



Research Paper

**Spatiotemporal Fusion of Landsat and MODIS Land Surface
Temperature Data Based on Ensemble Methods**

Ali Shamsoddini ^{1*}, Nahid Haghshenas²

1. Associate Professor, Department of Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran
2. PhD Candidate, Department of Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran

Received: 7/05/2026
Revised: 16/06/2026
Accepted: 26/06/2026

ABSTRACT

Land Surface Temperature (LST) is a key parameter for monitoring the Earth's surface energy balance and water cycle, playing an important role in assessing environmental changes from local to global scales. Despite advances in remote sensing and the availability of time-series data, limitations in sensor design and the trade-off between spatial and temporal resolution remain major challenges for generating accurate LST time series. To address these issues, various spatiotemporal fusion (STF) methods have been developed. In this study, four ensemble learning algorithms, namely Extreme Gradient Boosting (XGBoost), Gradient Boosting Machine (GBM), Random Forest (RF), and Deep Forest, were used as the core of a spatiotemporal fusion framework to simulate daily LST from Landsat 8 and Landsat 9 imagery. The Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model (ESTARFM) was also employed as a benchmark for comparison. The results showed that XGBoost achieved the best performance, with Root Mean Square Error (RMSE) values of 2.76 K, 1.60 K, 1.68 K, and 1.54 K for 2016, 2021, 2022, and 2023, respectively. Deep Forest showed the highest errors among the ensemble models, while GBM and Random Forest performed at an intermediate level. In addition, ESTARFM produced higher RMSE values ranging from 1.69 K to 2.91 K, indicating lower accuracy compared to the machine learning approaches. Overall, the results demonstrate that XGBoost provides the most accurate and robust performance for LST spatiotemporal fusion, outperforming both other ensemble methods and the ESTARFM model.

Keywords:

Spatiotemporal fusion, LST, ensemble Learning methods, MODIS, Landsat

*Corresponding Author: ali.shamsoddini@modares.ac.ir



Copyright@ 2026, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution- NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.

L

Extended Abstract:**Introduction:**

and surface temperature is a key parameter for monitoring surface energy balance, the water cycle, and environmental changes (Ebrahimi & Azadbakht, 2019). However, remote sensing data face an inherent trade-off between spatial and temporal resolution. MODIS provides daily LST with coarse resolution (1 km), while Landsat offers fine spatial resolution (30–100 m) but with multi-day revisit intervals. Cloud covers further limit data continuity (Guo et al., 2024). To overcome this, spatiotemporal fusion methods have been developed (Wang et al., 2023). The widely used ESTARFM method performs poorly in heterogeneous areas (Zhu et al., 2010). Recent learning-based approaches like CNNs require large training data and computational resources (Tan et al., 2019). Ensemble learning algorithms offer a promising alternative due to their ability to handle nonlinearity and heterogeneity (Galar et al., 2011). However, their application in LST fusion remains underexplored.

This study evaluates four tree-based ensemble algorithms, GBM, Random Forest, XGBoost, and Deep Forest, for daily LST simulation within an STF framework. ESTARFM serves as the reference method. The findings will advance STF accuracy for monitoring LST dynamics.

Methodology

As shown in Figure 3, LST data from MODIS and Landsat 8/9 were used to predict high-resolution LST maps. Three time points were defined: T1 (before), T2 (target), and T3 (after). Landsat images (L1, L2, L3) and MODIS images (M1, M2, M3) were resampled to 100 m. For spatiotemporal fusion algorithms, input data included Landsat at T1/T3 and MODIS at T1/T2/T3. After training, 100 m LST maps were generated for T2. Five downscaled LST outputs were produced per target date, enabling comprehensive evaluation of ensemble algorithms for spatiotemporal fusion.

Results and discussion

As shown in Table 2 and Figure 3, in all evaluated years (2016, 2021, 2022, and 2023), ensemble learning methods outperformed the physically based ESTARFM model. Among them, the Gradient Boosting Machine (GBM) consistently achieved the best performance in most metrics, recording the lowest RMSE values of 2.76, 1.60, 1.68, and 1.54 K, respectively. In contrast, Deep Forest produced the highest errors in most years. The comparison with ESTARFM indicated that this method is highly sensitive to the temporal gap between image pairs and surface heterogeneity. Although ESTARFM performed comparably to machine learning models in 2016 and 2022 (notably in 2022, with RMSE \approx 1.69 vs. 1.68 for GBM), its accuracy decreased significantly in 2021 and 2023.

The temporal gap analysis (Figure 4) showed that increasing the time interval does not lead to a strictly linear increase in error. Ensemble learning models exhibited relatively stable behavior under varying temporal conditions, whereas ESTARFM showed a clear decline in accuracy under larger temporal gaps, especially in heterogeneous environments.

Statistical tests indicated that XGBoost performance differences were significant compared to other machine learning models ($p < 0.05$), but its difference with ESTARFM was not statistically significant ($p = 0.1753$), suggesting similar performance under some conditions.

