

ارزیابی تاثیر ادغام تصاویر ماهواره‌های لندست ۸ و سنتینل ۲ در برآورد پهنه‌های سیلابی

اشکان بنی‌خدمت^۱، بهناز بیگدلی^{۲*}، سید فضل‌الله ساغروانی^۳

۱. دانشجوی دکتری، گروه مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران Banikhedmat.ashkan@gmail.com

۲. نویسنده مسئول، دانشیار گروه مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران bigdelli@shahroodut.ac.ir

۳. دانشیار گروه مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران Saghravani@shahroodut.ac.ir

چکیده

پایش دقیق آب‌های سطحی یکی از کاربردهای مهم و ضروری در استفاده از سیستم‌های سنجش از راه دور است. برآوردن نیازهای مطرح‌شده در استفاده از داده‌های سنجش از دور برداشت‌شده از سطح زمین در بسیاری از کاربردها، تنها با استفاده از یک محصول و الگوریتم طبقه‌بندی کننده کافی و ممکن نیست و برای درک دقیقتر، ادغام داده‌ها می‌تواند گزینه بهتری باشد. لذا در این پژوهش از رویکردهای مختلفی همچون بکارگیری تصاویر دو سنجنده، شاخص‌های استخراج آب و الگوریتم‌های طبقه‌بندی جهت شناسایی پهنه‌های آبی استفاده گردید. در این راستا ابتدا تصاویر سنجنده‌های نوری لندست-۸ و سنتینل-۲ با یکدیگر ادغام شدند که در نتیجه آن وضوح مکانی این سنجنده‌ها با حفظ اطلاعات طیفی، از ۳۰ به ۱۰ متر ارتقا یافت. سپس شاخص‌های استخراج آب همچون (NDWI, MNDWI, AWEI_sh, AWEI_nsh, WI) بر تصاویر ادغام‌شده اعمال شد و پس از ترکیب آن با تصاویر اصلی ماهواره‌های منتخب، با استفاده از الگوریتم‌های طبقه‌بندی (SVM, Maximum Likelihood, Minimum Distance, Neural Network, Random Forest) محدوده مطالعاتی به دو دسته پهنه‌های آبی و غیرآبی طبقه‌بندی شد و در نهایت با استفاده از روش حداکثر رای‌گیری که از رویکردهای ادغام در سطح تصمیم‌گیری محسوب می‌شود نتایج حاصل از تمام الگوریتم‌های طبقه‌بندی برای تصاویر قبل و بعد از سیلاب استان مازندران در واقعه سیلاب سال ۱۳۹۸ شمسی با یکدیگر ادغام شدند. الگوریتم طبقه‌بندی جنگل تصادفی با دقت کلی ۹۷/۷۶ و ۹۴/۱۲ و ضریب کاپا ۹۴/۴۹ و ۹۱/۴۱ برای تصاویر قبل و پس از سیلاب بهترین عملکرد طبقه‌بندی در بین الگوریتم‌های مورد استفاده در این پژوهش را داشت. ادغام الگوریتم‌های طبقه‌بندی نشان از بهبود عملکرد تفکیک پهنه‌های آبی و غیرآبی با افزایش دقت کلی تفکیک به ۹۸/۴۱ و ۹۵/۲۴ و ضریب کاپا ۹۶/۱۲ و ۹۲/۸۱ برای تصاویر قبل و پس از سیلاب داشت.

کلمات کلیدی: ادغام تصاویر، الگوریتم طبقه‌بندی، روش حداکثر رای‌گیری، سنجنده نوری، شاخص‌های استخراج آب.

۱. مقدمه

سیل یکی از حوادث طبیعی و مخرب است که سالانه خسارت‌های جبران‌ناپذیری در سراسر جهان ایجاد می‌کند. سیل عمدتاً ناشی از تغییرات آب و هوایی (بارش‌های شدید، ذوب برف‌ها و ...)، تغییرات کاربری اراضی، مدیریت نادرست آبخیزداری، سرریز شدن دریاچه‌ها و یا شکست سدها می‌باشد که عواملی مانند توسعه نامناسب زیرساخت‌ها، توسعه شهرنشینی و عدم رعایت حریم رودخانه‌ها موجب مخرب‌تر شدن سیل می‌گردد (Tavus et al., 2020; Schumann and Moller., 2015; Al-juaidi et al., 2018; Khosravi et al., 2016). ایران کشوری خشک و نیمه‌خشک با استعداد بالایی در رخداد سیل بخصوص در استان‌های شمالی آن است. به عنوان مثال مابین ۵ فروردین ۱۳۹۸ و ۱۹ فروردین ۱۳۹۸ سیل‌های ویرانگری بیش از ۲۵ استان از ۳۱ استان کشور را تحت تاثیر قرار داد که در پی آن، خسارات وارد بر حوضه‌های تحت سیلاب به علت مدیریت ضعیف آبخیزداری، ساختارهای ناکافی کنترل سیل و عدم هشدارهای لازم تشدید یافت (Sahabi et al., 2020).

از آنجایی که پیامدهای سیل بستگی زیادی به محل، میزان و عمق جاری شدن سیل دارد، شناخت ویژگی‌های سطوح و ارزیابی توام این ویژگی‌ها در رویدادهای سیل بسیار مهم است (Tien., 2018; Yu., 2012). سیستم‌های متداول پایش و کنترل هیدرولوژیکی در پیش‌بینی و پایش سیل و واکنش‌های اضطراری با محدودیت‌هایی مواجه هستند. برای کشورهای با مساحت بالا مانند ایران هزینه نصب و نگهداری ایستگاه‌های بارانسنجی یکی از عوامل محدودکننده است. یکی دیگر از عوامل محدودکننده در این زمینه وجود ایستگاه‌های خارج از محدوده بخصوص در رودخانه‌های مرزی است که می‌تواند شکافی در سری زمانی داده‌ها ایجاد کند. علاوه بر آن، ایستگاه‌های اندازه‌گیری ارتفاع آب را اندازه می‌گیرند و اطلاعاتی از پهنه‌های سیلابی در اختیار قرار نمی‌دهند. طی چند دهه گذشته، سیستم‌های اطلاعات جغرافیایی (GIS) و سنسور از دور (RS) نشان داده‌اند در مدیریت حوضه‌های بزرگ هیدرولوژیکی برای ایجاد نقشه‌های خطر سیلاب بسیار دقیق‌تر از پایش زمینی هستند (Klemas., 2015; Tien., 2019; Jensen., 2014). تصاویر ماهواره‌ای به عنوان یکی از مهمترین منابع اطلاعاتی در زمینه مدیریت حوادث و بلایای طبیعی در نظر گرفته می‌شود (Klemas., 2015). در دسترس بودن آنها در هر نوع شرایط آب و هوایی و موقعیت مکانی و توانایی آنها برای پوشش مناطق وسیع جغرافیایی، آنها را به ابزاری ضروری برای پاسخگویی موثر در مقابل بلایای طبیعی تبدیل کرده است (Sghaier., 2018; Bhatt., 2017). ماهواره‌های مجهز به دوربین‌های دیجیتال با وضوح بالا برای نقشه‌برداری مناطق ساحلی یا رودخانه‌های سیلابی استفاده می‌شوند که امکان ضبط دائمی چنین رویدادهایی را فراهم می‌کنند. در این زمینه، سنسورهای نوری و راداری ارائه دهنده اطلاعات اولیه برای ارزیابی و نظارت بر سیل هستند (Guvel., 2022; Sanyal., 2004). سنسورهای نوری به دلیل سابقه طولانی، سهولت در پردازش و تفسیر اطلاعات در زمینه پایش و ردیابی سیلاب بیشتر مورد استفاده قرار گرفته‌اند. به علت پاسخ‌های رادیومتریک مختلف از سطح آب، تشخیص پهنه‌های آبی در صورت عدم وجود مشکلاتی همچون ابر و سایه توسط سنسورهای نوری ساده‌تر از سنسورهای راداری است (Nandi., 2017; Feyisa., 2014). داده‌های ماهواره لندست که دارای سنسورهای نوری هستند، بطور کلی به دلیل رایگان بودن، در دسترس بودن و قابلیت پیمایش و تصویربرداری منظم در جهان کاربردهای زیادی دارد (Terry., 2006). در همین راستا مطالعاتی با داده‌های ماهواره‌ای لندست جهت پایش پهنه‌های آبی و پهنه‌های سیلابی انجام شده است که می‌توان به مقاله (Ogadhawara et al., 2013) اشاره کرد. آنها در پژوهشی به آشکارسازی پهنه‌های سیلابی و غیرسیلابی با استفاده از سنسورهای نوری در ساحل شمالی ایالت تگزاس آمریکا که تحت تاثیر طوفان آیف بود، پرداختند. آنها در این پژوهش از تفاوت شاخص‌های نرمال اختلاف آب (DNDWI) حاصله از تصاویر ماهواره LANDSAT-5 که قبل و بعد از عبور طوفان آیف بدست آمده بود، برای تعیین پهنه سیلاب استفاده کردند. حد آستانه ۰/۰۵ برای مقادیر این شاخص (DNDWI) انتخاب گردید و مقادیر پایینتر از این حد آستانه به عنوان مناطق غیرسیلابی و بالاتر از آن به عنوان مناطق سیلابی انتخاب گردیدند. نتایج این پژوهش نشان داد که میزان تفاوت شاخص‌های نرمال اختلاف آب (NDWI) پس از سیلاب از ۰/۲۲۶ به ۰/۱۲۲ برای مناطق سیلابی کاهش یافت. همچنین اعتبارسنجی این پژوهش با استفاده از روش مونت کارلو نشان از دقت ۸۵/۶۸ درصدی برای مناطق سیلابی و ۹۲/۱۳ برای مناطق غیرسیلابی داشت. حد آستانه‌ها بطور کلی دارای ارزش ثابت ۰ یا ۱ هستند ولی در مورد سایه‌ها، تپه‌ها و مناطق شهری چالش برانگیز می‌باشند. در چنین حالتی به منظور گسترده‌تر کردن تفاوت بین آب و سایر مناطق و سهولت در تعیین حد آستانه می‌توان از ترکیبی از چند شاخص آب استفاده کرد که موجب افزایش شکاف بین کلاس‌ها و کاهش حساسیت آستانه شود (Acharya et al., 2018; Ning and Lee., 2021). با استفاده از این رویکرد (Acharya et al., 2018) شاخص‌های NDWI، MNDWI، WRI و NDVI با یکدیگر ترکیب کردند تا کارایی آستانه گذاری شاخص‌های ترکیبی را با شاخص‌های انفرادی در تصاویر ماهواره‌های لندست-۸ مقایسه کنند. نتایج این پژوهش نشان از عملکرد بسیار بهتر شاخص ترکیبی داشت. یکی دیگر از رویکردهای تعیین پهنه‌های آبی

