



سنجش از دور

و

GIS ایران



سنجش از دور و GIS ایران سال پانزدهم، شماره چهارم، زمستان ۱۴۰۲
Vol.15, No. 4, Winter 2023 Iranian Remote Sensing & GIS

۸۳-۱۰۰

مقاله پژوهشی

ارزیابی الگوریتم‌های ریزمقیاس‌نمایی مکانی-زمانی داده‌های مادیس به داده‌های

سنیتیل-۲ در کلاس‌های متفاوت پوشش زمین

ناهید حق‌شناس^۱ و علی شمس‌الدینی^{۲*}

۱. دانشجوی دکتری گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تربیت مدرس، تهران

۲. دانشیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تربیت مدرس، تهران

تاریخ پذیرش مقاله: ۱۴۰۱/۱۰/۱۷

تاریخ دریافت مقاله: ۱۴۰۱/۰۴/۱۷

چکیده


داده‌های سنجش از دوری، با قدرت تفکیک مکانی بالا، اغلب دارای قدرت تفکیک زمانی و طیفی پایین و داده‌های با قدرت تفکیک مکانی پایین دارای قدرت تفکیک طیفی و زمانی بالا هستند. با وجود این، در حال حاضر، سنجنده‌های ماهواره‌ای به‌تنهایی نمی‌توانند داده‌هایی با قدرت تفکیک زمانی و قدرت تفکیک مکانی بالا را هم‌زمان ارائه کنند. این در حالی است که در برخی کاربردها دسترسی هم‌زمان به داده‌هایی با قدرت تفکیک مکانی و زمانی بالا ضروری است؛ از این رو در این مطالعه، با هدف دستیابی به داده‌های دارای قدرت تفکیک مکانی و زمانی بالا، تصاویر مادیس در کلاس‌های کاربری شهری، باغ، مرتع، کشاورزی و آب از طریق الگوریتم‌های STARFM، ESTARFM و FSDAF به قدرت تفکیک مکانی سنیتیل-۲، ریزمقیاس‌شد. منطقه مطالعاتی با تنوع پوشش‌های زمین‌گونه‌گون در اطراف شهر مهاباد انتخاب شد. در این مطالعه، باندهای مرئی و مادون‌قرمز نزدیک در سنیتیل-۲ و مادیس انتخاب و پیش‌پردازش‌های لازم، از جمله تصحیح هندسی، روی آنها انجام شد. سپس با استفاده از الگوریتم‌های ریزمقیاس‌نمایی، تصاویر مادیس به تصاویر سنیتیل-۲ ریزمقیاس‌شد. نتایج نشان‌دهنده صحت بالای کلاس‌های شهری، باغ و مرتع در قیاس با کلاس‌های کشاورزی و آب است؛ به‌گونه‌ای که الگوریتم‌های ESTARFM، FSDAF و STARFM به‌صورت میانگین در همه باندها، به‌ترتیب برای کلاس شهری، ضریب تعیین ۰/۸۸/۲۵، ۰/۸۶/۵ و ۰/۸۷/۲۵، درمورد کلاس باغ ضریب تعیین ۰/۸۳/۷۵، ۰/۸۳/۲۵ و ۰/۸۰/۵ و درمورد کلاس مرتع، ضریب تعیین ۰/۹۰/۷۵، ۰/۷۰/۵ و ۰/۸۷/۵ را نشان دادند. در مجموع، الگوریتم ESTARFM در مقایسه با دیگر الگوریتم‌ها در این تحقیق، نتیجه‌ای بهتر دربرداشت. **کلیدواژه‌ها:** ریزمقیاس‌نمایی مکانی-زمانی، کلاس‌های پوشش زمین، مادیس، سنیتیل-۲.

* نویسنده مکاتبه‌کننده: گروه سنجش از دور و GIS دانشکده علوم انسانی، دانشگاه تربیت مدرس، تهران. تلفن: ۰۹۱۵۵۰۳۴۵۲۲

Email: ali.shamsoddini@modares.ac.ir

<https://orcid.org/0000-0002-4559-7563>

<https://dx.doi.org/10.48308/gisj.2023.103096>



Copyright: © 2023 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

۱- مقدمه

2020). همهٔ این الگوریتم‌ها به یک یا چند جفت تصاویر با قدرت تفکیک مکانی پایین و بالا برای آموزش و یک تصویر با قدرت تفکیک مکانی پایین در تاریخ پیش‌بینی، به‌منزلهٔ ورودی، نیاز دارند. درواقع، خروجی این الگوریتم‌ها تصویری شبیه‌سازی‌شده با قدرت تفکیک مکانی بالا در تاریخ پیش‌بینی است. ذاتاً، همهٔ الگوریتم‌های ادغام مکانی- زمانی اطلاعات مکانی را از تصاویر دارای قدرت تفکیک مکانی بالا و اطلاعات زمانی را از تصاویر دارای قدرت تفکیک مکانی پایین دریافت می‌کنند (Zhu et al., 2016).

STARFM یکی از قدیمی‌ترین روش‌های برپایهٔ وزن، در زمینهٔ ادغام مکانی- زمانی است. در این شیوه، بازتاب طبق یک رابطهٔ وزن‌دهی خطی، برای تصاویر با قدرت تفکیک مکانی بالاتر، به‌دست می‌آید و پیکسل‌های مشابه در همسایگی، با توجه به شباهت طیفی‌شان با پیکسل مرکزی، انتخاب می‌شوند. STARFM برای مناظر همگن و مناطق با پوشش زمین پایدار در طول دورهٔ مورد نظر مؤثرتر است و بهترین نتایج را زمانی دربردارد که پیکسل‌هایی همگن در منطقه وجود داشته باشند (Mileva et al., 2018). الگوریتم STAARCH^۱، با معرفی فاکتوری برای تعیین کمیت تغییر بازتاب در تصاویر لندست، صحت ادغام مکانی- زمانی را برای مناطق دارای تغییر پوشش زمین جنگل، افزایش می‌دهد که نتایج خوبی در مورد مناطق جنگلی داشته است. این روش بر مبنای تبدیل تسلدکپ^۲ عمل می‌کند و شاخص‌هایی را برای مناطق تغییر یافته در نظر می‌گیرد. از جمله محدودیت‌های این روش مناسب بودن فقط برای منطقهٔ جنگلی است (Hilker et al., 2009).

1. Spatio-Temporal Fusion
2. Weight-Based Methods
3. Un-Mixing Based Methods
4. Learning-Based Methods
5. Bayesian-Based Methods
6. Spatial Temporal Adaptive Algorithm For Mapping Reflectance Change
7. Tasseled Cap Transformation

داده‌های سنجنش از دوری، از نظر قدرت تفکیک مکانی در سه دستهٔ کلی قدرت تفکیک مکانی بالا، متوسط و پایین قرار می‌گیرند. داده‌های با قدرت تفکیک مکانی بالا اغلب دارای قدرت تفکیک زمانی و طیفی پایین و داده‌های با قدرت تفکیک مکانی پایین دارای قدرت تفکیک طیفی و زمانی بالا هستند. با وجود این، در حال حاضر هیچ‌یک از سنجنده‌های ماهواره‌ای به‌تنهایی پوشش جهانی داده‌های سری زمانی دارای قدرت تفکیک زمانی بالا را با قدرت تفکیک مکانی بالا ارائه نمی‌کند که دلیل آن تناقض بین اندازهٔ پیکسل و عرض نوار و نیز وجود ابر در تصاویر است (Gevaert & García-Haro, 2015). از این رو استفاده از تصاویری با قدرت تفکیک‌های متفاوت و ادغام این تصاویر با هم می‌تواند در سنجنش از دور، همچون مطالعات پویایی سطح زمین، آب‌وهواشناسی، پایش روزانهٔ محصولات کشاورزی، مناطق دارای ابر و تبخیر-تعرق، کاربردهای بسیاری داشته باشد (Wang & Atkinson, 2018). یکی از مهم‌ترین مباحث، در زمینهٔ ادغام تصاویر ماهواره‌ای، ادغام مکانی- زمانی^۱ تصاویر سنجنده‌های گوناگون است. در این نوع ادغام، تصاویر با قدرت تفکیک مکانی بالا و تصاویر با قدرت تفکیک مکانی بالا، ادغام می‌شوند. به‌صورت کلی طی این ادغام، تصاویر با قدرت تفکیک مکانی بالا و قدرت تفکیک زمانی پایین با تصاویر دارای قدرت تفکیک مکانی پایین و قدرت تفکیک زمانی بالا، برای ایجاد سری‌های زمانی با قدرت تفکیک‌های مکانی و زمانی بالا، به‌صورت توأم ترکیب می‌شوند (Belgiu & Stein, 2019).

مطالعات بسیاری دربارهٔ ادغام داده‌های سنجنش از دور، برای رسیدن به قدرت تفکیک مکانی و زمانی بالا در مورد داده‌های اپتیک و حرارتی، انجام شده است. در مجموع، روش‌های ادغام مکانی- زمانی را می‌توان در پنج گروه روش‌های مبتنی بر وزن^۲، روش‌های مبتنی بر عدم اختلاط^۳، روش‌های مبتنی بر یادگیری^۴، روش‌های مبتنی بر بیزی^۵ و روش‌های ترکیبی قرار داد (Li et al.,

روش مبتنی بر وزن و عدم اختلاط، توسعه یافته‌اند. یکی از این شیوه‌ها روش ادغام داده‌های مکانی-زمانی انعطاف‌پذیر (FSDAF)^۱ است که تغییرات زمانی هر کلاس را با عدم اختلاط مکانی اختلاف تصاویر دارای قدرت تفکیک مکانی پایین و سپس توزیع باقی‌مانده‌های تخمین زده شده به روش درون‌یابی^۲ TPS^۳ را براساس وزن‌دهی مکانی پیکسل‌های مشابه همسایه، تخمین می‌زند (Zhu et al., 2016). با این حال چون بیشتر مطالعات در زمینه الگوریتم‌های ادغام مکانی-زمانی برای شبیه‌سازی تصاویر لندست توسعه یافته‌اند، استفاده از این الگوریتم‌ها برای سایر داده‌های سنجش از دوری حائز اهمیت است. ماهواره سنتینل-۲ در سال ۲۰۱۵ و ماهواره سنتینل-۲B در سال ۲۰۱۷ پرتاب شدند. بیشترین قدرت تفکیک مکانی آنها ده متر و دوره بازدید دوباره پنج روز است. تصویر سنتینل-۲، در تغییرات کاربری و پوشش زمین، استفاده گسترده‌ای داشته است (He et al., 2021) اما، به دلیل وجود ابر و سایه، معمولاً به بیش از پنج روز (گاه تا چندین ماه) نیاز است تا تصویری بدون ابر از سنتینل-۲ برای مناطق خاص به دست آید. مشاهدات سنتینل-۲، به‌ویژه در مورد مناطقی که تحت تأثیر پوشش ابری قرار دارند، کافی نیست (Wang & Atkinson, 2018). مطالعات بسیاری دربارهٔ ایجاد داده‌های دارای قدرت تفکیک مکانی و زمانی بالا، با استفاده از الگوریتم‌های ترکیب مکانی و زمانی، برای لندست انجام شده است.