In terms of computational efficiency, XGBoost required the least memory and extremely low execution time (<0.3 s), while Random Forest had the highest computational cost. ESTARFM was fast but less accurate than the machine learning approaches.

Overall, Moran's I value ($\approx 0.78-0.92$) confirmed the presence of spatial structure in residuals across all models. However, this spatial dependency was stronger in ESTARFM, indicating more pronounced spatial patterns in its errors. Variogram results further showed that ensemble models, particularly XGBoost and GBM, reduced spatial autocorrelation in errors, producing more random-like residuals compared to ESTARFM.

Conclusion

This study compared ensemble learning methods with ESTARFM for spatiotemporal fusion of land surface temperature over four years (2016, 2021, 2022, and 2023). The results showed that ensemble models, especially XGBoost, consistently achieved higher accuracy and stability than ESTARFM.

XGBoost provided the best overall performance across all years, demonstrating strong robustness in heterogeneous and dynamic agricultural environments. In contrast, ESTARFM showed higher sensitivity to temporal gaps and surface heterogeneity, leading to reduced accuracy under complex cond

itions. Overall, ensemble learning methods proved to be a more accurate and reliable alternative to the physically based ESTARFM model for LST spatiotemporal fusion, although further validation in different regions is still needed.



ادغام زمانی-مکانی داده های دمای سطح زمین لندست و مادیس بر پایه روش های یادگیری همادی

علی شمس‌الدینی^{۱*}، ناهید حق‌شناس^۲

۱- دانشیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تربیت مدرس، تهران، ایران
۲- دانشجوی دکتری گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تربیت مدرس، تهران، ایران

تاریخ دریافت: ۱۴۰۵/۰۲/۱۷
آخرین ویرایش: ۱۴۰۵/۰۳/۲۶
تاریخ پذیرش: ۱۴۰۵/۰۴/۰۵

چکیده

دمای سطح زمین یکی از پارامترهای کلیدی در پایش تعادل انرژی و چرخه آب کره زمین است. با وجود پیشرفت‌های سنجش‌از‌دور، محدودیت ذاتی در مبادله بین قدرت تفکیک مکانی و زمانی ماهواره‌ها، تولید سری‌های زمانی پیوسته دمای سطح زمین را با چالش مواجه کرده است. در این راستا، روش‌های ادغام مکانی-زمانی توسعه یافته‌اند. در این پژوهش، چهار الگوریتم یادگیری همادی شامل *Random.GBM*، *XGBoost*، *Deep Forest* و *Forest* به‌عنوان هسته یک چارچوب ادغام مکانی-زمانی برای تولید سری‌های زمانی روزانه دمای سطح زمین از داده‌های لندست ۸ و ۹ و مادیس به‌کار گرفته شدند.

نتایج نشان داد که *XGBoost* با کمترین خطا، عملکرد برتری نسبت به سایر روش‌های همادی و الگوریتم *ESTARFM* دارد. مقدار ریشه میانگین مربعات خطا در الگوریتم *XGBoost* برای سال‌های ۲۰۲۱، ۲۰۲۲ و ۲۰۲۳ به‌ترتیب ۲.۱۷، ۱.۶۰، ۱.۶۸ و ۱.۵۴ کلون به‌دست آمد، در حالی که *Deep Forest* بیشترین میزان خطا را داشت. الگوریتم *ESTARFM* نیز مقادیر بالاتری از خطا (تا ۲.۹۱ کلون) نشان داد که بیانگر محدودیت آن در شرایط متغیر زمانی-مکانی است.

علاوه بر صحت، *XGBoost* از نظر کارایی محاسباتی نیز برتری داشت؛ به‌طوری‌که کمترین زمان اجرا (کمتر از ۰.۳ ثانیه در مرحله پیش‌بینی) و کمترین مصرف حافظه (حدود ۲۵۰ مگابایت) را نشان داد. در مقابل، *Random Forest* و *Deep Forest* به دلیل ساختار پیچیده‌تر، هزینه محاسباتی بالاتری داشتند. در مجموع، نتایج نشان می‌دهد که الگوریتم *XGBoost* با ترکیب صحت بالا و کارایی محاسباتی مناسب، گزینه‌ای مؤثر برای تولید سری‌های زمانی دقیق دمای سطح زمین است.

ادغام مکانی زمانی، دمای سطح زمین، روش های یادگیری همادی، مادیس، لندست

واژگان کلیدی:

ali.shamsoddini@modares.ac.ir

* نویسنده مسئول



کپی‌رایت © ۲۰۲۶، انتشارات دانشگاه تربیت مدرس (TMU Press). این مقاله به‌صورت دسترسی آزاد منتشر شده است و تحت مجوز بین‌المللی Creative Commons Attribution-NonCommercial 4.0 قرار دارد. براساس این مجوز، شما می‌توانید این مطلب را در هر قالب و رسانه‌ای کپی، بازنشر و بازآفرینی کنید و یا آن را ویرایش و بازسازی نمایید، به شرط آنکه نام نویسنده را بیاورید و از آن برای مقاصد غیر تجاری استفاده کنید.