استفاده از الگوریتم‌های طبقه‌بندی است که می‌تواند به صورت قابل ملاحظه‌ای خطاهای ناشی از آستانه‌گذاری را کاهش دهد. (Nandi et al., 2017) در پژوهشی به پیش و نقشه‌برداری سیلاب‌دشت‌های شهر وارانسی با استفاده ماشین بردار پشتیبان و سنجنده نوری لندست-۸ پرداختند. آنها مناطق سیلابی در طی سیل ۲۰۱۴ این شهر را با استفاده از شاخص‌های استخراج آب NDWI و MNDWI استخراج کردند و مناطق مستغرق را توسط الگوریتم ماشین بردار پشتیبان طبقه‌بندی نمودند. نتایج این پژوهش نشان از عملکرد بهتر شاخص MNDWI نسبت به شاخص NDWI داشت. اعتبارسنجی بین مقادیر اندازه‌گیری‌شده و نتایج حاصل از روش ماشین بردار پشتیبان (SVM) نشان از همبستگی خوب بین آنها و عملکرد مطلوب SVM برای نقشه‌برداری سیل با استفاده از تصاویر لندست-۸ داشت.

در ژوئن ۲۰۱۵، ماهواره سنتینل-۲ جهت تداوم داده‌ها و بهبود مأموریت ماهواره‌های پیش از خود پرتاب شد. این ماهواره به دلیل وضوح مکانی و زمانی بالا برای طیف گسترده‌ای از کاربردهای مبتنی بر سنجنش از دور مفید می‌باشد (Zhu., 2015). با استفاده از تصاویر این ماهواره (Jiang et al., 2020) در پژوهشی شاخص SWI را برای تشخیص مناطق آبی پیشنهاد دادند و از ۴ نوع منطقه آبی شامل دریاچه تایهو، مصب رودخانه یانگتسو، دریاچه نمک چاکا و دریاچه چین برای ارزیابی این شاخص استفاده نمودند. آنها از شاخص آبی سنتینل (SWI) و شاخص تفاوت نرمال‌شده آب (NDWI) با روش آتسو برای استخراج پهنه آبی استفاده کردند. نتایج این پژوهش نشان داد که دقت کلی و ضریب کاپا برای شاخص SWI بالاتر از NDWI است و SWI شاخص کارآمدی برای استخراج سریع و دقیق آب برای داده‌های سنتینل-۲ است.

انواع مختلفی از محصولات داده‌ای سنجنش از دور که توسط ماهواره‌های رصد کننده زمین در دسترس قرار می‌گیرند کاربردهای مختلفی همچون اکتشافات معدنی، پیش بینی آب و هوا، استخراج کاربری اراضی، پهنه‌بندی سیلاب و ... دارند. برآوردن نیازهای مطرح‌شده در استفاده از داده‌های سنجنش از دور برداشت‌شده از سطح زمین در بسیاری از کاربردها، تنها با استفاده از یک محصول کافی و ممکن نیست و برای درک دقیقتر، ادغام داده‌ها می‌تواند گزینه بهتری باشد (Pandit., 2015; Richards., 2006). ادغام و ترکیب داده‌های سنجنش از دور، به افزایش قابلیت اطمینان در تفسیر نتایج و کاهش ابهامات طبقه‌بندی عوارض منجر می‌شود. ادغام داده‌های سنجنش از دور اغلب به دلیل دستیابی به یک یا چند مورد از اهداف زیر صورت می‌پذیرد. (۱) افزایش وضوح تصاویر چند طیفی. (۲) بهبود نتایج طبقه‌بندی داده‌های سنجنش از دور. (۳) بهبود محتوای اطلاعاتی داده‌های سنجنش از دور (Samadzegan et al., 2015).

در همین راستا یکی از محدودیت‌های ماهواره لندست این است که فقط می‌تواند هر ۱۶ روز یکبار از یک منطقه برداشت تصویر انجام دهد که در شرایط آب و هوایی ابری این تصاویر دچار مشکل هستند و بدلیل پوشیده شدن از ابر قابلیت استفاده و تحلیل ندارند. در واقع می‌توان گفت برای پایش تغییرات سریع در سطح زمین همچون جنگل‌زدایی، سیلاب و شهرنشینی استفاده از داده‌های لندست به تنهایی کاربردی نمی‌باشد (Gao et al., 2015; Atkinson et al., 2012). ماهواره سنتینل-۲ سیستمی متشکل از دو ماهواره مدار قطبی است که به تداوم و بهبود مأموریت ماهواره‌های SPOT و Landsat کمک می‌کند و داده‌هایی با کیفیت بالا و مطمئن ارائه می‌دهد (Drusch et al., 2012).

باندهای ماهواره سنتینل ۲ طول موج‌های متناظر و همچنین سیستم مختصات جغرافیایی مشابهی با ماهواره لندست دارد. علاوه بر این، دسترسی رایگان به داده‌های این دو ماهواره فرصتی عالی برای ادغام این دو نوع داده فراهم می‌کند. (Wang et al., 2017) در پژوهشی با استفاده از رویکرد کریجینگ پیشرفته area to point به ادغام تصاویر ماهواره‌ای لندست و سنتینل-۲ و افزایش دقت مکانی تصاویر ماهواره‌ای لندست-۸ از به ۳۰ متر به ۱۰ متر پرداختند. آنها با استفاده از این روش تغییرات پوشش زمین را مورد ارزیابی قرار دادند.