مناطق ناهمگن، مدل ادغام بازتابی تطبیقی مکانی و زمانی پیشرفته‌ای به نام ESTARFM^۱، با معرفی ضریب تبدیلی برای توصیف رابطه خطی بین تغییرات در بازتاب‌های مادیس و لندست، پیشنهاد شد (Zhu et al., 2010). ESTARFM، در واقع، برای مناطق ناهمگن و مکان‌هایی سودمند است که روابط بین تصاویر، در زمان‌های گوناگون، به صورت خطی است. وانگ و اتکینسون^۲ (۲۰۱۸) روش Fit-FC را برای مقابله با تغییرات شدید فصلی در ادغام مکانی-زمانی معرفی کردند. روش‌های مبتنی بر وزن‌دهی مکانی در پیش‌بینی دمای سطح زمین (Shen et al., 2016)، شاخص سطح برگ (LAI) (Houborg et al., 2016) و شاخص پوشش گیاهی نرمال شده (NDVI) (Tewes et al., 2015) کاربرد گسترده‌ای داشته است. روش‌های مبتنی بر عدم اختلاط مکانی معمولاً براساس یک تصویر، با قدرت تفکیک مکانی پایین در زمان پیش‌بینی و یک نقشه طبقه‌بندی پوشش زمین تولید شده از داده‌های با قدرت تفکیک مکانی خوب (مثلاً تصاویر چندطیفی در قدرت تفکیک مکانی خوب لندست) به کار می‌روند. تکنیک چندحسگر چندگانه (MMT) که ژوکو^۳ و همکاران (۱۹۹۹) پیشنهاد کرده‌اند، یکی از نخستین روش‌های مبتنی بر عدم اختلاط مکانی است. MMT بازتاب را با توجه به پیکسلی با قدرت تفکیک مکانی خوب و کلاس مربوط به آن، شبیه‌سازی می‌کند. در این شیوه‌ها، فرض بر این است که بازتاب با قدرت تفکیک مکانی پایین ترکیبی از پاسخ‌های هر طبقه پوشش زمین است (Zhukov et al., 1999). رویکرد ادغام داده‌های مکانی-زمانی بهبودیافته (ISTDAF)^۴ یکی دیگر از الگوریتم‌های ادغام مکانی-زمانی است که وو^۵ و همکاران (۲۰۱۶) برای غلبه بر نقاط ضعف الگوریتم STDAF^۶ مطرح کردند. گوارت و گارسیا-آرو^۷ (۲۰۱۵) راه‌حلی بیزی را برای بازتاب تصاویر با قدرت تفکیک مکانی بالا، در مدل عدم اختلاط، اعمال کردند. روش‌های ترکیبی نیز، با ترکیب مکانیسم‌های دو دسته

1. Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model
2. Wang & Atkinson
3. Zhukov
4. Improved Spatial and Temporal Data Fusion Approach
5. Wu
6. Spatial and Temporal Data Fusion Approach
7. Gevaert & García-Haro
8. Flexible Spatiotemporal Data Fusion
9. Thin-Plate Spline

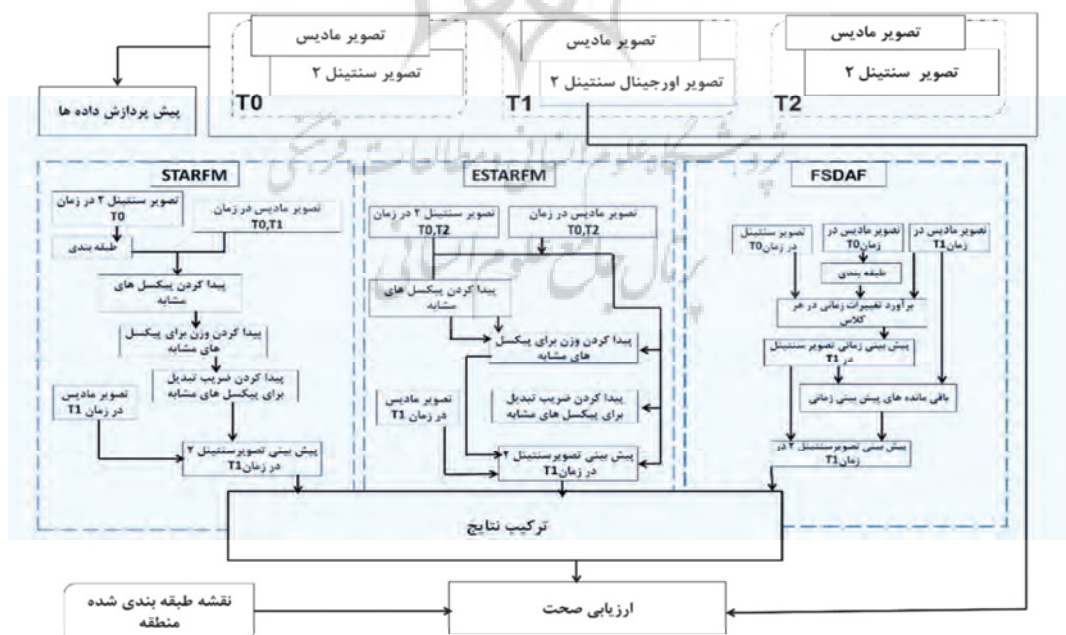
متفاوت هر کلاس و درجه همگنی و ناهمگنی آنها، مقایسه نتایج ریزمقیاس‌نمایی برای باندهای آبی، سبز، قرمز و مادون‌قرمز نزدیک مادیس است؛ این کار با استفاده از سه الگوریتم ادغام مکانی-زمانی STARFM، ESTARFM و FSDAF در کلاس‌های اراضی شهری، کشاورزی، باغ، مرتع و آب انجام شده است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

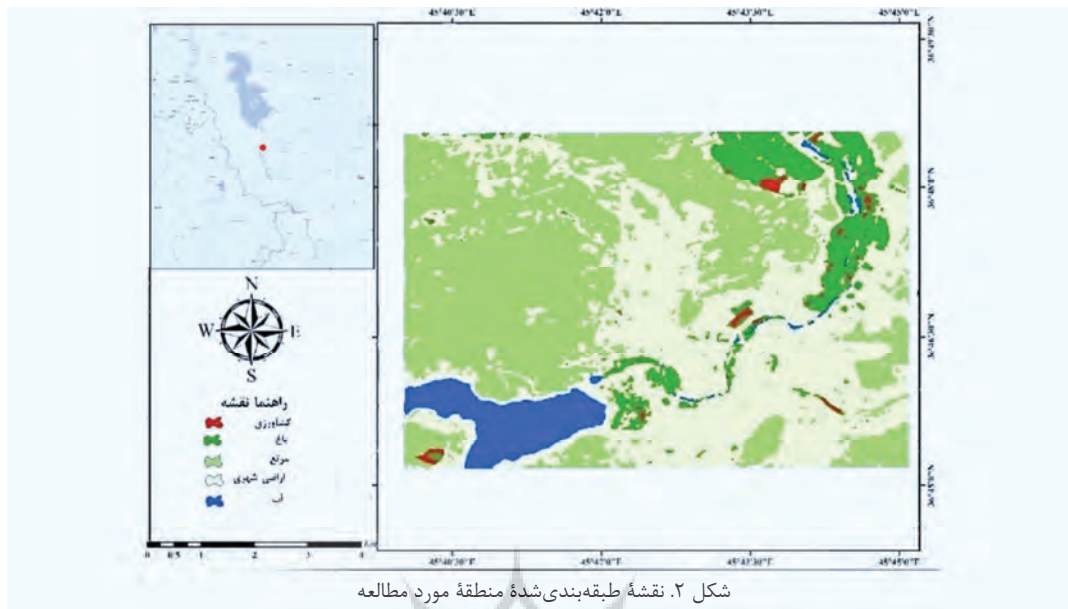
منطقه مورد مطالعه (شکل ۳) بخشی از شهر مهاباد و زمین‌های اطراف آن در استان آذربایجان غربی است که کاربری بسیار متنوعی دارد. این منطقه در طول جغرافیایی ۴۵ درجه و ۴۰ دقیقه تا ۴۵ درجه و ۴۵ دقیقه شرقی و در عرض جغرافیایی ۳۶ درجه و ۴۵ دقیقه تا ۳۶ درجه و ۸۰ دقیقه شمالی قرار گرفته است. مساحت منطقه مطالعاتی حدود ۴۱/۱ کیلومتر مربع است و پوشش کاربری این منطقه شامل شهری، باغ، کشاورزی، مرتع و آب می‌شود.