۱- مقدمه:

دمای سطح زمین^۱ یکی از پارامترهای فیزیکی بنیادین در پایش تعادل انرژی و چرخه آب سطح زمین محسوب می شود و نقشی تعیین کننده در تحلیل تغییرات محیطی در مقیاس های محلی تا جهانی ایفا می کند (Ebrahimi & Azadbakht, 2019). با گسترش داده های سنجنش ازدور، افزایش دسترسی به تصاویر ماهواره ای و پیشرفت توان پردازشی، رویکردهای پایش پویایی های سطح زمین به سمت تحلیل داده های عظیم سری زمانی سوق یافته اند (Woodcock et al., 2020). در این میان، دمای سطح زمین به عنوان شاخصی کلیدی برای مطالعه تغییرات اقلیمی، مدیریت منابع آب، پایش خشکسالی و بررسی جزایر حرارتی شهری مورد توجه گسترده قرار گرفته است (Li et al., 2021).

از منظر فیزیکی، دمای سطح زمین حاصل برهم کنش پیچیده ای از فرآیندهای تبادل انرژی شامل تابش، هدایت حرارتی و تبخیر-تعرق است که این فرآیندها در سطح زمین به صورت یکنواخت عمل نمی کنند. در نتیجه، ناهمگنی حرارتی قابل توجهی در مقیاس زیرپیکسلی شکل می گیرد که به ویژه در سطوح ناهمگن مانند اراضی کشاورزی تشدید می شود. در این مناطق، تفاوت در رطوبت خاک، وضعیت آبیاری، نوع پوشش گیاهی و شدت تبخیر-تعرق باعث ایجاد الگوهای دمایی غیرخطی و پویا می گردد. (Liou & Kar, 2014).

بنابراین با وجود توسعه چشمگیر سامانه های سنجنش ازدور، دستیابی به داده هایی با هر دو قدرت تفکیک مکانی و زمانی بالا همچنان با محدودیت روبه روست. سنجنده مادیس مستقر بر ماهواره های ترا ۲ و آکوا ۳ داده های دمای سطح زمین را با قدرت تفکیک زمانی روزانه اما با قدرت تفکیک مکانی حدود یک کیلومتر ارائه می کند. در مقابل، مجموعه ماهواره های لندست شامل Landsat 5 TM، Landsat 7 ETM+، Landsat 8 OLI/TIRS و Landsat 9 OLI-2/TIRS-2، داده های حرارتی را با قدرت تفکیک مکانی ۶۰ تا ۱۲۰ متر (بسته به سنجنده) فراهم می سازند، در حالی که قدرت تفکیک زمانی آن ها حدود ۱۶ روز است (Guo et al., 2024). علاوه بر این، پوشش ابری و مه، به ویژه در مناطق مرطوب، دستیابی به سری های زمانی پیوسته و کامل را با دشواری مضاعف مواجه می کند (Zhu et al., 2021). این مبادله اجتناب ناپذیر میان قدرت تفکیک مکانی و زمانی و ناهمگنی حرارتی در مقیاس زیرپیکسلی یکی از محدودیت های ساختاری داده های سنجنش ازدور حرارتی به شمار می رود.

به منظور کاهش اثر این محدودیت، رویکردهای ادغام مکانی زمانی^۲ توسعه یافته است که با ترکیب داده های با قدرت تفکیک مکانی بالا و داده های با قدرت تفکیک زمانی بالا، امکان بازسازی تصاویر با هر دو ویژگی را فراهم می کند. روش های ادغام مکانی زمانی عموماً در چهار گروه اصلی طبقه بندی می شوند: روش های مبتنی بر تابع وزن^۳، روش های مبتنی بر تفکیک طیفی^۴، روش های ترکیبی^۵ و روش های مبتنی بر یادگیری (Wang et al., 2023). در میان روش های

1 Land Surface Temperature

2 Terra

3 Aqua

4 Spatio-Temporal Fusion

5 Weight Function-based Methods

6 Unmixing-based Methods

7 Hybrid Methods

مبتنی بر وزن، مدل 8STARFM (Gao et al., 2006) و نسخه بهبودیافته آن ESTARFM از پرکاربردترین چارچوب‌ها محسوب می‌شوند (Zhu et al., 2010) که بر پایه وزن‌دهی مکانی-زمانی و فرض همگنی پیکسل‌ها توسعه یافته‌اند. با این حال، این روش‌ها در مناطق ناهمگن و دارای الگوهای مکانی پیچیده، با کاهش صحت مواجه می‌شوند. در سال‌های اخیر، روش‌های مبتنی بر یادگیری، به‌ویژه شبکه‌های عصبی کانولوشنی^{۱۰}، در ادغام مکانی-زمانی مورد توجه قرار گرفته‌اند (Chen et al., 2022). این رویکردها قادر به مدل‌سازی روابط غیرخطی پیچیده‌اند، اما اغلب به حجم بالایی از داده‌های آموزشی و منابع محاسباتی قابل توجه نیاز دارند و در شرایط محدودیت داده یا آلودگی ابری عملکرد پایداری نشان نمی‌دهند.