نتایج این پژوهش نشان از بهبود کیفیت مکانی تصاویر ماهواره لندست و بهبود عملکرد آن و ارزش کاربردی بالقوه بالای ادغام تصاویر این ماهواره‌ها داشت. در پژوهشی دیگر (Liu et al., 2022) به منظور استخراج پهنه‌های رودخانه‌ای، یک روش ادغام تصویر را برای استفاده همزمان از اطلاعات تصاویر ماهواره‌های Sentinel-1, Landsat-8 به منظور ارتقا و وضوح طیفی و مکانی آنها توسعه دادند. نتایج آنها نشان از این داشت که نه تنها رویکرد ادغام موجب بهبود عملکرد طبقه‌بندی می‌گردد بلکه اثر تداخل ابر را نیز می‌تواند حذف کند. (Zhang et al., 2023) معتقد بودند که پایش دینامیکی محصولات کشاورزی به تصاویر با دوره زمانی فشرده نیاز دارد، اما هیچ محصول ترکیبی سنجش از راه دور پیشنهادی وجود نداشته است که وضوح مکانی-زمانی بالایی را به طور خاص برای نظارت بر زمین‌های کشاورزی ارائه دهد. در همین راستا آنها از رویکرد ادغام تصاویر حاصل از سنجنده‌های لندست-۸ و سنتینل-۲ به جهت بالا بردن توام وضوح مکانی و زمانی بهره بردند. نتایج این پژوهش نشان داد منحنی‌های سری زمانی شاخص‌های گیاهی که توسط مجموعه داده یکپارچه ترسیم شده است، می‌تواند به طور دقیق سیستم کشت را توصیف کند و تغییرات شدت رشد محصول را به تصویر بکشد. با توجه به مطالب ارائه شده این مطالعه سعی دارد تا با استفاده از تصاویر دریافتی از ماهواره‌های لندست-۸ و سنتینل-۲ و بهره‌گیری از رویکردی مبتنی بر شاخص‌های استخراج آب، طبقه‌بندی نظارت شده و ادغام داده‌ها در سطح تصمیم‌گیری پهنه‌های سیلابی را با دقت مطلوبی استخراج کند. در این پژوهش ترکیب شاخص‌های استخراج آب به منظور تمایز بهتر مناطق آبی و غیرآبی، روشهای طبقه‌بندی بیشترین شباهت، کمترین فاصله، ماشین بردار پشتیبان، شبکه عصبی و درخت تصادفی برای بهبود عملکرد طبقه‌بندی و در نهایت ادغام نتایج در سطح تصمیم‌گیری جهت افزایش دقت استخراج پهنه‌های آبی و مناطق تحت تاثیر سیلاب مورد استفاده قرار گرفت. بطور کلی نوآوری‌های این پژوهش را استفاده از دو سنجنده نوری با ترکیب جزئیات طیفی آنها، استفاده از ۵ شاخص استخراج آب، اعمال ۵ الگوریتم طبقه‌بندی و ادغام در سطح تصمیم‌گیری برشمرد.

۲. ترکیب داده‌های چند طیفی برای استخراج پهنه‌های سیلابی

این مطالعه یک رویکرد ادغام در سطح تصمیم‌گیری برای افزایش دقت تعیین پهنه‌های سیلابی ارائه می‌کند. شکل ۱ ساختار کلی رویکرد پیشنهادی را نمایش می‌دهد. در این مقاله از تصاویر دو ماهواره با سنسور نوری (Sentinel-2 و Landsat-8) جهت افزایش دقت مکانی و زمانی برداشت تصاویر استفاده شده است. در مرحله اول ادغام در سطح پیکسل با استفاده از روش گرم اشمیت بر روی تصاویر دریافتی از ماهواره‌ها انجام گرفت که تصویر حاصل از آن به عنوان ورودی نقشه استخراج آب و طبقه‌بندی کننده‌ها استفاده می‌شود. تصاویر حاصل از استخراج نقشه‌های پهنه‌های آبی در دو مرحله قبل و بعد از سیلاب با استفاده از شاخص‌های (MNDWI, NDWI, AWEI_sh, AWEI_nsh و WI)، با یکدیگر ترکیب شدند و با استفاده از نقاط نمونه برداری که به کمک گوگل ارث و بازدید میدانی بدست آمده بودند با استفاده از ۵ روش طبقه‌بندی (بیشترین شباهت، کمترین فاصله، ماشین بردار پشتیبان، شبکه عصبی و درخت تصادفی)، به دو دسته پهنه‌های آبی و غیرآبی تقسیم شدند. با توجه به اینکه الگوریتم‌های طبقه‌بندی کننده بر اساس ویژگی‌های خود نتایج متفاوتی ارائه می‌کنند جهت بهبود دقت طبقه‌بندی انجام شده و افزایش قطعیت در تشخیص پهنه‌های آبی، نقشه‌های حاصل از طبقه‌بندی کننده‌ها با استفاده از الگوریتم حداکثر تعداد رای‌گیری که ادغام‌کننده در سطح تصمیم‌گیری می‌باشد با یکدیگر ادغام شدند.

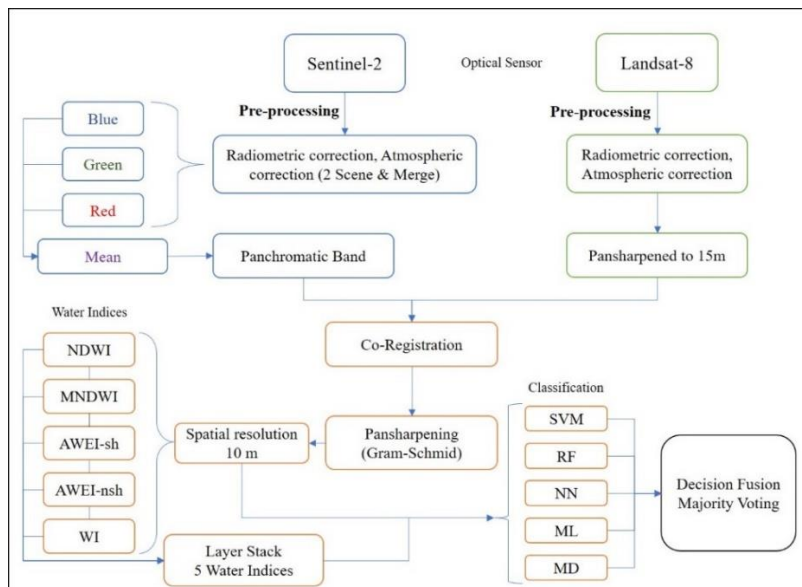


Figure 1. Workflow of flood mapping in this study.

۱.۲ منطقه مورد مطالعه و داده‌های مورد استفاده

در این پژوهش شهرستان‌های غربی استان گلستان (آق‌قلا، گمیشان و ضلع غربی شهرستان گنبد کاووس) به عنوان محدوده مطالعاتی انتخاب گردیدند (شکل ۲). این محدوده مطالعاتی از شمال به رودخانه اترک و از غرب به دریای کاسپین منتهی می‌شود. این منطقه در سه حوزه آبریز گرگان رود، قره‌سو و اترک قرار دارد. به دلیل عبور رودخانه‌های متعدد از این منطقه همواره مورد تهدید سیلاب‌های مخربی بوده است. لذا بررسی و پایش پهنه‌های تحت اثر سیلاب‌ها می‌تواند کمک ویژه‌ای در مدیریت و کنترل بحران‌های ناشی از سیلاب در این منطقه داشته باشد. در این پژوهش پهنه‌های تحت اثر سیلاب فروردین ۱۳۹۸ با استفاده از تصاویر اپتیکی ماهواره‌های Sentinel-2 و Landsat-8 مورد ارزیابی قرار گرفت. مشخصات تصاویر دریافتی در جدول ۱ و موقعیت حوزه مطالعاتی در شکل ۲ ارائه شده است.

Table ۱. Information of landsat-8 and sentinel-2 Image

Satellite	Sensor type	Spatial resolution (m)	Acquisition Date (Before the flood)	Acquisition Date (After the flood)
Landsat-8	Optical	30	2019/03/02	2019/04/03
Sentinel-2	Optical	20	2019/03/06	2019/04/05

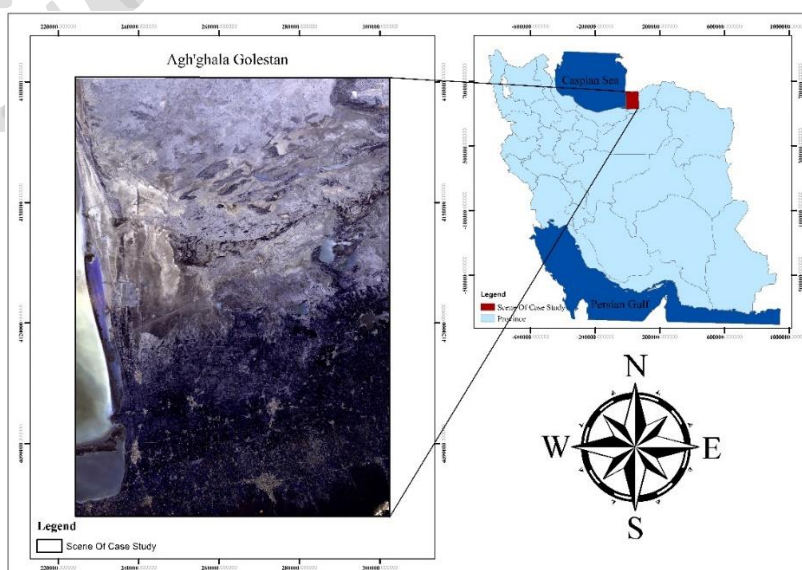


Figure 2. Geographical location of case study.