از پرکاربردترین این الگوریتم‌ها، الگوریتم‌های FSDAF، STARFM و ESTARFM است. الگوریتم STARFM برای مناطق با ترکیب همگن پوشش زمینی و مسطح، بیشتر کاربرد دارد. الگوریتم ESTARFM در مناطقی با ناهمگنی بالا و الگوریتم FSDAF درمورد مناطق ناهمگن و دارای هر دو نوع تغییر تدریجی و ناگهانی کاربرد دارد. داده‌های سنتینل-۲ دارای قدرت تفکیک مکانی بیشتر از لندست است و از این‌رو، می‌تواند در پایش روزانه پدیده‌های زمینی که به قدرت تفکیک مکانی بهتری نیاز دارند، تأثیرگذار باشد. افزون‌براین الگوریتم‌های ترکیب مکانی-زمانی، در بیشتر موارد، برای داده‌های لندست به‌وجود آمدند. با توجه به این نکات، پژوهش پیش‌رو از الگوریتم‌های پرکاربرد و پایه مورد استفاده برای لندست، با هدف مقایسه این الگوریتم‌ها در تولید تصاویر سنتینل-۲ و ترکیب نتایج این الگوریتم‌ها برای رسیدن به نتیجه بهتر در تولید تصاویر سنتینل-۲، انجام شده است. یکی دیگر از اهداف این مطالعه، با توجه به نتایج متفاوت ریزمقیاس‌نمایی درمورد کلاس‌های کاربری گوناگون و نیز تغییرپذیری




شکل ۱. نمودار جریان‌ی تحقیق

ارزیابی الگوریتم‌های ریزمقیاس‌نمایی مکانی-زمانی داده‌های مادیس به داده‌های ...



شکل ۲. نقشه طبقه‌بندی‌شده منطقه مورد مطالعه



شکل ۳. نقشه موقعیت جغرافیایی منطقه مورد مطالعه

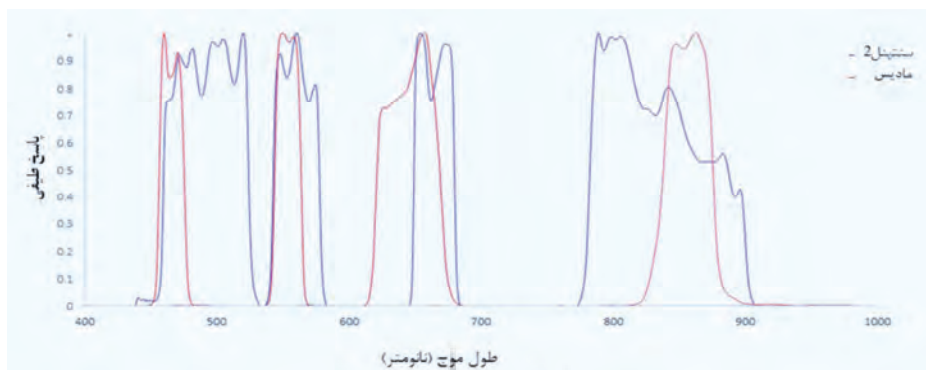
۲-۲- داده‌های مورد استفاده

و ۳۱ اوت ۲۰۲۰ برای هر دو سنجنده تهیه شده است. محدوده طیفی باندهای متناظر در مادیس و سنتینل-۲ در جدول ۱ و شکل ۳، برای تفسیر بهتر نتایج، نشان داده شده است.

داده‌های به‌کاررفته در این تحقیق باندهای مرئی و مادون‌قرمز نزدیک، متعلق به سنتینل-۲ و مادیس، با قدرت تفکیک مکانی به‌ترتیب ۱۰ متر و ۵۰۰ متر است. این داده‌ها در سه تاریخ ۲۱ اوت ۲۰۲۰، ۲۶ اوت ۲۰۲۰

جدول ۲. محدوده متناظر باندهای انعکاسی مادیس و سنتینل-۲

سینجده	آبی (میکرومتر)	سبز (میکرومتر)	قرمز (میکرومتر)	مادون قرمز نزدیک (میکرومتر)
سنتینل-۲	۴۵۹/۴ - ۵۲۵/۴	۵۴۱/۸ - ۵۷۷/۸	۶۴۹/۱ - ۶۸۰/۱	۷۷۹/۸ - ۸۸۵/۸
مادیس	۴۷۹ - ۴۵۹	۵۶۵ - ۵۴۵	۶۷۰ - ۶۲۰	۸۷۰ - ۸۴۱



شکل ۳. باندهای متناظر به ترتیب (آبی، سبز، قرمز و مادون قرمز نزدیک) در سینجده‌های مادیس و سنتینل-۲

۲-۲- روش پژوهش

شود اما در مورد دو روش دیگر، فقط از دو تاریخ استفاده شد؛ به این صورت که در تاریخ اول، از تصاویر سنتینل-۲ و مادیس و در تاریخ دوم، از تصاویر مادیس استفاده شد تا در این تاریخ، تصاویر سنتینل-۲ پیش‌بینی شود. سپس نتایج برای سه الگوریتم مورد نظر به دست آمد و از داده‌های اصلی سنتینل-۲ که در تاریخ تصویر ریزمقیاس‌نمایی شده موجود بود، به منظور مقایسه نتایج استفاده شد. برای ارزیابی صحت نتایج ریزمقیاس‌نمایی در کلاس‌های متفاوت نیز، نقشه طبقه‌بندی شده منطقه مورد مطالعه، متعلق به این تاریخ با استفاده از داده‌های سنتینل-۲ تهیه شده است (شکل ۲). به منظور ارزیابی جداگانه صحت نتایج در مورد هر کلاس در باندهای متفاوت، شاخص‌های آماری ضریب همبستگی^۱، انحراف استاندارد^۲، RMSE^۳، و بایاس^۴ محاسبه شد. سرانجام به منظور

همان‌طور که در نمودار جریان‌ی تحقیق در شکل ۱ مشخص است، ابتدا تصاویر سینجده مادیس و سنتینل-۲ در سه تاریخ ۲۶، ۳۱ اوت ۲۰۲۰ انتخاب شد؛ در این تاریخ‌ها میزان ابرناکی حداقل بوده است. سپس باندهای مرئی و مادون قرمز نزدیک، در هر دو سینجده، انتخاب شد و محدوده طیفی این باندها در هر دو سینجده، از نظر انطباق با هم، بررسی شدند. مطابق شکل ۳، این محدوده‌ها کاملاً بر هم منطبق نیستند. در مرحله بعد، این تصاویر از نظر تصحیحات اتمسفری و هندسی تصحیح شدند و اندازه پیکسل‌های مادیس به اندازه ده‌متری مشابه با سنتینل-۲ تبدیل شد و داده‌ها برای ورود به الگوریتم‌های ریزمقیاس‌نمایی آماده شدند. پیش‌تر هم اشاره کردیم و در شکل ۱ نیز مشخص است که این الگوریتم‌ها به تعداد تصاویر متفاوتی برای پیش‌بینی نیاز دارند؛ بدین ترتیب برای روش ESTARFM از سه تاریخ مورد نظر استفاده شد. در تاریخ اول و سوم، هر دو تصاویر سنتینل-۲ و مادیس و برای تاریخ دوم، تصاویر مادیس به کار رفت تا تصویر سنتینل-۲، متعلق به این تاریخ، شبیه‌سازی

1. Correlation
2. Standard Deviation
3. Root Mean Square Error
4. Normalized Root Mean Square Error
5. Bias

الگوریتم، برای پیش‌بینی تصویر دارای قدرت تفکیک مکانی بالاتر، یک جفت تصویر از هر دو نوع قدرت تفکیک، در زمانی پیش‌تر از تاریخ پیش‌بینی و همچنین تصویری با قدرت تفکیک مکانی پایین‌تر و متعلق به زمان پیش‌بینی، استفاده می‌شود (Gao et al., 2006).

دستیابی به نتیجه بهتر، نتایج این الگوریتم‌ها براساس روش میانگین‌گیری با هم ترکیب شد و صحت نتایج ترکیب نیز ارزیابی شدند.

۲-۴- الگوریتم‌های ریزمقیاس‌نمایی مورد استفاده

۲-۴-۱- الگوریتم STARFM

گائو^۱ و همکاران (۲۰۰۶)، به منظور دستیابی به تصاویر با قدرت تفکیک مکانی و زمانی بالاتر، الگوریتمی را برای داده‌های لندست-۷ و مادیس ابداع کردند که STARFM نام گرفت. این الگوریتم، در واقع، از الگوریتم‌های مهم و مبنایی است که در ادغام مکانی-زمانی تصاویر سنجنش از دوری به کار می‌رود و بر این فرض استوار است که پوشش زمین و خطاها، بین دو تاریخ ورودی و پیش‌بینی، ثابت است؛ بنابراین می‌توان، در زمان پیش‌بینی، با استفاده از رابطه (۱) تصویر را شبیه‌سازی کرد.

$$L(x_i, y_j, T_p) = L(x_i, y_j, T_0) + (M(x_i, y_j, T_p) + M(x_i, y_j, T_0)) \quad (1)$$

در این معادله، $L(x_i, y_j, T_0)$ و $L(x_i, y_j, T_p)$ بازتابندگی‌های تصاویر دارای قدرت تفکیک بالاتر یا همان لندست در پیکسل x, y و زمان‌های T_0 و T_p است و $M(x_i, y_j, T_p)$ و $M(x_i, y_j, T_0)$ بازتابندگی‌های تصاویر دارای قدرت تفکیک پایین‌تر یا مادیس در پیکسل x, y در زمان‌های T_0 و T_p محسوب می‌شود. البته این رابطه فقط برای حالت خاصی صدق می‌کند که منطقه مسطح و دارای ترکیب همگن پوشش زمینی است و در باقی حالت‌ها، الگوریتم با استفاده از اطلاعات اضافی حاصل از پیکسل‌های همسایه و شباهت‌های طیفی پیکسل‌ها و یک تابع وزن‌دهی، بازتابندگی لندست را در تاریخ مورد نظر، پیش‌بینی می‌کند. این الگوریتم فرض می‌کند پیکسل‌های لندست متناظر با پیکسل مادیس الگوهای تغییرات مشابهی را به‌نمایش می‌گذارند که این فرض می‌تواند عملکرد این الگوریتم را در مورد پیکسل‌های مخلوط، با خطا مواجه کند. در این