در این میان، الگوریتم‌های یادگیری همادی^{۱۱} به‌عنوان رویکردهایی قدرتمند در یادگیری ماشین شناخته می‌شوند که با ترکیب چندین یادگیرنده پایه، صحت پیش‌بینی و پایداری مدل را بهبود می‌بخشند (Zhou, 2021). این الگوریتم‌ها به‌دلیل توانایی در مدیریت ناهمگنی مکانی، نویز زمانی و ساختارهای غیرخطی پیچیده، ظرفیت بالقوه بالایی برای کاربرد در ادغام مکانی زمانی دارند (Galar et al., 2011). با این حال، بررسی نظام‌مند کارایی این مدل‌ها در ادغام مکانی-زمانی دمای سطح زمین تاکنون به‌طور گسترده گزارش نشده است و شکاف پژوهشی قابل توجهی در این زمینه وجود دارد. بر این اساس، پژوهش حاضر با هدف ارزیابی کارایی الگوریتم‌های یادگیری همادی شامل ماشین تقویت گرادیانی^{۱۲} (GBM)، جنگل تصادفی^{۱۳} (RF)، ماشین بوستینگ گرادیانی^{۱۴} (XGBoost) و جنگل عمیق^{۱۵} (Deep Forest) در چارچوب یک مدل ادغام مکانی-زمانی برای شبیه‌سازی سری‌های زمانی روزانه دمای سطح زمین طراحی شده است. به‌کارگیری الگوریتم‌های تجمعی مبتنی بر درخت به‌عنوان هسته اصلی در مدل‌های ادغام مکانی زمانی در شرایط تغییرات تدریجی و ناگهانی در زمین‌های کشاورزی و فاصله متفاوت بین تصاویر مرجع، جنبه‌ای نوآورانه در این پژوهش محسوب می‌شود. هم‌چنین به‌کارگیری الگوریتم جنگل عمیق به‌عنوان یک مدل تجمعی عمیق، امکان بررسی هم‌افزایی میان سازوکارهای یادگیری عمیق و تجمعی را در مدل‌های ادغام مکانی زمانی مبتنی بر درخت فراهم می‌کند. به‌منظور مقایسه عملکرد و تحلیل مزایای نسبی مدل‌های ادغام مکانی زمانی مبتنی بر درخت، روش کلاسیک ESTARFM به‌عنوان چارچوب مرجع مورد استفاده قرار گرفته است. نتایج این مطالعه می‌تواند به تبیین نقش یادگیری تجمعی مبتنی بر درخت در ارتقای صحت و پایداری مدل‌های ادغام مکانی زمانی کمک کرده و گامی مؤثر در توسعه روش‌های نوین ادغام مکانی-

8 Spatial and Temporal Adaptive Reflectance Fusion Model

9 Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model

10 Convolutional Neural Network

11 Ensemble Learning

12 Gradient Boosting Machine

13 Random Forest

14 Extreme Gradient Boosting

15 Deep Forest(gcForest)

زمانی برای پایش پویایی های دمای سطح زمین باشد.

در ادامه، ساختار مقاله به این صورت سازمان دهی شده است: بخش دوم به معرفی داده ها و منطقه مورد مطالعه می پردازد؛ بخش سوم روش شناسی و شاخص های ارزیابی را تشریح می کند؛ بخش چهارم نتایج را نشان می دهد و بخش پنجم بحث را ارائه می دهد؛ و در نهایت، بخش ششم به جمع بندی و نتیجه گیری اختصاص دارد.