۲.۲ ادغام سنجنده‌ها

برای افزایش وضوح مکانی تصاویر لندست ۱۵ متری به تصاویر ۱۰ متری با بهره‌گیری از باند پانکروماتیک سنتینل-۲، پس از انجام تصحیحات رادیومتری و اتمسفری بر روی تصاویر دریافتی از این سنجنده‌ها و اعمال Co-Registration (یکسان‌سازی موقعیت مکانی عارضه‌ها بر روی تصاویر دو سنجنده)، از الگوریتم گرم اشمیت که یکی از رویکردهای پشارپنینگ است استفاده گردید. تصویر ۱۵ متری لندست از پشارپ باندهای طیف مرئی ۳۰ متری با باند پانکروماتیک ۱۵ متری و تصویر پانکروماتیک سنتینل ۲ از میانگین طول موج باندهای RGB به دست آمده است.

۳.۲ شاخص‌های استخراج آب

استفاده از روش شاخص‌های طیفی یکی از روش‌های پرکاربرد و مفید برای استخراج پهنه‌های آبی است که با استفاده از یک یا چند باند طیفی اختلاف بین مناطق آبی و غیرآبی از هم را نمایان می‌کند.

۱.۳.۲ شاخص NDWI

معروفترین و پرستفاده‌ترین شاخص پیشنهادی استخراج آب، شاخص NDWI می‌باشد که توسط مک فیتز در سال ۱۹۹۶ پیشنهاد شده است. ایشان از اختلاف انعکاس آب در باند سبز و مادون قرمز نزدیک استفاده کردند و رابطه آن را به صورت زیر ارائه نمودند (Mcfeeters., 1996).

$$NDWI = \frac{(Green - NIR)}{(Green + NIR)} \quad (۱)$$

۲.۳.۲ شاخص MNDWI

ژو با هدف کاهش و حذف نویزهای شاخص NDWI مانند گیاهان و خاک، با جایگذاری باند مادون قرمز میانی بجای باند مادون قرمز نزدیک، توانست به شاخص MNDWI برسد که رابطه آن به صورت زیر است (Xu., 2006).

$$MNDWI = \frac{(Green - MIR)}{(Green + MIR)} \quad (۲)$$

۳.۳.۲ شاخص AWEI

شاخص استخراج خودکار آب (AWEI) در سال ۲۰۱۴ به جهت بهبود طبقه‌بندی آب در مناطقی که دارای سایه هستند، توسط Feysia (et al., 2014) ارائه شد. آنها از ۵ باند لندست برای توسعه این شاخص استفاده کردند. معادلات ارائه شده توسط فیزیا و همکاران به صورت زیر می‌باشد:

$$AWEI_{no\ shadow} = 4(Green - SWIR1) - (0.25NIR + 2.75SWIR2) \quad (۳)$$

$$AWEI_{shadow} = Blue + 2.5Green - 1.5(NIR + SWIR1) - 0.25SWIR2 \quad (۴)$$

زمانی که سطوح دارای آلبیدوی زیاد و سایه هستند استفاده از هر دو باعث تفکیک و جداسازی آب می‌شود و زمانی که سطح، دارای آلبیدوی بالایی نباشد و سایه‌ای وجود نداشته باشد تفاوتی بین رابطه ۳ و ۴ نخواهد بود.

۴.۳.۲ شاخص WI₂₀₁₅

از شاخص‌هایی است که بر اساس روابط رگرسیونی بین باندهای مادون قرمز نزدیک، مادون قرمز طول موج کوتاه و بلند، سبز و قرمز بوجود آمده است. این شاخص در سال ۲۰۱۶ توسط فیشر بر اساس همان روش WI₂₀₀₆ و بر پایه بازتاب سطحی داده‌های نرمال شده ارائه شده است که با استفاده از رابطه زیر قابل استخراج می‌باشد (Fisher et al., 2016)

$$WI_{2015} = 1.7204 + 171\rho_{Green} + 3\rho_{Red} - 70\rho_{NIR} - 45\rho_{SWIR1} - 71\rho_{SWIR2} \quad (5)$$

۴.۲ روشهای طبقه‌بندی

۱.۴.۲ طبقه‌بندی بیشترین شباهت (Maximum Likelihood (ML))

ML از متداول‌ترین روش‌های طبقه‌بندی نظارت‌شده است که اصل تصمیم در این روش بر اساس احتمال تعلق یک پیکسل به یک کلاس خاص است. معادله پایه این روش فرض می‌کند که احتمالات برای تمامی کلاس‌ها یکسان است و باندهای ورودی دارای توزیع نرمال هستند. در این روش احتمال تعلق یک پیکسل به تمامی کلاس‌ها محاسبه شده و پیکسل به کلاس با بیشترین احتمال تعلق می‌گیرد (Outkei and Blaschke., 2010; Erdas., 1999). طبق (Erdas., 1999) الگوریتم شباهت D در طبقه‌بندی بیشترین شباهت برای یک پیکسل X در تصویر با n باند متعلق به یک کلاس مشخص Mc بر پایه معادلات Bayesian به صورت زیر بیان می‌شود.

$$D = \ln(a_c) - [0.5 \ln(|cov_c|)] - [0.5(X - M_c)T(cov_c - 1)(X - M_c)] \quad (6)$$

ماتریس واریانس کواریانس داده‌ها که علاوه بر بردار میانگین در این روش مورد استفاده قرار می‌گیرد باعث می‌شود تا خصوصیات بیشتری از داده‌ها مورد بهره‌برداری قرار گیرد که همین موضوع باعث افزایش دقت طبقه‌بندی می‌گردد.

۲.۴.۲ طبقه‌بندی کمترین فاصله (Minimum Distance (MD))

در این روش ابتدا میانگین همه طبقه‌ها با استفاده از نواحی تعلیمی محاسبه شده و هر پیکسل مجهول به طبقه‌ای واگذار می‌شود که نزدیکترین فاصله اقلیدسی را با میانگین آن طبقه داشته باشد (Mather and Tso., 2009).

۳.۴.۲ طبقه‌بندی ماشین بردار پشتیبان (Support Vector Machine (SVM))

این روش طبقه‌بندی بر اساس نظریه یادگیری آماری واقع شده است. ماشین بردار پشتیبان یک طبقه‌کننده دودویی است که اولین بار توسط وپینگ معرفی شد. این روش طبقه‌بندی یک روش آماری غیرپارامتریک نظارت‌شده است که امروزه جز الگوریتم‌های پرکاربرد برای طبقه‌بندی داده‌های سنجش از دور محسوب می‌شود. این روش طبقه‌بندی کلاس‌ها را به وسیله یک مرز خطی از هم جدا می‌کند. به صورتی که دو کلاس بیشترین حاشیه جداسازی را در طبقه‌بندی داشته باشند (Vapnik., 1979; Vapnik., 1995). در حالت خطی معادله به صورت زیر نوشته می‌شود:

$$y = f(x) = \text{Sign} \left[\sum_{i=1}^n y_i a_i (x_i \cdot x_j) + b \right] \quad (7)$$

در صورتی که نمونه‌ها به صورت خطی جداپذیر نباشند، پس از انتقال با یک کرنل (جمله‌ای، پایه شعاعی، حلقوی) به ابعاد بالاتر، صفحه جداکننده تعریف می‌شود. در این حالت رابطه ۷ به رابطه ۸ تغییر می‌یابد (Mather and Tso., 2009).

$$y = f(x) = \text{Sign} \left[\sum_{i=1}^n y_i a_i K(x_i \cdot x_j) + b \right] \quad (8)$$

تابع $K(x_i, x_j)$ که جهت ایجاد ماشین‌هایی با سطوح مختلف تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب داخلی تولید می‌کند.

۴.۴.۲ طبقه‌بندی جنگل تصادفی (Random Forest (RF))

این روش ترکیبی از درخت‌های تصمیم است که توسط (Breiman., 2001) در سال ۲۰۰۱ توسعه داده شد. این الگوریتم یکی از الگوریتم‌های پرکاربرد و ابزاری کارآمد در مسائل مربوط به تخمین متغیر هدف به کمک درخت تصمیم است. در ساخت هر درخت تصمیم یک استراتژی تقسیم‌بندی برگشتی بالا به پایین استفاده می‌شود و درخت تصمیم، با استفاده از قوانین تصمیم‌گیری، نمونه‌های آموزشی را در هر گره به زیرمجموعه‌های کوچکتر تقسیم می‌کند. در واقع مجموعه‌ای از درخت‌های تصمیم با هم یک جنگل را تولید

می‌کنند و این جنگل می‌تواند تصمیمات بهتری را نسبت به یک درخت اتخاذ کند. در این روش هر طبقه‌بندی کننده با استفاده از یک نمونه‌ی برداری تصادفی که مستقل از بردارهای ورودی آموزشی است تولید می‌شود و هر درخت یک رای واحد برای هر بردار جهت قرار دادن در محبوبترین کلاس می‌دهد. تکنیک تولید یک جنگل تصادفی عموماً ترکیبی از روش‌های Bagging و Random Subspace است (Breiman., 2001; Breiman., 1996).