۲-۴-۲- الگوریتم ESTARFM

این الگوریتم نسخه‌ای از مدل STARFM است که ژو^۲ و همکاران (۲۰۱۰) آن را برای استفاده در مناطق ناهمگن، ارتقا دادند. اساس این مدل بر این فرض است که بین تصاویر سنجنده‌های گوناگون، در یک زمان معین، همبستگی وجود دارد و می‌توان از این همبستگی برای ادغام تصاویر بهره برد. این مدل، برای دو حالت متفاوت پیکسل‌های همگن و ناهمگن، شرایط متفاوتی را در نظر می‌گیرد. در محدوده‌ای همگن، می‌توان فرض کرد بین میزان بازتابندگی پیکسل‌های تصویر دارای قدرت تفکیک مکانی پایین‌تر و پیکسل‌های متناظر آن در تصویر دارای قدرت تفکیک مکانی بالاتر، در زمانی مشخص، شباهت فراوانی وجود دارد؛ بنابراین می‌توان بازتابندگی تصویر دارای قدرت تفکیک مکانی بیشتر را در قالب معادله‌ای خطی از بازتابندگی پیکسل متناظرش در تصاویر دارای قدرت تفکیک مکانی کمتر، به صورت رابطه (۲) نوشت.

$$L(x, y, T_p, B) = L(x, y, T_0, B) + \alpha \times (M(x, y, T_p, B) - M(x, y, T_0, B)) \quad (2)$$

در این معادله، $L(x, y, T_0, B)$ و $L(x, y, T_p, B)$ بازتابندگی‌های تصاویر دارای قدرت تفکیک بیشتر، یا همان لندست در پیکسل x, y و زمان‌های T_0, T_p و باند B است. $M(x, y, T_0, B)$ و $M(x, y, T_p, B)$ نیز بازتابندگی‌های تصاویر با قدرت تفکیک بیشتر، یا مادیس در پیکسل x, y و زمان‌های T_0, T_p و باند B است. α ضریب تبدیل برای کالیبراسیون تصاویر مادیس

1. Gao

2. Zhu

پیکسل لندست (سی متر) تبدیل می‌شوند. در گام نخست، دو تصویر لندست زمان اول و دوم با روش‌های نظارت‌نشده طبقه‌بندی می‌شوند و با استفاده از پنجره‌ای متحرک، پیکسل‌های مشابه پیکسل مرکزی آن پنجره تعیین می‌شود. در نتیجه، برای هر پیکسل، تعدادی پیکسل مشابه وجود دارند که با توجه به فاصله‌شان از پیکسل مرکزی و میزان همبستگی‌شان با آن پیکسل، وزن‌دهی (بین ۰ و ۱) می‌شوند. برای به‌دست آوردن ضرایب تبدیل نیز، از رگرسیون پیکسل‌های مشابه استفاده می‌شود و در نهایت، بازتابندگی پیکسل مرکزی لندست مانند زمان پیش‌بینی، از طریق وزن‌دهی زمانی بازتابندگی دو پیکسل لندست قبل و پس از آن، به‌دست می‌آید (Zhu et al., 2010).

۳-۴-۲- الگوریتم FSDAF

این الگوریتم را ژو و همکاران (۲۰۱۶) ارتقا دادند. در این الگوریتم، داده‌های ورودی شامل یک زوج تصویر دارای قدرت تفکیک مکانی پایین در زمان t_1 و t_2 و تصویر دارای قدرت تفکیک مکانی پایین در زمان t_1 می‌شود. الگوریتم FSDAF شش گام اصلی دارد: (۱) طبقه‌بندی تصویر دارای قدرت تفکیک مکانی بالا در زمان t_1 ؛ (۲) تخمین تغییرات زمانی هر طبقه در تصویر دارای قدرت تفکیک مکانی پایین از زمان t_1 به زمان t_2 ؛ (۳) پیش‌بینی تصویر دارای قدرت تفکیک مکانی بالا در زمان t_2 با استفاده از سطح طبقه‌ای تغییرات زمانی و محاسبه باقی‌مانده هر پیکسل دارای قدرت تفکیک مکانی بالا؛ (۴) پیش‌بینی تصویر دارای قدرت تفکیک مکانی بالا از تصویر دارای قدرت تفکیک مکانی پایین در زمان t_2 ؛ (۵) توزیع باقی‌مانده‌ها براساس پیش‌بینی TPS؛ (۶) پیش‌بینی نهایی تصویر دارای قدرت تفکیک مکانی بالا، با استفاده از اطلاعات پیکسل‌های همسایه. برای تعیین نسبت هر کلاس در یک پیکسل مادیس (تصویر

و لندست نسبت به همدیگر، زمان p متعلق به تاریخ پیش‌بینی و زمان 0 تاریخ تصویر ورودی‌اند. در این الگوریتم، تغییرات بازتابندگی بین دو تاریخ در مورد پیکسل‌های ناهمگن، به‌صورت تابعی از مجموع وزن‌دهی شده تغییرات هر پوشش در پیکسل مورد نظر، لحاظ می‌شود و علاوه بر پیکسل هدف، پیکسل‌های همسایه مشابه آن نیز در نظر گرفته می‌شود. بدین‌منظور، پنجره‌ای متحرک با اندازه W برای شناسایی پیکسل‌های مشابه به‌کار می‌رود و در این حالت، بین بازتابندگی تصاویر دارای قدرت تفکیک کمتر و بیشتر، رابطه (۳) برقرار است.

$$\text{رابطه (۳)} \quad L(X_{W/2}, Y_{W/2}, T_p, B) = L(X_{W/2}, Y_{W/2}, T_0, B) + \sum_{i=1}^N W_i \times \alpha \times (M(X_i, Y_i, T_p, B) - M(X_i, Y_i, T_0, B))$$

در این معادله، N تعداد پیکسل‌های مشابه در پنجره متحرک، شامل خود پیکسل مرکزی (هدف) با مختصات $X_{W/2}, Y_{W/2}$ است. W_i وزن آلمین پیکسل مشابه و α ضریب تبدیل آلمین پیکسل مشابه محسوب می‌شود. اندازه پنجره متحرک برای جست‌وجوی پیکسل‌های مشابه، براساس همگنی منطقه تعیین می‌شود. برای تعیین ضرایب رابطه (۳) و تعیین بازتابندگی پیکسل تصویر ریزمقیاس‌شده در مدل ESTARFM، به دو زوج تصویر لندست و مادیس از دو زمان متفاوت و نیز یک تصویر مادیس، متعلق به زمانی که قرار است تصویر لندست مانند شبیه‌سازی شود، نیاز است. معمولاً دو تصویر لندست و مادیس در زمان‌های قبل و پس از تاریخ پیش‌بینی استفاده می‌شوند. ابتدا پیش‌پردازش‌های لازم، مانند تصحیحات هندسی و اتمسفری، روی همه تصاویر لندست و مادیس انجام می‌شود تا بازتابندگی سطحی تولید شود و تمامی تصاویر، از نظر مکانی، کاملاً بر هم منطبق باشند. سپس تصاویر مادیس، با باز نمونه‌گیری، به اندازه

دوم به‌دست آورد. سپس با استفاده از اطلاعات پیکسل‌های همسایه، پیش‌بینی نهایی تصویر دارای قدرت تفکیک مکانی بالا انجام می‌شود. قدرت این الگوریتم بیشتر از دیگر الگوریتم‌های موجود است؛ چون به حداقل تعداد داد، ورودی نیاز دارد و درمورد مناطق ناهمگن، کارایی مطلوبی دارد. همچنین این الگوریتم اصول و مبانی ساده‌ای دارد و می‌تواند هر دو نوع تغییر تدریجی و ناگهانی را در نظر بگیرد (Zhu et al., 2016).

۳- نتایج و بحث

نتایج شبیه‌سازی تصاویر سن‌تینل-۲ از طریق سه الگوریتم ESTARFM، STARFM و FSDAF درمورد کلاس‌های کاربری شهری، کشاورزی، باغ، مرتع و آب، متعلق به تاریخ ۲۶ اوت ۲۰۲۰، در جدول ۲ آورده شده است. نتایج نشان می‌دهد صحت کلاس شهری و باغ بهتر از دیگر کلاس‌هاست؛ به‌گونه‌ای که ضریب تعیین بین ۸۵ تا ۹۰٪ را نشان می‌دهند. در هر سه الگوریتم، کلاس کاربری آب در همهٔ باندها نتایجی ضعیف‌تر از کلاس‌های دیگر دارد و دامنهٔ ضریب تعیین آن بین باندهای گوناگون، ۳۶ تا ۷۶٪ برای الگوریتم ESTARFM، ۱۸ تا ۶۸٪ برای الگوریتم STARFM و ۲۶ تا ۶۴٪ برای الگوریتم FSDAF است. این نتایج درمورد کلاس آب، ممکن است حاصل عملکرد ضعیف الگوریتم‌های به‌کاررفته در شبیه‌سازی در پیکسل‌های مرزی باشد زیرا، همان‌طور که در شکل ۸ مشخص است، از نظر بصری، پیکسل‌های مرزی در کلاس آب نتایج ضعیف‌تری نشان می‌دهند. علاوه‌براین مقایسهٔ سه الگوریتم مورد استفاده، متعلق به کلاس‌های کاربری متفاوت، در شکل‌ها ۵، ۶ و ۷ نشان می‌دهد اراضی شهری و باغ نتایجی بهتر و پایدارتر در هر سه الگوریتم دارند و نتایج اراضی کشاورزی ضعیف‌تر از دیگر کلاس‌ها بوده است.