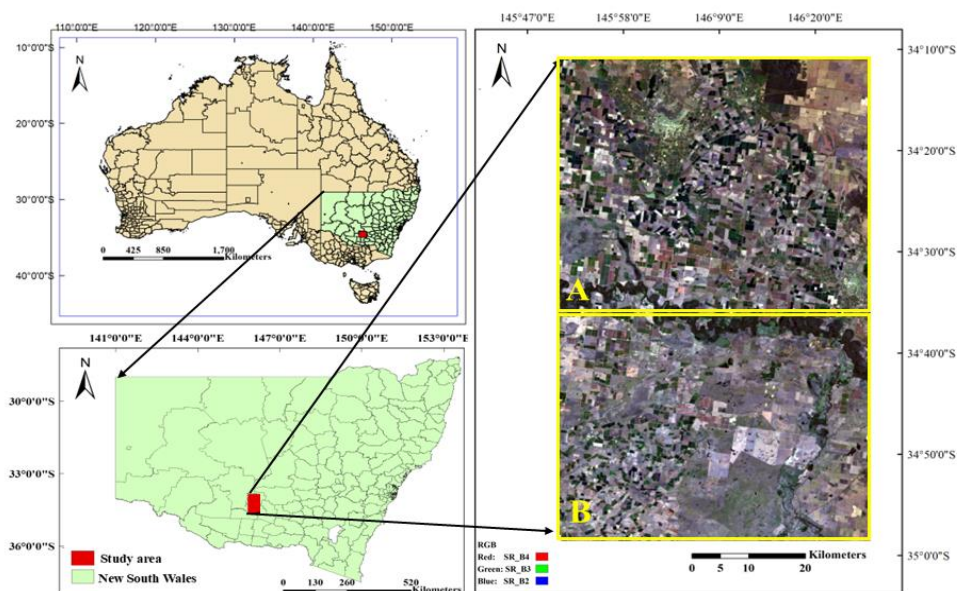
۲- منطقه مورد مطالعه و داده ها

۲-۱ منطقه مورد مطالعه

همان طور که در شکل (۱) دیده می شود، منطقه مورد مطالعه در ناحیه یانکو در جنوب شرقی استرالیا واقع شده است. این منطقه با مساحت حدود 80×40 کیلومتر مربع، عمدتاً شامل اراضی کشاورزی آبی و مراتع است. از لحاظ موقعیت جغرافیایی، منطقه در بازه عرض جغرافیایی $34^{\circ}18'5$ تا $34^{\circ}9'80$ - درجه جنوبی و طول جغرافیایی $145^{\circ}8'34$ تا $146^{\circ}7'69$ درجه شرقی قرار دارد. توپوگرافی آن هموار بوده و ارتفاع آن بین ۱۱۷ تا ۱۵۰ متر متغیر می باشد (Senanayake et al., 2021).

۲-۲ داده ها

در این پژوهش، تعداد ۱۲ جفت تصویر دمای سطح زمین از سنجنده مادیس و ماهواره های لندست ۸ و لندست ۹ گردآوری و مورد استفاده قرار گرفت. این تصاویر مربوط به فصل های تابستان و پاییز در چهار سال $2016, 2021, 2021, 2022$ و 2023 هستند. به دلیل پوشش ابری، شرایط نامساعد جوی و محدودیت های زمانی در اخذ هم زمان داده ها، امکان استخراج جفت تصاویر منطبق برای تمامی تاریخ های تصویربرداری فراهم نبود. از این رو، تنها تاریخ هایی انتخاب شدند که از نظر کیفیت داده و حداقل پوشش ابری، شرایط قابل قبول برای تحلیل ادغام مکانی زمانی را داشته باشند. جزئیات کامل تصاویر مورد استفاده، شامل تاریخ اخذ، سنجنده و سایر مشخصات فنی، در جدول (۱) ارائه شده است.



شکل ۱. منطقه مورد مطالعه در ناحیه یانکو، ایالت نیو ساوت ولز، استرالیا

Figure 1. The study area is located in the Yanko region, New South Wales, Australia

جدول ۱. مجموعه داده‌های مورد استفاده و اطلاعات اصلی آن‌ها

Table 1. The datasets used and their main information

تاریخ اخذ داده	مجموعه داده ها	الگوریتم بازیابی دمای سطح زمین
۵ فوریه ۲۰۱۶	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۸ مارس ۲۰۱۶	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۲۵ آوریل ۲۰۱۶	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۱۷ ژانویه ۲۰۲۱	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۲ فوریه ۲۰۲۱	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۶ مارس ۲۰۲۱	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۱۲ ژانویه ۲۰۲۲	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۲۰ ژانویه ۲۰۲۲	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۱۳ فوریه ۲۰۲۲	لندست ۸	تک کاناله
	MOD11A	پنجره مجزا
۱۵ ژانویه ۲۰۲۳	لندست ۹	تک کاناله
	MOD11A	پنجره مجزا
۳۱ ژانویه ۲۰۲۳	لندست ۹	تک کاناله
	MOD11A	پنجره مجزا
۲۱ آوریل ۲۰۲۳	لندست ۹	تک کاناله
	MOD11A	پنجره مجزا

۳-۲ داده‌های دمای سطح زمین لندست

ماهواره‌های لندست ۸ و لندست ۹ که به ترتیب در تاریخ‌های ۱۱ فوریه ۲۰۱۳ و ۲۷ سپتامبر ۲۰۲۱ پرتاب شدند، مجهز به سنجنده‌های مادون‌قرمز حرارتی^{۱۶} هستند و قادر به اندازه‌گیری دمای سطح زمین با قدرت تفکیک مکانی حدود ۱۰۰ متر می‌باشند. هر دو ماهواره در حدود ساعت ۱۰ صبح به وقت محلی از خط استوا عبور می‌کنند و تصاویر با بازه زمانی ۱۶ روزه ثبت می‌شوند. که در صورت ترکیب هر دو ماهواره و شرایط بدون ابر ممکن است این ۱۶ روز کاهش یابد. برای این مطالعه، داده‌های دمای سطح زمین از محصولات سطح ۲^{۱۷} استخراج شده و با استفاده از الگوریتم تک‌کاناله