۵.۴.۲ شبکه‌بندی شبکه عصبی مصنوعی (Neural Network (NN))

مفهوم شبکه عصبی مصنوعی از سیستم عصبی انسان گرفته شده است. این شبکه اولین بار توسط رزنبالات در سال ۱۹۸۵ ارائه شده است. در این روش، برای آموزش مجموعه، نمونه‌های آموزشی از طریق لایه‌ی ورودی وارد شبکه شده و بعد از ضرب شدن در وزن‌های ارتباط‌دهنده نرون‌ها، وارد لایه میانی می‌شوند. در هر نرون از لایه‌های میانی، یک تابع فعالیت، بر روی ورودی‌ها اعمال شده و مقادیر محاسبه شده به لایه خروجی فرستاده می‌شود. در این حالت خروجی شبکه با داده‌های مطلوب مشاهداتی مقایسه می‌شوند و میزان خطا محاسبه می‌گردد. این شبکه‌ها با دو روش بدون نظارت و با نظارت به طبقه‌بندی الگوهای ورودی می‌پردازند. یک از روش‌های مفید در حل مشکلات بهینه‌سازی استفاده از روش شبکه عصبی مصنوعی پس انتشار است.

$$a_c = \sum_p w_{pc} \times b_{pc} \quad (9)$$

ac مجموع ضرب ورودیها در وزن آنهاست، w_{pc} وزن این ورودیها است و b_{pc} شامل مقدار نرون‌های C برای هر مقدار ورون p است. اگر داده‌ها را با $(x_1, y_1), \dots, (x_n, y_n)$ و تابع cost را با I نمایش دهیم در نهایت تابع زیر حاصل خواهد شد.

$$a_c = \sum_{i=1}^n l(h_w(x_i), y_i) \quad (10)$$

در این رابطه x_i ورودی، y_i خروجی و $h_w(x)$ خروجی NN می‌باشد (Nielsen., 2015).

۵.۲ ادغام در سطح تصمیم‌گیری

ادغام در سطح تصمیم‌گیری سطحی است که پس از پردازش هر داده ورودی بطور جداگانه و استخراج اطلاعات از آن، و استفاده از برخی قوانین در سطح تصمیمات اتخاذشده، ادغام اطلاعات صورت می‌پذیرد. ادغام در سطح تصمیم‌گیری بالاترین سطح ادغام اطلاعات است که تفسیر مشترک را تقویت کرده و اختلافات را حل می‌کند و درک بهتری از اشیای مشاهده شده ارائه می‌دهد. در این سطح از ادغام، نیازی به هم‌مرجع کردن سنجنده‌ها نیست، زیرا حوزه زمانی و مکانی اطلاعات سنجنده‌ای که تصمیم براساس آن اتخاذشده، بطور واضح هنگام تصمیم‌گیری در نظر گرفته شده است. رویکرد ادغام در سطح تصمیم‌گیری شامل روشهای استنتاج بی‌زی، نظریه‌ی دمستفر-شفر، شبکه عصبی مصنوعی (ANN)، روش‌های وزن‌دهی، استدلال قیاسی و روش‌های معنایی است (Samadzegan et al., 2015; (Ghassemian., 2016).

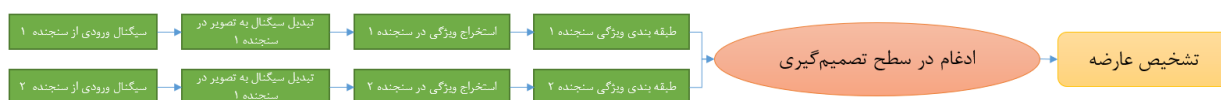


Figure 3. Step of decision level fusion

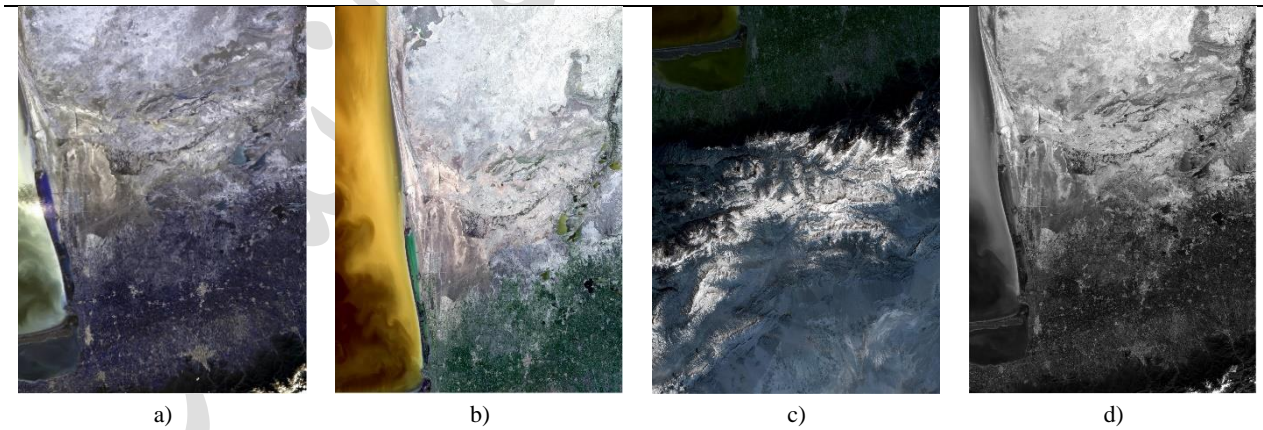
۱.۵.۲ روش حداکثر رای گیری

روش حداکثر رای گیری یک از پرکاربردترین روشهای مطرح در ادغام طبقه‌بندی کننده‌های با خروجی مطلق است. در این روش با تصمیم هر طبقه‌بندی کننده به صورت یک رای برخورد می‌شود. در این روش اگر همه طبقه‌بندی کننده‌ها وزن و دقت یکسانی داشته باشند تصمیم تمام طبقه‌بندی کننده‌ها برای یک نمونه ورودی با وزن یکسان در نظر گرفته شده و تصمیم با بیشترین رای به عنوان کلاس برنده برای نمونه ورودی معرفی می‌شود. با این فرض که $D_{i,i} = 1, \dots, M$ مجموعه طبقه‌بندی کننده‌ها به تعداد M و $w_{j,j} = 1, \dots, c$ تعداد کلاس‌های موجود باشد، برای هر طبقه‌بندی کننده بردار c بعدی $[d_{i1}, d_{i2}, \dots, d_{ic}]$ در نظر گرفته می‌شود. d_{ij} می‌تواند مقادیر یک یا صفر را بگیرد، به این ترتیب که اگر ورودی متعلق به آن طبقه بود عدد یک و در غیر اینصورت عدد صفر در نظر گرفت. در حالت رای گیری ساده که طبقات وزن برابری دارند کلاسی که بیشترین رای را داشته باشد رای برنده خواهد بود. (Kuncheva., 2004; Kuncheva. and Whitaker., 2003)

$$\sum_{i=1}^L d_{i,k} = \max_{j=1}^L d_{i,j} \quad (11)$$

۳. نتایج و بحث

جهت انجام این پژوهش تصاویر قبل و بعد از سیلاب حوزه مطالعاتی از سنجنده های نوری ماهواره‌های لندست-۸ و سنتینل-۲ دریافت شدند. پس از اعمال تصحیحات رادیومتریک و اتمسفری در تصاویر ماهواره لندست، با ادغام تصاویر اصلاح شده و باند پانکروماتیک این سنجنده، دقت مکانی تصاویر حاصل از آنها از ۳۰ متره به ۱۵ متر ارتقا یافت. سپس با اصلاح و موزاییک کردن دو تصویر از ماهواره سنتینل ۲ و میانگین گیری از سه باند آبی، سبز و قرمز این ماهواره و انجام همسان سازی موقعیت عارضه ها (Co-Registered) در نهایت با استفاده از روش گرم اشمیت ادغام آن با تصویر لندست ۱۵ متری دقت این تصاویر جهت پایش سیلاب به ۱۰ متر ارتقا یافت. که تصاویر حاصل از این مراحل در شکل ۴ ارائه شده است.







