- [۳۳] S. Martinis, A. Tuele, and S. Voigt, "Towards operational near real-time flood detection using a split-based automatic thresholding procedure on high resolution TerraSAR-X data," *Natural Hazards and Earth System Sciences*, vol. 9, no. 2, pp. 303-314, 2009.
- [۳۴] R. A. Disha and S. Waheed, "Performance analysis of machine learning models for intrusion detection system using Gini Impurity-based Weighted Random Forest (GIWRF) feature selection technique," *Cybersecurity*, vol. 5, no. 1, p. 1, 2022/01/04 2022, doi: 10.1186/s42400-021-00103-8.
- [۳۵] A. Moghimi, S. Khazai, and A. Mohammadzadeh, "An improved fast level set method initialized with a combination of k-means clustering and Otsu thresholding for unsupervised change detection from SAR images," *Arabian Journal of Geosciences*, vol. 10, no. 13, p. 293, 2017/07/07 2017, doi: 10.1007/s12517-017-3072-3.