16 Thermal Infrared

17 Level-2 Collection 2

¹⁸ پردازش شدند. مجموعه داده های دمای سطح زمین با بهره گیری از نسخه ۱۰۳۰۰ الگوریتم توسعه یافته توسط مؤسسه فناوری روچستر تولید شد. تمامی داده ها از طریق پلتفرم USGS Earth Explorer در دسترس قرار دارند).
<https://earthexplorer.usgs.gov>

۲-۴ داده های دمای سطح زمین مادیس

محصول MOD11A1.006 با قدرت تفکیک مکانی حدود ۱ کیلومتر، از باندهای ۳۱ و ۳۲ سنجنده مادیس و با استفاده از الگوریتم پنجره مجزا^{۱۹} استخراج شده است. الگوریتم پنجره مجزا با مقایسه تشعشع حرارتی در دو باند حرارتی نزدیک به هم، تأثیر جذب اتمسفری و ویژگی های سطحی را کاهش داده و دمای سطح زمین را تخمین می زند. سنجنده مادیس که بر روی ماهواره های ترا و آکوا نصب شده، بیش از دو دهه است که داده های دمای سطح زمین را فراهم می کند. محصول MOD11A1 برای این مطالعه انتخاب شد، زیرا زمان عبور ماهواره های مادیس از منطقه مورد مطالعه با زمان تصویربرداری ماهواره های لندست نزدیک است و این ویژگی امکان ادغام مکانی-زمانی دقیق تر را فراهم می کند. صحت تخمین های دمای سطح زمین این محصول در مناطق با پوشش یکنواخت، حدود ۱۰۳ درجه کلونین گزارش شده است. تمامی داده ها از طریق پلتفرم USGS Earth Explorer در دسترس هستند (<https://earthexplorer.usgs.gov>).

۳- روش انجام کار

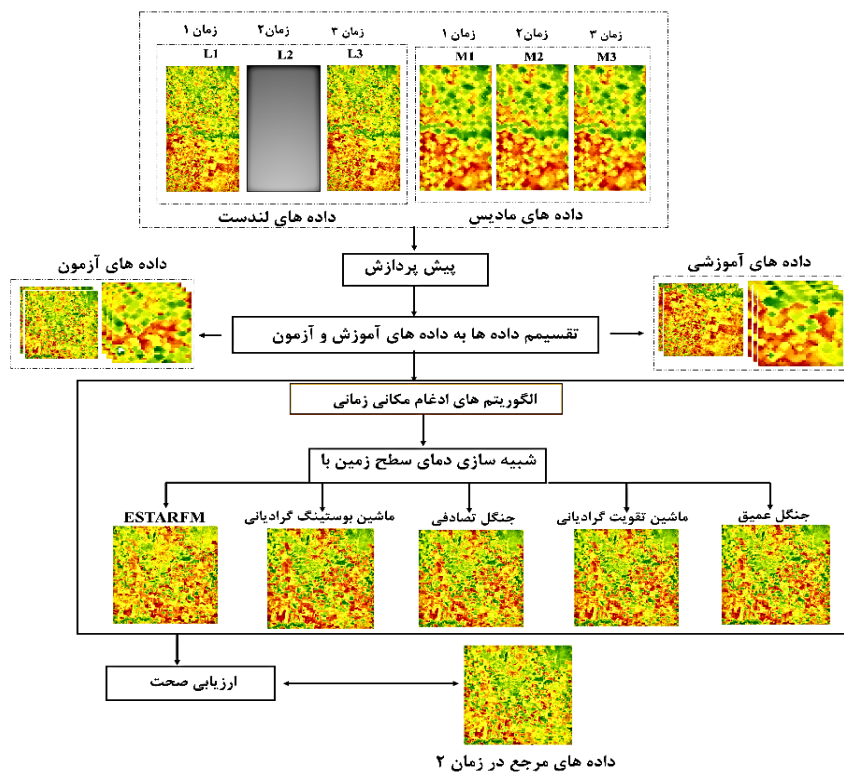
همانطور که در شکل ۳ و نمودار جریان کار مربوطه نشان داده شده است، این مطالعه از داده های دمای سطح زمین حاصل از سنجنده های مادیس، و لندست ۸ و ۹ برای پیش بینی نقشه های دمای سطح زمین با قدرت تفکیک مکانی بالا استفاده کرده است. در این چارچوب، T1 زمان قبل از پیش بینی، T3 زمان بعد از پیش بینی و T2 تاریخ هدف پیش بینی دمای سطح زمین است. داده های لندست در زمان های T1، T2 و T3 به ترتیب L1، L2 و L3 نامگذاری شده اند و داده های مادیس نیز در این سه زمان به ترتیب M1، M2 و M3 هستند.