با قدرت تفکیک مکانی پایین، تصویر لندست (تصویر دارای قدرت تفکیک مکانی بالا) در زمان اول، با طبقه‌بندی نظارت‌شده یا نظارت‌نشده و به‌کارگیری همهٔ باندهای موجود، طبقه‌بندی می‌شود. الگوریتم طبقه‌بندی براساس نوع کاربرد و دسترسی به داده‌های منطقه انتخاب می‌شود. اگر داده‌های سطح زمین مشخص و در دسترس باشند، می‌توان از الگوریتم‌های طبقه‌بندی نظارت‌شده استفاده کرد و در غیر این‌صورت، استفاده از الگوریتم‌های نظارت نشده مانند ISODATA می‌تواند به طبقه‌بندی تصویر کمک کند. برای تخمین تغییرات زمانی، باند b پیکسل دارای قدرت تفکیک مکانی پایین (x_i, y_i) طبق رابطه (۴) تعریف می‌شود.

$$\text{رابطه (۴)} \quad \Delta C(x_i, y_j, b) = C2(x_i, y_j, b) - C1(x_i, y_j, b)$$

مطابق نظریهٔ اختلاط خطی طیفی، تغییرات زمانی پیکسل تصویری دارای قدرت تفکیک مکانی پایین با مجموع وزنی تغییرات زمانی همهٔ کلاس‌های داخل آن، طبق رابطه (۵)، برابر است.

$$\text{رابطه (۵)} \quad \Delta C(x_i, y_j, b) = \sum_{c=1}^i f_c(x_i, y_j, b) \Delta F(c, b)$$

در این معادله، i تعداد کلاس‌ها و $\Delta F(c, b)$ تغییرات کلاس c باند b در تصویر دارای قدرت تفکیک مکانی بیشتر، بین زمان‌های اول و دوم است. برای پیش‌بینی تصویر دارای قدرت تفکیک مکانی بیشتر و باقی‌مانده‌ها با استفاده از تغییرات زمانی، تغییرات زمانی هر کلاس را می‌توان به پیکسل‌های تصویر دارای قدرت تفکیک مکانی بیشتر و مورد استفاده، مرتبط کرد و تغییرات درون کلاسی را در نظر گرفت. درواقع، اگر نوع پوشش گیاهی بین زمان‌های ۱ و ۲ تغییر نکند، با افزودن تغییرات زمانی به مقادیر مشاهده‌شدهٔ پیکسل‌های تصویر دارای قدرت تفکیک مکانی بیشتر در زمان اول، می‌توان مقدار پیش‌بینی را درمورد زمان

ناهید حق شناس و علی شمس‌الدینی

جدول ۲. نتایج شبیه‌سازی تصویر سنتینل-۲ با استفاده از الگوریتم‌های ریزمقیاس‌نمایی مکانی-زمانی

کلاس کاربری	الگوریتم ادغام مکانی زمانی	باندها	RMSE	NRMSE	R ²	Bias	STD
	STARFM	آبی	۰/۰۱	۰/۰۳	۰/۸۳	۰/۰۰	۰/۰۱
		سبز	۰/۰۱	۰/۰۲	۰/۹۲	۰/۰۰	۰/۰۱
		قرمز	۰/۰۱	۰/۰۲	۰/۸۷	۰/۰۰	۰/۰۱
		مادون قرمز	۰/۰۱۳	۰/۰۲	۰/۸۹	۰/۰۰	۰/۰۱
مرتع	ESTARFM	آبی	۰/۰۱	۰/۰۲	۰/۸۹	۰/۰۰۲	۰/۰۱
		سبز	۰/۰۱	۰/۰۲	۰/۹۱	۰/۰۰	۰/۰۱
		قرمز	۰/۰۱	۰/۰۲	۰/۹۲	۰/۰۰	۰/۰۱
		مادون قرمز	۰/۰۱	۰/۰۲	۰/۹۴	۰/۰۱	۰/۰۱
	FSDAF	آبی	۰/۰۱	۰/۰۴	۰/۷۶	۰/۰۱	۰/۰۱
		سبز	۰/۰۱	۰/۰۵	۰/۸۰	۰/۰۱	۰/۰۱
		قرمز	۰/۰۲	۰/۰۷	۰/۶۶	۰/۰۱	۰/۰۲
		مادون قرمز	۰/۰۴	۰/۱۱	۰/۶۰	۰/۰۲	۰/۰۳
	STARFM	آبی	۰/۰۲	۰/۰۶	۰/۷۲	۰/۰۱	۰/۰۱
		سبز	۰/۰۱	۰/۰۵	۰/۸۴	۰/۰۱	۰/۰۱
		قرمز	۰/۰۳	۰/۱۰	۰/۶۳	۰/۰۲	۰/۰۲
		مادون قرمز	۰/۰۴	۰/۱۴	۰/۵۹	۰/۰۳	۰/۰۳
کشاورزی	ESTARFM	آبی	۰/۰۲	۰/۰۳	۰/۹۵	۰/۰۰	۰/۰۲
		سبز	۰/۰۱	۰/۰۴	۰/۷۵	۰/۰۱	۰/۰۱
		قرمز	۰/۰۱	۰/۰۱	۰/۷۵	۰/۰۱	۰/۰۵
		مادون قرمز	۰/۰۴	۰/۱۴	۰/۴۳	۰/۰۲	۰/۰۳
	FSDAF	آبی	۰/۰۱	۰/۰۴	۰/۷۶	۰/۰۸	۰/۰۱
		سبز	۰/۰۱	۰/۰۵	۰/۸۰	۰/۰۱	۰/۰۱
		قرمز	۰/۰۲	۰/۰۷	۰/۶۶	۰/۰۱	۰/۰۲
		مادون قرمز	۰/۰۴	۰/۱۱	۰/۶۰	۰/۰۲	۰/۰۳
	STARFM	آبی	۰/۰۱	۰/۳۰	۰/۱۹	۰/۰۱	۰/۰۱
		سبز	۰/۰۱	۰/۲۴	۰/۴۱	۰/۰۱	۰/۰۱
		قرمز	۰/۰۱	۰/۳۱	۰/۲۶	۰/۰۱	۰/۰۱
		مادون قرمز	۰/۰۲	۰/۰۸	۰/۶۸	۰/۰۱	۰/۰۲
آب	ESTARFM	آبی	۰/۰۱	۰/۱۶	۰/۳۷	۰/۰۰	۰/۰۰
		سبز	۰/۰۱	۰/۲۰	۰/۵۳	۰/۰۱	۰/۰۱
		قرمز	۰/۰۱	۰/۲۴	۰/۴۰	۰/۰۱	۰/۰۱
		مادون قرمز	۰/۰۱۴	۰/۰۵	۰/۷۶	۰/۰۱	۰/۰۱
	FSDAF	آبی	۰/۰۱	۰/۲۷	۰/۲۷	۰/۰۱	۰/۰۱
		سبز	۰/۰۱	۰/۲۵	۰/۳۲	۰/۰۱	۰/۰۰
		قرمز	۰/۰۱	۰/۲۹	۰/۲۲	۰/۰۱	۰/۰۱
		مادون قرمز	۰/۰۲	۰/۰۶	۰/۶۵	۰/۰۱	۰/۰۱

ادامهٔ جدول ۲

STD	Bias	R ²	NRMSE	RMSE	باند‌ها	الگوریتم ادغام مکانی زمانی	کلاس کاربری
۰/۰۲	۰/۰۱	۰/۸۴	۰/۰۳	۰/۰۳	آبی	STARFM	
۰/۰۲	۰/۰۰	۰/۸۴	۰/۰۳	۰/۰۲	سبز		
۰/۰۳	۰/۰۰	۰/۸۸	۰/۰۴	۰/۰۳	قرمز		
۰/۰۳	۰/۰۱	۰/۸۷	۰/۰۴	۰/۰۳	مادون قرمز		
۰/۰۲	۰/۰۱	۰/۸۶	۰/۰۳	۰/۰۲	آبی	ESTARFM	شهر
۰/۰۲	۰/۰۰	۰/۸۸	۰/۰۳	۰/۰۲	سبز		
۰/۰۳	۰/۰۰	۰/۹۰	۰/۰۳	۰/۰۳	قرمز		
۰/۰۳	۰/۰۰	۰/۹۰	۰/۰۳	۰/۰۳	مادون قرمز		
۰/۰۲	۰/۰۱	۰/۸۶	۰/۰۳	۰/۰۲	آبی	FSDAF	
۰/۰۲	۰/۰۰	۰/۸۷	۰/۰۳	۰/۰۲	سبز		
۰/۰۳	۰/۰۰	۰/۹۰	۰/۰۳	۰/۰۳	قرمز		
۰/۰۳	۰/۰۰	۰/۸۹	۰/۰۳	۰/۰۳	مادون قرمز		
۰/۰۱	۰/۰۱	۰/۷۴	۰/۰۶	۰/۰۱	آبی	STARFM	
۰/۰۱	۰/۰۱	۰/۸۵	۰/۰۴	۰/۰۱	سبز		
۰/۰۱	۰/۰۱	۰/۸۱	۰/۰۷	۰/۰۲	قرمز		
۰/۰۳	۰/۰۱	۰/۸۴	۰/۰۵	۰/۰۳	مادون قرمز		
۰/۰۱	۰/۰۰	۰/۷۹	۰/۰۴	۰/۰۱	آبی	ESTARFM	باغ
۰/۰۱	۰/۰۱	۰/۸۵	۰/۰۴	۰/۰۱	سبز		
۰/۰۱	۰/۰۱	۰/۸۴	۰/۰۵	۰/۰۲	قرمز		
۰/۰۲	۰/۰۱	۰/۸۸	۰/۰۴	۰/۰۲	مادون قرمز		
۰/۰۱	۰/۰۱	۰/۷۹	۰/۰۴	۰/۰۳	آبی	FSDAF	
۰/۰۱	۰/۰۱	۰/۸۴	۰/۰۴	۰/۰۱	سبز		
۰/۰۱	۰/۰۱	۰/۸۴	۰/۰۵	۰/۰۲	قرمز		
۰/۰۲	۰/۰۱	۰/۸۶	۰/۰۵	۰/۰۲	مادون قرمز		