Figure 4. a) pansharpening landsat-8 with panchromatic band (Before the flood). b) first scene of sentinel-2 (Before the flood). c) second scene of sentinel-2 (Before the flood). d) mosaic of two scene of sentinel-2 (Before the flood). e) pansharpening landsat-8 with panchromatic band (After the flood). f) first scene of sentinel-2 (After the flood). g) second scene of sentinel-2 (After the flood). h) mosaic of two scene of sentinel-2 (After the flood). i) coregistered image of landsat-8 and sentinel-2 (Before the flood). j) pansharpening coregistered image of sentinel-2 and landsat-8 with gram schmidt algorithm (Before the flood). k) coregistered image of landsat-8 and sentinel-2 (After the flood). l) pansharpening coregistered image of sentinel-2 and landsat-8 with gram schmidt algorithm (After the flood).

بر اساس استراتژی این تحقیق شاخص‌های استخراج پهنه‌های آبی (NDWI, MNDWI, AWEI_nsh, AWEI_sh, WI₂₀₁₅) بر روی تصاویر ادغام‌شده قبل و بعد از سیلاب پیش از پیاده سازی الگوریتم‌های طبقه بندی اعمال شد که در شکل ۵ نمایش داده شده است. بازتابندگی کم آب‌ها در محدوده مادون قرمز نزدیک باعث افزایش قابلیت تفکیک این پدیده در این طول موج از دیگر پدیده‌ها می‌شود. هدف اصلی از اعمال ۵ شاخص استخراج آب، افزایش دقت طبقه‌بندی در تشخیص پهنه آبی و مناطق گل و لای دار و بطور کلی تفکیک طیفی بهتر مناطق آبی و غیرآبی بود که این امر در صحت نمونه‌های انتخاب‌شده جهت طبقه‌بندی تصاویر بسیار مفید بود و منجر به افزایش دقت نمونه‌های انتخابی شد.






Figure 5. a) NDWI (Before the flood). b) MNDWI (Before the flood). c) AWEI_nsh (Before the flood). d) AWEI_sh (Before the flood). e) WI2015 (Before the flood). f) NDWI (After the Flood). g) MNDWI (After the Flood). h) AWEI_nsh (After the Flood). i) AWEI_sh (After the Flood). j) WI2015 (After the Flood)




Figure 6. a) Sample of each class (Before the flood). b) Sample of each class (After the Flood)

به لحاظ تفسیر بصری در تمامی شاخص‌ها مسیر رودخانه و مناطق آبی به خوبی استخراج شده است و عملکرد این شاخص‌ها مطلوب ارزیابی می‌شود، اما برای اختصاص بهتر عارضه‌ها به طبقه مربوطه، نتایج حاصل از تمامی شاخص‌ها و تصویر ۱۰ متری (تصویر ادغام شده لندست-۸ و سنتینل-۲) برای تصاویر قبل و بعد از سیلاب با همدیگر ترکیب شدند و سپس با بهره‌گیری از نقاط نمونه برداری میدانی و گوگل ارث (شکل ۶) از الگوریتم‌های طبقه‌بندی کننده (SVM, ML, MD, RF, NN) استفاده شد. روش‌های یادگیری و آموزش بطور قابل توجهی استخراج آب‌های سطحی را بهبود بخشید. با توجه به نتایج ضریب کاپا و دقت کلی الگوریتم‌های طبقه‌بندی (جدول ۲) عملکرد تمامی ۵ روش طبقه‌بندی برای تصویر ترکیب شده خوب بوده و همگی با دقتی بالا مناطق آبی را تشخیص دادند. در بین این روشها الگوریتم‌های RF و ML برای تصاویر قبل از سیلاب با دقت کلی ۹۷.۷۶ و ۹۲.۲۲ و ضریب کاپا ۹۵/۴۹ و ۸۴/۲۱ بالاترین و کمترین دقت را داشتند. در تصاویر بعد از سیلاب نیز روشهای طبقه‌بندی RF و ML با دقت کلی ۹۴/۱۲ و ۸۱/۵۵ و ضریب کاپا ۹۱/۴۱ و ۷۰/۲۸ بالاترین و پایینترین دقت را دارا بودند. علت اصلی پایین‌تر بودن دقت روش‌های طبقه‌بندی حداکثر احتمال و کمترین فاصله تا میانگین را نسبت به سایر روشهای طبقه‌بندی می‌توان ماهیت پارامتریکی آنها عنوان نمود، زیرا به نوع توزیع آماری داده‌های مورد استفاده و تعداد نمونه‌های آموزشی وابسته می‌باشند اما روشهای ناپارامتریک همچون SVM, NN, RF بدلیل عدم وابستگی به توزیع آماری خاصی دقت بالاتری نسبت به روش‌های پارامتریک ارائه دادند.

در تصاویر قبل از سیلاب (شکل ۷) که تفکیک خوبی بین پهنه‌های آبی و غیرآبی وجود دارد هم از لحاظ بصری و هم به لحاظ آماری عملکرد تمامی روشها مطلوب ارزیابی شده است اما با بررسی مناطق حریم رودخانه پس از سیلاب و زیر آب رفتن بخش وسیعی از

این منطقه الگوریتم جنگل تصادفی عملکرد بسیار مطلوبی در تفکیک مناطق آبی گل آلود و زمین های اطراف آن نسبت به سایر الگوریتم ها داشته است.

عمده خطای مشاهده شده در الگوریتم های MD و ML عدم تفکیک مناسب بین زمین های مرطوب و پهنه های آبی است که همانطور که در شکل ۷ دیده می شود بخش جنوبی حوضه مطالعاتی خطای بالایی در تفکیک این مناطق داشته است. خطای دیگری که در تصاویر ارایه شده به آن اشاره شده است خطای موجود در ایجاد پیوستگی مسیر رودخانه های عبوری است که در تمامی الگوریتم ها نیز با خطاهای متفاوت مشاهده گردید.

با بررسی نقشه های حاصل از هر روش طبقه بندی کننده مساحت پهنه های آبی برای روشهای SVM, RF, ML, MD, NN به ترتیب برابر با ۱۰/۱، ۱۰/۳، ۱۱/۵، ۱۰ و ۱۰ محاسبه گردید که این مقادیر برای بعد از سیلاب به ۲۳/۲، ۲۳/۹، ۲۴/۸، ۲۱/۹ و ۲۰/۶ افزایش داشتند که نشان از افزایش ۱۳/۱، ۱۳/۶، ۱۳/۳، ۱۱/۹ و ۱۰/۶ درصدی مساحت پهنه های آبی در استفاده از هر روش داشت.




Figure 7. a) Maximum likelihood classification (Before the flood). b) Maximum likelihood classification (After the flood). c) Minimum distance classification (Before the flood). d) Minimum distance classification (After the flood). e) Support vector machine classification (Before the flood). f) Support vector machine classification (After the flood). g) Random forest classification (Before the flood). h) Random forest classification (After the flood). i) Neural network classification (Before the flood). j) Neural network classification (After the flood).

Table 2. Result of overall accuracy and kappa coefficient for each classification algorithm.

OA & KC	ML		MD		SVM		NN		RF	
	Before	After	Before	After	Before	After	Before	After	Before	After
Overall Accuracy	92.22	81.55	94.13	89.94	96.81	91.73	95.33	90.74	97.76	94.12
Kappa Coefficient	84.21	70.28	91.18	82.89	93.16	87.79	91.65	86.16	94.49	91.41

در نهایت نتایج طبقه بندی کننده ها با استفاده از روش حداکثر رای گیری با یکدیگر ادغام شده (شکل ۱۰) و ضرایب کاپا و دقت کلی برای آن محاسبه گردید (شکل های ۸ و ۹). نتایج حاصل از آن (دقت کلی ۹۸/۴۱ و ۹۵/۲۴ و ضریب کاپا ۹۶/۱۲ و ۹۲/۸۱ برای قبل و بعد از سیلاب) نشان از بهبود دقت کلی و ضریب کاپا در طبقه بندی پهنه های آبی نسبت به تمامی الگوریتم های طبقه بندی داشت. در این مرحله با توجه به استفاده از آرای ۵ الگوریتم طبقه بندی در هر پیکسل با انجام رای گیری از طبقه بندی کننده در صورتی که پیکسلی بیشترین رای (۳ رای از ۵) را به خود اختصاص دهد به آن طبقه تعلق می گیرد. به همین جهت تصمیم اتخاذ شده میتواند دقت بالاتری

نسبت به استفاده از یک روش طبقه‌بندی کننده داشته باشد که در نتایج حاصل شده در این پژوهش نیز مشهود است. از جمله بخش های که میتوان به نتایج بهبود یافته آن اشاره نمود تفکیک بهتر زمین های مرطوب و کشاورزی با زمین های تحت سیلاب و ایجاد پیوستگی بهتر در خطوط مسیل رودخانه می باشد.