در گام نخست، تمام تصاویر ماهواره ای تصحیح هندسی شده و سپس داده های مادیس با استفاده از روش درون یابی خطی^{۲۰} به قدرت تفکیک مکانی معادل داده های لندست (۱۰۰ متر) بازنمونه گیری^{۲۱} شدند تا سازگاری مکانی میان مجموعه داده ها تضمین شده و مقایسه و مدل سازی دقیق چندسنجنده ای میسر گردد.

در گام دوم، داده ها به صورت سالانه سازماندهی شدند. برای هر سال، سه تصویر لندست با قدرت تفکیک بالا و سه تصویر با قدرت تفکیک پایین (مادیس) در نظر گرفته شد. در هر چرخه مدل سازی، دو تصویر لندست با قدرت تفکیک بالا در زمان های T1 و T3، همراه با سه تصویر با قدرت تفکیک پایین در زمان های T1، T2 و T3 به کار رفتند. در گام سوم، فرآیند ادغام مکانی زمانی دمای سطح زمین با الگوریتم های همادی و الگوریتم ESTARFM انجام شد. برای الگوریتم ESTARFM در هر اجرا، دو جفت تصویر متناظر زمانی با قدرت تفکیک بالا و پایین در T1 و T3، همراه با تصویر با قدرت تفکیک پایین

18 Single-channel
 19 Split-Window
 20 Linear Interpolation
 21 Resampling

در تاریخ هدف (T2)، به عنوان ورودی استفاده شدند. سپس خروجی‌های دمای سطح زمین تولید شده برای هر تاریخ با دمای سطح زمین مرجع لندست در T2 برای همان تاریخ مقایسه شدند. برای الگوریتم‌های یادگیری همادی داده‌ها به دو بخش آموزش و آزمون (منطقه A و B که در شکل ۱ نشان داده شده است) تقسیم شدند. و منطقه آزمون مناطق A انتخاب شد که نتایج برای الگوریتم ESTARFM به دست آمده بود تا هماهنگی بین نتایج الگوریتم‌های مختلف در ارزیابی صحت حفظ شود. بنابراین، مدل‌های یادگیری همادی برای هر تاریخ هدف با استفاده از داده‌های آموزشی آموزش دید. داده‌های آموزشی شامل تصاویر لندست با قدرت تفکیک مکانی بالا در T1 و T3 به عنوان متغیرهای ورودی و تصاویر مادیس با قدرت تفکیک مکانی پایین در T1، T2 و T3 بودند. پس از آموزش، با استفاده از مدل‌های آموزش دیده نقشه‌های دمای سطح زمین با قدرت تفکیک ۱۰۰ متر برای ۴ تاریخ هدف در زمان T2 تولید شد. بنابراین مدل‌های ادغام مکانی زمانی با بهره‌گیری از یادگیرنده‌های مختلف، تصویر لندست با قدرت تفکیک بالا را برای تاریخی پیش‌بینی می‌کند که تصویر مادیس آن موجود است، اما تصویر متناظر لندست در دسترس نمی‌باشد. در پایان، برای هر تاریخ هدف، پنج مجموعه خروجی دمای سطح زمین ریز مقیاس‌سازی شده به دست آمد که ترکیب‌های مختلف سنجنده‌ها و الگوریتم‌ها را نشان می‌داد. این چارچوب امکان ارزیابی جامع عملکرد الگوریتم‌های یادگیری همادی در شرایط مختلف با تغییرات مکانی و زمانی مختلف برای ادغام مکانی زمانی فراهم کرد.



شکل ۲. نمودار جریان پژوهش

Figure 2. Research flow chart

آمایش فضا و ژئوماتیک

۳-۱ الگوریتم های مورد استفاده**۳-۱-۱ الگوریتم ESTARFM**

مدل ESTARFM از دو جفت تصویر مرجع با قدرت تفکیک مکانی بالا و پایین استفاده می کند و فرض می کند که تغییرات پوشش زمین بین دو تاریخ تصویربرداری، از الگوی خطی پیروی می کنند. برای کمی سازی این تغییرات، یک ضریب تبدیل خطی (V) محاسبه می شود که نرخ تغییرات طیفی را نشان می دهد (Zhu et al., 2010). سپس مدل با بهره گیری از تابع وزن دهی، اختلافات طیفی زمانی و مکانی پیکسل های مشابه را ادغام می کند و پیش بینی نهایی را تولید می کند (Knauer et al., 2016). در این مطالعه، از پنجره ای به اندازه 3×3 پیکسل برای تعریف همسایگی و شناسایی پیکسل های طیفی مشابه استفاده شد.