بهترین نتیجه را داشته است. این روش در مورد کلاس کشاورزی در باند سبز نیز نتیجه‌ای بهتر از باندهای دیگر داشته و در باند قرمز و مادون قرمز نزدیک، نتایج ضعیف‌تری به دست داده است. علاوه بر این، طبق شکل ۶ و جدول ۲، نتایج نشان می‌دهند عملکرد الگوریتم FSDAF در مورد باندهای گوناگون، در کلاس‌های شهری و باغ، تقریباً مشابه است؛ در حالی که در مورد سایر کلاس‌ها در باندهای گوناگون، نتایج متفاوت بوده است. ضریب تعیین نتایج ریزمقیاس‌نمایی، برای کلاس آب، کمتر از باقی کلاس‌ها بوده است و بهترین نتیجه، میان باندهای گوناگون در مورد کلاس آب، به باند

همچنین مقایسهٔ نتایج الگوریتم‌های STARFM و FSDAF طبق جدول ۲ نشان می‌دهد کلاس کشاورزی و مرتع نتایج تقریباً متفاوتی در روش‌های گوناگون دارند؛ در حالی که کلاس‌های دیگر، به صورت کلی، حالت پایدارتری داشته‌اند. شکل ۵ به خوبی نشان می‌دهد عملکرد الگوریتم STARFM در باندهای متفاوت، در کلاس‌های شهری، باغ و مرتع، خیلی به هم نزدیک بوده در صورتی که در مورد کلاس آب و کشاورزی در باندهای گوناگون، نتایج متفاوت بوده و عملکرد این روش، برای کلاس آب در باند آبی، کمترین ضریب تعیین و در باند مادون قرمز نزدیک،


ضریب تعیین برای باند مادون قرمز نزدیک، با استفاده از الگوریتم‌های گوناگون در کلاس کشاورزی، مشکل است (Salehi et al., 2018). حساسیت بالای باند مادون قرمز نزدیک در برابر تغییرات گیاهی منطقه مورد مطالعه ممکن است یکی از دلایل این مسئله باشد (Salehi & Shamsoddini, 2021). در واقع، حساسیت بالای باند مادون قرمز نزدیک در برابر تغییرات کلروفیل پوشش گیاهی (Mancino et al., 2020) باعث می‌شود، در یک پوشش کشاورزی، در باند مادون قرمز نزدیک و به‌ویژه با قدرت تفکیک مکانی بالا، پیکسل‌هایی با مقادیر متفاوت بازتابندگی ایجاد شوند؛ در صورتی که تغییرپذیری پیکسل‌ها در سایر باندها بسیار کمتر است. این باعث می‌شود الگوریتم‌های ریزمقیاس‌نمایی نتوانند تغییرات زیاد باند مادون قرمز نزدیک را به‌خوبی شبیه‌سازی کنند (Salehi & Shamsoddini, 2021). در پژوهش پیش رو، در مورد کلاس‌های آب و اراضی شهری، نتایج ریزمقیاس‌نمایی در باندهای گوناگون با کلاس کشاورزی تفاوت داشته است و با اطمینان بیشتری می‌توان دلیل نتایج ضعیف در باند مادون قرمز نزدیک را حساسیت این باند در برابر پوشش‌های گیاهی در نظر گرفت.

برای ارزیابی صحت نتایج در این مطالعه، مطابق جدول ۲، شاخص‌های آماری گوناگونی به‌کار رفته اما برای مقایسه و نتیجه‌گیری کلی، بیشتر از ضریب تعیین استفاده شده است. علاوه بر نتایج شبیه‌سازی سنتینل-۲، با استفاده از الگوریتم‌های متفاوت ریزمقیاس‌نمایی، از روش ترکیب نتایج الگوریتم‌ها نیز به‌روشنی میانگین‌گیری استفاده شده تا صحت نتایج بهبود داشته باشد. نتایج این ترکیب، به‌صورت کلی در مورد همه کلاس‌های کاربری، در جدول ۳ آورده شده و در جدول ۴، نتایج ترکیب در مورد هر کلاس جداگانه نشان داده شده است. طبق جدول‌های ۳ و ۴، ترکیب نتایج این الگوریتم‌ها در برخی کلاس‌ها، به‌ویژه اراضی شهری،


مادون قرمز نزدیک بازمی‌گردد. نتایج کلاس باغ و مرتع نیز تقریباً نزدیک بوده است و هر دو کلاس، در باند سبز، بهترین نتیجه و در باند مادون قرمز نزدیک، نتیجه ضعیف‌تری داشته‌اند. با توجه به شکل ۷ می‌توان مشاهده کرد الگوریتم ESTARFM، در کلاس آب، نتایجی متفاوت در باندهای گوناگون داشته و بهترین نتیجه، مانند مدل‌های قبلی، متعلق به باند مادون قرمز نزدیک است. در مورد این الگوریتم، کلاس کشاورزی در باند آبی نتیجه‌ای بهتر از بقیه باندها داشته و نتایج در دیگر باندها تقریباً نزدیک به هم بوده است. در کلاس‌های مرتع، باغ و اراضی شهری، صحت نتایج در همه باندها به هم نزدیک و بهتر از کلاس آب و کشاورزی است. با توجه به جدول ۲ نیز، بهترین ضریب تعیین در بین الگوریتم‌های ریزمقیاس‌نمایی مورد استفاده، ۰.۹۵٪ و متعلق به الگوریتم ESTARFM در باند آبی، در مورد کلاس کشاورزی است. در واقع، این روش نتیجه کلی بهتری در قیاس با دیگر الگوریتم‌ها داشته است.

در پژوهش شمس‌الدینی و نحوی^۱ (۲۰۲۱) که به منظور ریزمقیاس‌نمایی الگوریتم‌های گوناگون، برای شبیه‌سازی باندهای مرئی و مادون قرمز لندست-۸ در منطقه‌ای همگن از پوشش زمین‌های کشاورزی تک‌محصولی نیشکر انجام شد، باند مادون قرمز نزدیک ضعیف‌ترین نتیجه و باند سبز و قرمز نتایج بهتری داشته‌اند. در این تحقیق، برخلاف تحقیق حاضر، فقط در مورد مناطق کشت‌شده ریزمقیاس‌نمایی انجام شده است اما در پژوهش پیش رو، در مورد کلاس کشاورزی نیز، ضعیف‌ترین نتیجه به باند مادون قرمز نزدیک و بهترین نتیجه به باند سبز تعلق دارد. در مطالعه صالحی^۲ و همکاران (۲۰۱۸) که با هدف شبیه‌سازی داده‌های سنتینل-۲ در مورد زمین‌های کشت نیشکر انجام شد، نتایج باند مادون قرمز نزدیک ضعیف‌تر از سایر باندها بوده که با تحقیق حاضر، به‌منظور شبیه‌سازی تصویر سنتینل-۲ در کلاس کشاورزی، هم‌راستا است. البته با وجود عوامل گوناگون عدم قطعیت در فرایند ریزمقیاس‌نمایی، یافتن علت اصلی کاهش

1. Shamsoddini & Nahvi
2. Salehi



شکل ۵. ارزیابی نتایج ریزمقیاس‌نمایی با استفاده از مدل STARFM کلاس‌های کاربری گوناگون



شکل ۶. ارزیابی نتایج ریزمقیاس‌نمایی با استفاده از مدل FSDAF کلاس‌های کاربری گوناگون

داده‌های لندست انجام شد، ممکن است به پژوهش ما نیز ارتباط بیابد؛ اینکه شاید یکی از دلایل نتایج ضعیف‌تر الگوریتم FSDAF در قیاس با الگوریتم ESTARM، درمورد شبیه‌سازی داده‌های سنتینل-۲ در تحقیق حاضر، فاصله زمانی کوتاه بین تصاویر ورودی و پیش‌بینی باشد و درواقع، به‌علت این فاصله، تغییرات شایان توجهی در این بازه زمانی، درمورد بیشتر کلاس‌ها، مشاهده نشده است (Oldoni et al., 2021) زیرا الگوریتم FSDAF فقط از یک جفت تصویر با قدرت تفکیک مکانی بالا و پایین، به‌منزله ورودی، بهره می‌برد و اغلب از میزان تغییر پوشش زمین، بین دو تاریخ در میان داده‌های ورودی، تأثیر می‌پذیرد (Liao et al., 2016). همچنین با توجه به شکل ۲،


موجب بهبود نتایج و نزدیک شدن آنها به هم در همه باند‌ها و درمورد این کلاس شده است. در باقی موارد، ترکیب نتایج نتوانست نقش شایان توجهی در نتایج داشته باشد. مقایسه بصری نتایج تصویر شبیه‌سازی شده سنتینل-۲، تصویر اصلی سنتینل-۲ و مادیس درمورد کلاس‌های کاربری متفاوت، در شکل ۸ آورده شده است و نشان می‌دهد ESTARFM از نظر بصری نیز شباهت بیشتری به تصویر اصلی سنتینل-۲ دارد.

لیائو^۱ و همکاران (۲۰۱۷)، به‌منظور ایجاد سری‌های زمانی NDVI با استفاده از داده‌های لندست برای مقایسه الگوریتم‌های STARFM، ESTARFM و FSDAF، مطالعه‌ای انجام دادند. نتایج این پژوهش نشان داد الگوریتم FSDAF، در مقایسه با دو الگوریتم دیگر، بهتر بوده و الگوریتم ESTARFM نتایجی بهتر از STARFM داشته است. اگرچه این تحقیق درمورد

1. Liao

ازسویی، در تحقیق حاضر، نتایج شبیه‌سازی درمورد کاربری‌های گوناگونی مقایسه شده و در برخی کاربری‌ها، مانند شهری و آب، تغییرات شایان توجهی مشاهده نشده است؛ بنابراین الگوریتم FSDAF که قابلیت بیشتری برای در نظر گرفتن تغییرات دارد، در این تحقیق نتوانست کاربرد خاص خود را برای در نظر گرفتن تغییرات در مقایسه با دیگر الگوریتم‌ها داشته باشد. این نکته با یافته‌های لیائو و همکاران (۲۰۱۶) هم‌راستا است.