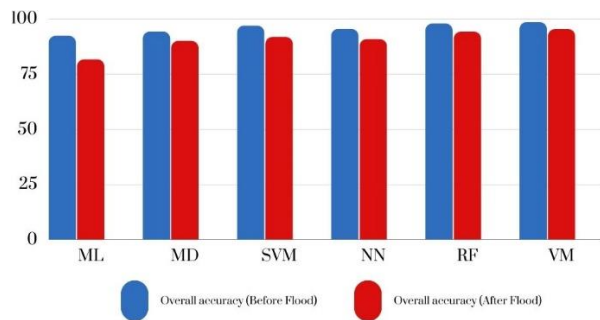


Figure 9. Graph of overall accuracy for each classification algorithms

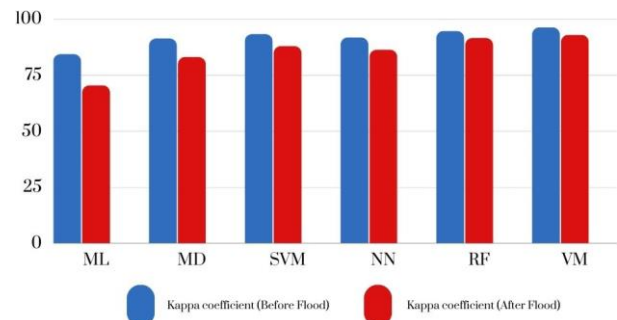


Figure 8. Graph of kappa coefficient for each classification algorithms




Figure 10. Decision level fusion (Before the flood). b) Decision level fusion (After the flood).

به منظور تعیین مساحت زمین های تحت سیلاب، اختلاف تصویر ادغام شده قبل و بعد از سیلاب محاسبه گردید (شکل ۱۱). نتایج حاصل از تحلیل تصاویر ادغام شده قبل از سیلاب نشان داد که ۱۰/۱۳ درصد از مساحت محدوده مطالعاتی به کاربری مناطق آبی و ۸۹/۸۷ درصد به کاربری مناطق غیرآبی اختصاص دارد، که این ارقام در تصویر حاصل از ادغام نقشه های طبقه بندی شده بعد از وقوع سیلاب به ۲۲/۹۴٪ برای مناطق آبی و ۷۷/۰۶٪ برای مناطق غیرآبی تغییر کرد. با محاسبه اختلاف نقشه های قبل و بعد از سیلاب مشاهده گردید که ۱۲/۸۱ درصد از زمین های محدوده مطالعاتی که قبل از سیلاب جز مناطق غیرآبی محسوب می شدند پس از سیلاب زیر آب رفته اند.




Figure 11. Flooded area

همانطور که در اختلاف تصاویر قبل و بعد از سیلاب مشاهده می‌گردد حاشیه خطوط ساحلی (بخش ۱) پیشرفت داشته و بخشی از ساحل را در بر گرفته‌اند. در بخش جنوبی محدوده مطالعاتی (بخش ۲) گرچه تصاویر نشان از وجود آب باریکه ای در این بخش دارد که یکی از رودهای های فرعی آن نیز بسیار کم آب است اما پس از سیلاب مسیل اصلی و حریم آن بطور قابل توجهی تحت تاثیر سیلاب قرار گرفته است. که دلیلی اصلی آن را میتوان زمین های دشتی با شیب کم این منطقه عنوان نمود که قابلیت گسترش سیلاب بالایی دارند. بخش ۳ پایین دست شهرستان آق قلا می باشد که پس از شکست ریل راه آهن آب در دشت های پایین دست آن پخش شده است. بخش چهار که در شکل ۱۱ به آن اشاره شده است از زیر شاخه های رودخانه مرزی اترک می باشد و جز رودخانه های پر آب می باشد که تحت اثر سیلاب رواناب قابل توجهی در مسیل آن مشاهده گردید.

۴. نتیجه گیری:

آبهای سطحی نقش بسیار مهمی در زندگی انسانها دارند. به همین علت شناسایی و پایش آبهای سطحی می‌تواند مخاطرات ناشی از سیل و خشکسالی را کاهش دهد. در این مطالعه از دو استراتژی استفاده شد که استراتژی اول ادغام تصاویر لندست-۸ و سنتینل-۲ و استراتژی دوم استراتژی ادغام تصاویر طبقه‌بندی شده بر اساس لایه‌های ترکیب شده بر اساس ۵ شاخص استخراج آب و تصاویر ترکیبی لندست-۸ و سنتینل-۲ برای تصاویر قبل و بعد از سیلاب استان گلستان در رویداد سیل سال ۱۳۹۸ استفاده بود. نتیجه این پژوهش نشان داد که ادغام تصاویر ماهواره‌های لندست ۸ و سنتینل ۲ موجب بهبود دقت مکانی و زمانی تصاویر خواهد شد و همچنین بکارگیری شاخص های استخراج آب در انتخاب نمونه های انتخابی هر طبقه در افزایش دقت تصاویر طبقه‌بندی شده بسیار مفید خواهد بود.

استفاده از روش های طبقه‌بندی کننده با تعداد بیشتر منجر به کاهش عدم قطعیت و در نهایت افزایش دقت کلی و ضریب کاپا برای تصاویر ادغام شده خواهد شد که در نتایج کلی این پژوهش هم برای تصاویر قبل و هم برای تصاویر بعد از سیلاب مشهود است.

- Acharya, T. D., Subedi, A., Yang, I. T., & Lee, D. H. (2018). Combining Water Indices for Water and Background Threshold in Landsat Image. *Proceedings*, 2, 143-149.
- Al-Juaidi, A. E. M., Nassar, A.M. & Al-Juaidi, O.E.M. (2018). Evaluation of flood susceptibility mapping using logistic regression and GIS conditioning factors. *Arab J Geosci* 11, 765, 1-10.
- Atkinson, P. M., Jeganathan, C., Dash, J., & Atzberger, C. (2012). "Inter-comparison of four models for smoothing satellite sensor time-series data to estimate vegetation phenology," *Remote Sensing of Environment*, 123, 400–417.
- Bhatt, C.M., Rao, G.S., Farooq, M., Manjusree, P., Shukla, A. & Sharma, S.V.S.P. (2017) Satellite-Based Assessment of the Catastrophic Jhelum Floods of September 2014, Jammu & Kashmir, India. *Journal of Geomatics, Natural Hazards and Risk*, 8, 309-327.
- Breiman, L. 1996. Bagging predictors. *Machine Learning* 26:123-140
- Nielsen, M. A. (2015). *Neural Networks and Deep Learning*, Vol. 2018, Determination Press, San Francisco, California.
- Breiman, L. 2001. Random forests. *Machine Learning* 45:5-32.
- Drusch, M & et al. (2012). "Sentinel-2: ESA's optical high-resolution mission for GMES operational services," *Remote Sensing of Environment*, 120, 25–36.
- ERDAS, "Field Guide," 5th Edition, ERDAS, Inc., Atlanta, 1999.
- Feyisa, G. L., Meilby, H., Fensholt, R., & Proud, S. R. (2014). Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment*. 140, 23- 35.
- Fisher, A., Flood, N., & Danaher, T. (2016). Comparing Landsat water index methods for automated water classification in eastern Australia. *Remote Sensing of Environment*. 175, 167- 182.
- Gao, F., Hilker, T., Zhu, X., Anderson, M., Masek, J., Wang, P., & Yang, Y. (2015). Fusing Landsat and MODIS Data for Vegetation Monitoring. *IEEE Geoscience and Remote Sensing Magazine*. 3, 47- 60.
- Ghassemian, H. (2016). A Review of Remote Sensing Image Fusion Methods. *Information Fusion*, 32, 75-89.
- Guvel, S. P., Akgul, M. A., Aksu, H. (2022). Flood inundation maps using Sentinel-2: a case study in Berdan Plain. *Water Supply*, 22 (4), 4098–4108.
- Jiang, W., Ni, Y., Pang, Z., He, G., Fu, J., Lu, J., Yang, K., Long, T., & Lei, T. (2020). A new index for identifying water body from sentinel-2 satellite remote sensing imagery, *ISPRS Annals. Photogramm. Remote Sensing*. 3, 33–38.
- Jensen, V. (2014). Remote sensing of the environment: An earth resource perspective. *Prentice-Hall, Inc.* 2, 1-10.
- Khosravi, K., Nohani, E., Maroufinia, E., & Pourghasemi, H. R. (2016). A GIS-based flood susceptibility assessment and its mapping in Iran: a comparison between frequency ratio and weights-of-evidence bivariate statistical models with multi-criteria decision-making technique. *Natural Hazards* 83, 947–987.
- Klemas, V. (2015). Remote Sensing of Floods and Flood-Prone Areas: An Overview. *Journal of Coastal Research*, 31, 1005-1013.
- Kuncheva, L. (2004). *Combining Pattern Classifiers: Methods and Algorithms*. John Wiley & Sons. Inc. publication, Hoboken, New jersey. canada.
- Kuncheva, L., & Whitaker, C. J. (2003). Measures of diversity in classifier ensemble and their relationship with the ensemble accuracy, *Machine Learning*, 51, 181- 207.
- Mather, P., & Tso, B. (2009). *Classification Methods for Remotely Sensed Data*. CRC Press, Boca Raton.
- Mcfeters, S. K. (1996). The use of the normalized difference water index (NDWI) in the delineation of open water features, *international journal of remote sensing*. 17, 1425- 1432.
- Nandi, I., Srivastava, P. K., & Shah, K. (2017). Floodplain Mapping through Support Vector Machine and Optical/Infrared Images from Landsat 8 OLI/TIRS Sensors: Case Study from Varanasi. *Water Resource Manage.* 1568, 1-15.
- Ning, F. S., & Lee, Y. C. (2021). Combining Spectral Water Indices and Mathematical Morphology to Evaluate Surface Water Extraction in Taiwan. *Water*, 13, 2774-2791.
- Ogadhawara, I., Curtarelli, M. P., & Ferreira, C. M. (2013). The use of optical remote sensing for mapping flooded areas. *Journals of engineering research and application*. 3, 1956-1960.
- Otukey, J. R., & Blaschke, T. (2010). Land Cover Change Assessment Using Decision Trees, Support Vector Machines and Maximum Likelihood Classification Algorithms. *International Journal of Applied Earth Observation and Geoinformation*. 12, 27-S31.
- Pandit, V., & Bhiwani, R. J. (2015). Image Fusion in Remote Sensing Applications: A Review. *International Journal of Computer Applications* 120, 22-32.
- Richards, J. A. (2006). "Remote Sensing Digital Image Analysis", *Springer*.