وجود کلاس‌هایی مانند اراضی شهری که مساحت بیشتری از منطقه مورد مطالعه را در مقایسه با کلاس‌های کشاورزی، دربرگرفته است و طی دوره‌های کوتاه زمانی با تغییرات کمتری مواجه می‌شود، می‌تواند یکی از دلایل نتایج ضعیف‌تر الگوریتم FSDAF در مقایسه با ESTARFM باشد (Oldoni et al., 2021).



کلاکلاای کاربری

شکل ۷. ارزیابی نتایج ریزمقیاس‌نمایی با استفاده از مدل ESTARFM در کلاس‌های کاربری متفاوت

جدول ۳. نتایج مقایسه بین الگوریتم‌های ریزمقیاس‌نمایی و حاصل ترکیب این نتایج

الگوریتم‌ها	باند‌ها	RMSE	NRMSE	R ²	Bias	STD
STARFM	آبی	۰/۰۲	۰/۰۲	۰/۹۲	۰/۰۱	۰/۰۲
	سبز	۰/۰۲	۰/۰۲	۰/۹۴	۰/۰۰	۰/۰۰
	قرمز	۰/۰۲	۰/۰۲	۰/۹۵	۰/۰۰	۰/۰۲
	مادون قرمز	۰/۰۲	۰/۰۳	۰/۹۳	۰/۰۰	۰/۰۲
ESTARFM	آبی	۰/۰۲	۰/۰۲	۰/۹۳	۰/۰۰	۰/۰۲
	سبز	۰/۰۲	۰/۰۲	۰/۹۵	۰/۰۰	۰/۰۲
	قرمز	۰/۰۲	۰/۰۲	۰/۹۶	۰/۰۰	۰/۰۲
	مادون قرمز	۰/۰۲	۰/۰۲	۰/۹۶	۰/۰۰	۰/۰۲
FSDAF	آبی	۰/۰۲	۰/۰۲	۰/۹۳	۰/۰۰	۰/۰۲
	سبز	۰/۰۲	۰/۰۲	۰/۹۴	۰/۰۰	۰/۰۱
	قرمز	۰/۰۲	۰/۰۲	۰/۹۶	۰/۰۰	۰/۰۲
	مادون قرمز	۰/۰۲	۰/۰۳	۰/۹۵	۰/۰۰	۰/۰۲
ترکیب نتایج	آبی	۰/۰۱	۰/۰۲	۰/۹۳	۰/۰۰	۰/۰۱
	سبز	۰/۰۲	۰/۰۲	۰/۹۵	۰/۰۰	۰/۰۱
	قرمز	۰/۰۲	۰/۰۲	۰/۹۶	۰/۰۰	۰/۰۲
	مادون قرمز	۰/۰۲	۰/۰۳	۰/۹۵	۰/۰۰	۰/۰۲

جدول ۴. نتایج ترکیب نتایج الگوریتم‌های ریزمقیاس‌نمایی در شبیه‌سازی تصویر سنتینل-۲

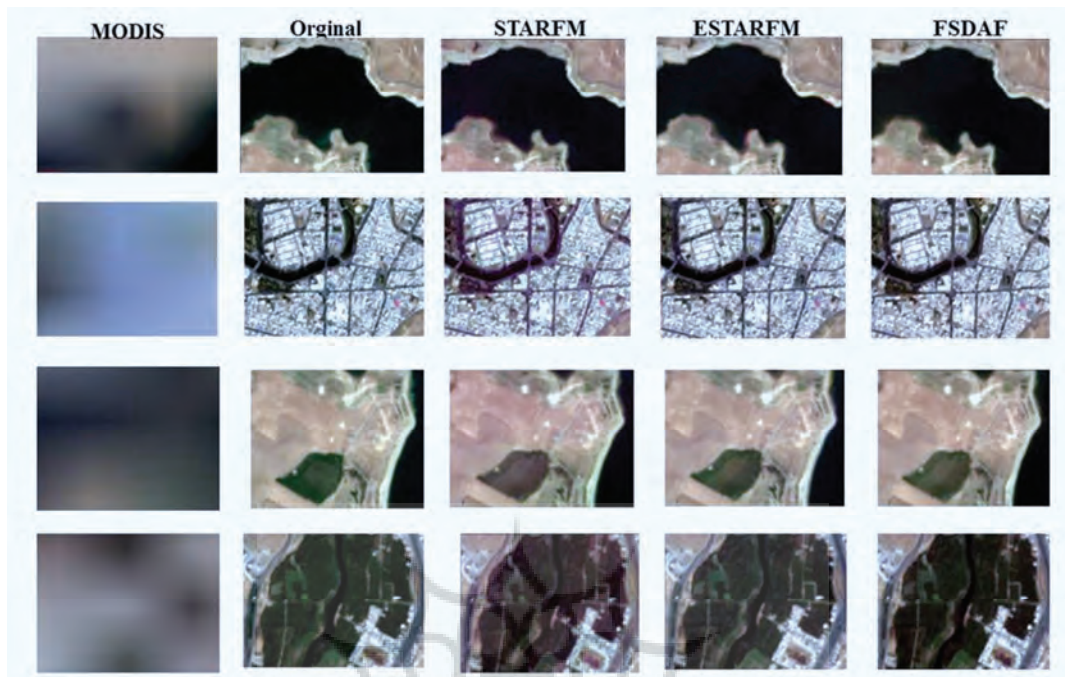
کاربری	باندها	RMSE	NRMSE	R ²	Bias	STD
شهری	آبی	۰/۰۳	۰/۰۳	۰/۹۰	۰/۰۰	۰/۰۳
	سبز	۰/۰۲	۰/۰۳	۰/۸۸	۰/۰۰	۰/۰۲
	قرمز	۰/۰۳	۰/۰۳	۰/۹۰	۰/۰۰	۰/۰۳
	مادون قرمز	۰/۰۳	۰/۰۳	۰/۹۰	۰/۰۰	۰/۰۳
کشاورزی	آبی	۰/۰۱	۰/۰۴	۰/۷۸	۰/۰۱	۰/۰۰
	سبز	۰/۰۱	۰/۰۵	۰/۸۲	۰/۰۱	۰/۰۱
	قرمز	۰/۰۲	۰/۰۸	۰/۶۶	۰/۰۲	۰/۰۲
	مادون قرمز	۰/۰۴	۰/۱۱	۰/۶۲	۰/۰۳	۰/۰۳
باغ	آبی	۰/۰۱	۰/۰۴	۰/۸۰	۰/۰۱	۰/۰۱
	سبز	۰/۰۱	۰/۰۴	۰/۸۵	۰/۰۱	۰/۰۱
	قرمز	۰/۰۲	۰/۰۶	۰/۸۵	۰/۰۱	۰/۰۱
	مادون قرمز	۰/۰۲	۰/۰۴۴	۰/۸۷	۰/۰۱	۰/۰۲
مرتع	آبی	۰/۰۱	۰/۰۳	۰/۸۸	۰/۰۰	۰/۰۱
	سبز	۰/۰۱	۰/۰۲	۰/۹۲	۰/۰۰	۰/۰۱
	قرمز	۰/۰۱	۰/۰۲	۰/۹۱	۰/۰۰	۰/۰۱
	مادون قرمز	۰/۰۱	۰/۰۲	۰/۹۳	۰/۰۰	۰/۰۱
آب	آبی	۰/۰۲	۰/۲۴	۰/۳۰	۰/۰۱	۰/۰۰
	سبز	۰/۰۱	۰/۲۳	۰/۵	۰/۰۱	۰/۰۰
	قرمز	۰/۰۱	۰/۲۶	۰/۳۴	۰/۰۱	۰/۰۱
	مادون قرمز	۰/۰۲	۰/۰۶	۰/۷۲	۰/۰۱	۰/۰۱

۴- نتیجه‌گیری

هدف این مطالعه شبیه‌سازی باندهای مرئی و مادون قرمز نزدیک سنجنده سنتینل-۲ بوده و این کار با استفاده از الگوریتم‌های ESTARFM، STARFM و FSDAF درمورد کلاس‌های کاربری اراضی شهری، کشاورزی، باغ، مرتع و آب انجام شده است. در این پژوهش، اراضی شهری و باغ نتیجه‌ای بهتر و پایدارتر از باقی کلاس‌های کاربری داشتند و درمورد هر سه الگوریتم، ضعیف‌ترین نتیجه به کلاس کاربری آب در همه باندها بازمی‌گردد. از سویی، کلاس مرتع و کشاورزی در قیاس با بقیه کلاس‌ها، در الگوریتم‌های

درمقابل، ESTARFM فرض می‌کند روابط بین جفت تصویر دارای قدرت تفکیک مکانی بالا و پایین، در همه تاریخ‌ها، یکسان است و در صورت نبود تغییرات و ثابت بودن این روابط، پیش‌بینی را با صحت بیشتری انجام می‌دهد (Oldoni et al., 2021). این نکته با یافته‌های تحقیق حاضر هم‌سویی دارد. در پژوهش الدونی^۱ و همکاران (۲۰۲۱)، نتایج الگوریتم FSDAF درمورد محصولات کشاورزی سويا و ذرت، بهتر از الگوریتم ESTARFM بوده است. در این مطالعه نیز، به علت تغییرات زیاد و فاصله زمانی طولانی بین تاریخ تصاویر ورودی و پیش‌بینی، الگوریتم FSDAF توانست قابلیت خود را درمورد محصولات کشاورزی سويا و ذرت، به خوبی نشان دهد.

1. Oldoni



شکل ۸. مقایسه بصری نتایج تصویر شبیه‌سازی‌شده سنتینل-۲، تصویر اصلی سنتینل-۲ و مادیس در مورد کلاس‌های کاربری گوناگون (به ترتیب، از بالا به پایین: کلاس آب، کلاس شهری، کلاس کشاورزی و کلاس باغ)

Gevaert, C.M. & García-Haro, F.J., 2015, **A Comparison of STARFM and an Unmixing-Based Algorithm for Landsat and MODIS Data Fusion**, Remote Sensing of Environment, 156, PP. 34-44.

<https://doi.org/10.1016/j.rse.2014.09.012>

He, S., Shao, H., Xian, W., Zhang, S., Zhong, J. & Qi, J., 2021, **Extraction of Abandoned Land in Hilly Areas Based on the Spatio-Temporal Fusion of Multi-Source Remote Sensing Images**, Remote Sensing, 13(19), P. 3956.

<https://doi.org/10.3390/rs13193956>

Hilker, T., Wulder, M.A., Coops, N.C., Seitz, N., White, J.C., Gao, F., ... Stenhouse, G., 2009, **Generation of Dense Time Series Synthetic Landsat Data through Data Blending with MODIS Using a Spatial and Temporal Adaptive Reflectance Fusion Model**, Remote Sensing of Environment, 113(9), PP. 1988-1999.

<https://doi.org/10.1016/j.rse.2009.05.011>

گوناگون، نتایج متفاوت و متغیری را در باندهای متفاوت داشته‌اند و نتایج اراضی کشاورزی ضعیف‌تر از کلاس باغ و مرتع در این مطالعه بود. در کل، میان الگوریتم‌های ادغام مکانی-زمانی مورد استفاده در این تحقیق، الگوریتم ESTARFM نتیجه‌ای بهتر از دیگر الگوریتم‌ها داشته و نتایج الگوریتم FSDAF، به دلیل نبود تغییرات شایان توجه در فاصله زمانی مورد مطالعه، ضعیف‌تر از باقی الگوریتم‌ها بوده است.

۵- منابع

Belgiu, M. & Stein, A., 2019, **Spatiotemporal Image Fusion in Remote Sensing**, Remote Sensing, 11(7), P. 818.

<https://doi.org/10.3390/rs11070818>

Gao, F., Masek, J., Schwaller, M. & Hall, F., 2006, **On the Blending of the Landsat and MODIS Surface Reflectance: Predicting Daily Landsat Surface Reflectance**, IEEE Transactions on Geoscience and Remote Sensing, 44(8), PP. 2207-2218.

<https://doi.org/10.1109/TGRS.2006.872081>

- Houborg, R., McCabe, M.F. & Gao, F., 2016, **A Spatio-Temporal Enhancement Method for Medium Resolution LAI (STEM-LAI)**, International Journal of Applied Earth Observation and Geoinformation, 47, PP. 15-29.
<https://doi.org/10.1016/j.jag.2015.11.013>
- Li, J., Li, Y., He, L., Chen, J. & Plaza, A., 2020, **Spatio-Temporal Fusion for Remote Sensing Data: An Overview and New Benchmark**, Science China Information Sciences, 63(4), P. 140301.
<https://doi.org/10.1007/s11432-019-2785-Y>
- Liao, L., Song, J., Wang, J., Xiao, Z. & Wang, J., 2016, **Bayesian Method for Building Frequent Landsat-Like NDVI Datasets by Integrating MODIS and Landsat NDVI**, Remote Sensing, 8(6), P. 452.
<https://doi.org/10.3390/rs8060452>
- Mancino, G., Ferrara, A., Padula, A. & Nolè, A., 2020, **Cross-Comparison between Landsat 8 (OLI) and Landsat 7 (ETM+) Derived Vegetation Indices in a Mediterranean Environment**, Remote Sensing, 12(2), P. 291.
<https://doi.org/10.3390/rs12020291>
- Mileva, N., Mecklenburg, S. & Gascon, F., 2018, **New Tool for Spatio-Temporal Image Fusion in Remote Sensing: A Case Study Approach Using Sentinel-2 and Sentinel-3 Data**, Paper Presented at the Image and Signal Processing for Remote Sensing XXIV.
<http://dx.doi.org/10.1117/12.2327091>
- Oldoni, L.V., Mercante, E., Antunes, J.F.G., Cattani, C.E.V., Silva Junior, C.A.d., Caon, I.L. & Prudente, V.H.R., 2021, **Extraction of Crop Information through the Spatiotemporal Fusion of OLI and MODIS Images**. Geocarto International, 37(25), PP. 1-25.
<https://doi.org/10.1080/10106049.2021.2000648>
- Salehi, H. & Shamsoddini, A., 2021, **MODIS and Sentinel-2 Data Fusion For 10-m Daily Evapotranspiration Mapping**, Iranian Journal of Irrigation and Drainage, 14(6), Feb.-Mar. 2021, PP. 1881-1892.
20.1001.1.20087942.2021.14.6.20.1
- Salehi, H., Shamsoddini, A. & Mirlatif, S.M., 2018, **MODIS Image Downscaling Using STARFM and SADFAT Algorithms for Daily Landsat-Like Spatial Resolution Evapotranspiration Mapping**, Iranian Journal of Remote Sensing and GIS, 10(3), PP. 123-140.
- Shamsoddini, A. & Nahvi, S., 2021, **Comparison of MODIS to Landsat-8 Data Downscaling Algorithms for Evapotranspiration Estimation**, MJSP, 25(4), PP. 141-173. URL: <http://hsmmp.modares.ac.ir/article-21-53900-fa.html>.
20.1001.1.16059689.1400.25.4.1.2
- Shen, H., Huang, L., Zhang, L., Wu, P. & Zeng, C., 2016, **Long-Term and Fine-Scale Satellite Monitoring of the Urban Heat Island Effect by the Fusion of Multi-Temporal and Multi-Sensor Remote Sensed Data: A 26-Year Case Study of the City of Wuhan in China**, Remote Sensing of Environment, 172, PP. 109-125.
<https://doi.org/10.1016/j.rse.2015.11.005>
- Tewes, A., Thonfeld, F., Schmidt, M., Oomen, R.J., Zhu, X., Dubovyk, O., ... Schellberg, J., 2015, **Using RapidEye and MODIS Data Fusion to Monitor Vegetation Dynamics in Semi-Arid Rangelands in South Africa**, Remote Sensing, 7(6), PP. 6510-6534.
<https://doi.org/10.3390/rs70606510>
- Wang, Q. & Atkinson, P.M., 2018, **Spatio-Temporal Fusion for Daily Sentinel-2 Images**, Remote Sensing of Environment, 204, PP. 31-42.
<https://doi.org/10.1016/j.rse.2017.10.046>
- Wu, M., Wu, C., Huang, W., Niu, Z., Wang, C., Li, W. & Hao, P., 2016, **An Improved High Spatial and Temporal Data Fusion Approach for Combining Landsat and MODIS Data to Generate Daily Synthetic Landsat Imagery**, Information Fusion, 31, PP. 14-25.
<https://doi.org/10.1016/j.inffus.2015.12.005>
- Zhu, X., Chen, J., Gao, F., Chen, X. & Masek, J.G., 2010, **An Enhanced Spatial and Temporal Adaptive Reflectance Fusion**

- Model for Complex Heterogeneous Regions**,
Remote Sensing of Environment, 114(11), PP.
2610-2623.
<https://doi.org/10.1016/j.rse.2010.05.032>
- Zhu, X., Helmer, E.H., Gao, F., Liu, D., Chen, J.
& Lefsky, M.A., 2016, A **flexible
Spatiotemporal Method for Fusing Satellite
Images with Different Resolutions**, Remote
Sensing of Environment, 172, PP. 165-177.
<https://doi.org/10.1016/j.rse.2015.11.016>
- Zhukov, B., Oertel, D., Lanzl, F. & Reinhackel,
G., 1999, **Unmixing-Based Multisensor
Multiresolution Image Fusion**, IEEE
Transactions on Geoscience and Remote
Sensing, 37(3), PP. 1212-1226.
<https://doi.org/10.1109/36.763276>





سجش از دور

,

GIS ایران



سنجش از دور و GIS ایران سال پانزدهم، شماره چهارم، زمستان ۱۴۰۲
Vol.15, No. 4, Winter 2023 Iranian Remote Sensing & GIS

83-100

Evaluation of Spatio-Temporal Downscaling Algorithms of MODIS Data to Sentinel- 2 Data in Different Land Cover Classes

Haghshenas N.¹ and Shamsoddini A.^{2*}

1. Ph.D. Student, Dep. of Remote Sensing and GIS, Tarbiat Modarres University, Tehran
2. Associate Prof., Dep. of Remote Sensing and GIS, Tarbiat Modarres University, Tehran

Abstract

Normally, images with a high resolution (temporal or spatial) are available, while there is a limitation in accessing images which are simultaneously high spatial and temporal resolution. While, in some applications, access to images with high spatial and temporal resolution is necessary. Therefore, this study was conducted to downscaling MODIS images to Sentinel- 2 spatial resolution by STARFM, ESTARFM and FSDAF spatio-temporal downscaling algorithms in different land cover classes including urban, garden, pasture, agricultural and water classes. The study area was selected with a variety of land covers around the city of Mahabad, Iran. First, the corresponding visible and near-infrared bands in Sentinel- 2 and MODIS were selected and necessary pre-processes such as geometric correction were done on these images. Then, Sentinel- 2 images were simulated using downscaling algorithms. The results indicated the accuracy of downscaling in the urban, garden and pasture classes compared to the agricultural and water classes. So that the ESTARFM, FSDAF and STARFM algorithms averagely showed the coefficient of determination of 88.25, 87.25 and 86.5 for the urban class, the coefficient of determination of 83.75, 83.25 and 80.5 for the garden class and the coefficient of determination of 90.75, 70.5 and 87.5 for the pasture class in all bands.

Keywords: Spatio-temporal downscaling, Land cover, MODIS, Sentinel- 2.

* Correspondence Address: Dep. of Remote Sensing and GIS, Faculty of Humanities, Tarbiat Modarres University, Tehran. Tel: 09155034522

Email: ali.shamsoddini@modares.ac.ir

<https://orcid.org/0000-0002-4559-7563>

<https://dx.doi.org/10.48308/gisj.2023.103096>



Copyright: © 2023 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).