- Samadzadegan, F., Tabibmahmoudi, F., & Bigdeli., B. (2015). Data fusion in remote sensing: theory and methods: In Persian.
- Sanyal, J., & Lu, X.X. (2004). Application of Remote Sensing in Flood Management with Special Reference to Monsoon Asia: A Review. *Natural Hazards*, 33, 283-301.
- Schumann, G. J. P., & Moller, D. K. (2015). Microwave remote sensing of flood inundation. *Physics and Chemistry of the Earth*. V83–84, 84-95.
- Sghaier, M. O., Hammami, I., Foucher, S., & Lepage, R. (2018). Flood Extent Mapping from Time-Series SAR Images Based on Texture Analysis and Data Fusion. *Remote Sens.* 10, 237, 1-30.
- Shahabi, H., Shirzadi, A., Ghaderi, K., Omidvar, E., Al-Ansari, N., Clague, J.J., Geertsema, M., Khosravi, K., Amini, A., Bahrami, S., & et al. (2020). Flood Detection and Susceptibility Mapping Using Sentinel-1 Remote Sensing Data and a Machine Learning Approach: Hybrid Intelligence of Bagging Ensemble Based on K-Nearest Neighbor Classifier. *Remote Sensing*. 12, 266, 1- 30.
- Sigurdsson, J., Armannsson, S.E., Ulfarsson, S.E., & Sveinsson, J.R. (2022). Fusing Sentinel-2 and Landsat 8 Satellite Images Using a Model-Based Method. *Remote sensing*. 14(13). 3224.
- Tavus, B., Kocaman, S., Nefeslioghlu, H. A., & Gokceoglu, C. (2020). A Fusion approach for flood mapping using sentinel-1 and sentinel-2 datasets. *Int. Arch. Photogramm. Remote Sensing. Spatial Inf. Sci.*, XLIII-B3, 641–648.
- Terry, A., Samuel, G., John, G., & Darrel, W. (2006). Landsat-7 Long-Term Acquisition Plan. *Photogrammetric Engineering & Remote Sensing*. 10, 1137- 1146.
- Tien Bui, D., Khosravi, K., Li, S., Shahabi, H., Panahi, M., Singh, V.P., Chapi, K., Shirzadi, A., Panahi, S., Chen, W., & et al. (2018). New Hybrids of ANFIS with Several Optimization Algorithms for Flood Susceptibility Modeling. *Water*, 10, 1210, 1-28.
- Tien Bui, D., Khosravi, K., Shahabi, H., Daggupati, P., Adamowski, J.F., Melesse, A.M., Thai Pham, B., Pourghasemi, H.R., Mahmoudi, M., Bahrami, S., & et al. (2019). Flood Spatial Modeling in Northern Iran Using Remote Sensing and GIS: A Comparison between Evidential Belief Functions and Its Ensemble with a Multivariate Logistic Regression Model. *Remote Sensing*, 11, 1589, 1-27.
- Vapnik, V. 1979. Estimation of dependences based on empirical data [in Russian]. Nauka, Moscow. (English translation: *Springer-Verlag, New York*).
- Vapnik, V. 1995. The nature of statistical learning theory. New York: *Springer-Verlag*.
- Wang, Q., Blackburn, G. A., Onojeghuo, A. O., Dash, J., Zhou, L., Zhang, Y., & Atkinson, P.M. (2017). Fusion of Landsat 8 OLI and Sentinel-2 MSI Data. *IEEE Trans. Geosci. Remote Sens.* 55, 3885–3899.
- Xu. H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International journal of remote sensing*. 27, 3025- 3033.
- Yu, J. J., Qin, X. S., Larsen, O., (2012). Joint Monte Carlo and possibilistic simulation for flooddamage assessment. *Stoch Environ Res Risk Assess.* 27(3), 1-12.
- Zhang, H., Zhang, Y., Gao, T., Lan, Sh., Tong, F., & Li, M. (2023). Landsat-8 and Sentinel-2 Fused Dataset for High Spatial-Temporal Resolution Monitoring of Farmland in China’s Diverse Latitudes. *Remote sensing*. 15(11), 2951.
- Zhu, Z., Wang, S., Woodcock, C. E. (2015). Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. *Remote Sensing of Environment*. 159, 269- 277.

Evaluation of the Impact of Image Fusion of Landsat 8 and Sentinel 2 Satellites on Flood Zone Estimation

Ashkan Banikhedmat¹, Behnaz Bigdeli^{2,*}, Seyed Fazlolah Saghraani³

- 1. PhD Candidate, Water Resources Engineering and Management, Faculty of Civil Engineering, Shahrood university of technology, Shahrood, Iran**
- 2. Associate Professor, Faculty of Civil Engineering, Shahrood university of technology, Shahrood, Iran**
- 3. Associate Professor, Faculty of Civil Engineering, Shahrood university of technology, Shahrood, Iran**

Abstract

Accurate monitoring of surface water is one of the important and necessary applications in the use of remote sensing systems. Meeting the needs raised in the use of remote sensing data collected from the earth's surface in many applications, using only one product and classification algorithm is not sufficient and possible, and for a more accurate understanding, data fusion can be a better option. In this system, various approaches such as water extraction indices or classification algorithms are used to identify water areas. In this research, an fusion approach of Landsat-8 and Sentinel-2 optical sensor images was used. Firstly, the spatial resolution of these sensors was enhanced from 30 to 10 meters by Pansharpening them and preserving spectral information. Then, water extraction indices such as NDWI, MNDWI, AWEI_sh, AWEI_nsh, and WI were applied to the integrated images. Subsequently, using classification algorithms such as SVM, Maximum Likelihood, Minimum Distance, Neural Network, and Random Forest, the study area was classified into two categories of water and non-water areas. Finally, the results obtained from all classification algorithms for pre and post-flood images of Mazandaran province in the 2019 flood event were merged using the majority voting method, which is considered an integration approach at the decision-making level. Random forest classification algorithm with overall accuracy of 97.76 and 94.12 and Kappa coefficient 94.49 and 91.41 for images before and after flood had the best classification performance among the algorithms used in this research. The fusion of classification algorithms showed an improvement in the separation performance of water and non-water areas with an increase in the overall accuracy of separation to 98.41 and 95.24 and Kappa coefficient 96.12 and 92.81 for the images before and after the flood.

Keywords: Classification algorithms, Image fusion, Majority voting method, Optical sensor, Water extraction indices.