۳-۱-۲ جنگل تصادفی

الگوریتم جنگل تصادفی نسخه بهبود یافته الگوریتم بگینگ^{۲۲} محسوب می شود که در آن، درختان تصمیم گیری برای طبقه بندی و رگرسیون به عنوان یادگیرنده های پایه به کار گرفته می شوند. این الگوریتم با انتخاب تصادفی زیرمجموعه های داده و نمونه گیری تصادفی ویژگی ها در هر گره تقسیم، تنوع مدل را افزایش داده و صحت پیش بینی را بهبود می بخشد. علاوه بر این، تقریباً ۳۰٪ از نمونه های آموزشی که در فرآیند بوت استرپینگ^{۲۳} استفاده نمی شوند، برای برآورد خطای پیش بینی خارج از کیسه^{۲۴} به کار گرفته می شوند تا ارزیابی صحت مدل بدون نیاز به داده های جداگانه آزمون انجام شود (Breiman, 2001). در این مطالعه، با استفاده از جستجوی شبکه ای^{۲۵}، ابرپارامترهای بهینه مدل به صورت زیر تعیین شدند: تعداد ۱۵۰ درخت، حداکثر عمق درخت برابر ۱۰، انتخاب ۱۰ ویژگی در هر تقسیم، حداقل ۵ نمونه برای تقسیم یک گره، و حداقل ۲ نمونه در هر برگ.

۳-۱-۳ ماشین تقویت گرادیانی

الگوریتم ماشین تقویت گرادیانی یک روش قدرتمند برای حل مسائل رگرسیون و پیش بینی است که با ترکیب تجمعی یادگیرنده های ضعیف، معمولاً درختان رگرسیونی، صحت پیش بینی را بهبود می بخشد. در هر تکرار، یک مدل جدید به منظور اصلاح خطاهای مدل قبلی اضافه می شود و با استفاده از روش گرادیان کاهش^{۲۶}، تابع زیان به حداقل می رسد.

از ویژگی های کلیدی ماشین تقویت گرادیانی می توان به موارد زیر اشاره کرد:

یادگیری تکراری از باقی مانده های خطا،

بهینه سازی مستمر مدل در طول فرآیند آموزش،

تأثیر قابل توجه پارامترهایی مانند عمق درخت، نرخ یادگیری و تعداد تکرارها بر عملکرد نهایی مدل.

توانایی ماشین تقویت گرادیانی در مدل سازی روابط پیچیده و غیرخطی، انعطاف پذیری بالا و ظرفیت تعمیم دهی قوی آن باعث شده است که این الگوریتم در کاربردهای متنوع علمی و مهندسی به طور گسترده مورد استفاده قرار گیرد

-
- 22 Bagging
 - 23 Bootstrapping
 - 24 Out-of-Bag
 - 25 Grid search
 - 26 Gradient Descent

(Konstantinov & Utkin, 2021)

در این مطالعه، از روش جستجوی شبکه‌ای برای تعیین مجموعه بهینه ابرپارامترها استفاده شد. مدل نهایی ماشین تقویت گرادیانی با ۱۵۰ درخت، حداکثر عمق درخت برابر ۵، نرخ یادگیری ۰.۱ و در نظر گرفتن ۱۰ ویژگی در هر تقسیم تنظیم شد. این تنظیمات بهترین عملکرد را در آزمایش‌های انجام شده ارائه دادند.

۳-۱-۴ ماشین بوستینگ گرادیانی

الگوریتم ماشین بوستینگ گرادیانی نسخه پیشرفته ماشین تقویت گرادیانی محسوب می‌شود که با بهره‌گیری از پردازش موازی در سطح گره‌ها^{۲۷}، سرعت یادگیری بالاتری نسبت به ماشین تقویت گرادیانی سنتی ارائه می‌دهد. علاوه بر این، این الگوریتم از تکنیک‌های نرمال‌سازی و منظم‌سازی^{۲۸} برای کنترل پیچیدگی مدل و کاهش خطر بیش‌برازش^{۲۹} استفاده می‌کند. این ویژگی، یکی از مزایای کلیدی ماشین بوستینگ گرادیانی نسبت به روش‌های کلاسیک ماشین تقویت گرادیانی به شمار می‌رود و باعث افزایش صحت و پایداری پیش‌بینی‌ها می‌شود (Chen & Guestrin, 2016). در این مطالعه، از روش جستجوی شبکه‌ای برای بهینه‌سازی ابرپارامترها استفاده شد. بهترین عملکرد با استفاده از ۱۵۰ درخت و حداکثر عمق درخت برابر ۵ به دست آمد. نسبت نمونه‌گیری برابر با ۰.۸ برای هر دو بخش سطرها و ستون‌ها^{۳۰} اعمال شد. همچنین، پارامتر منظم‌سازی^{۳۱} برابر ۳، ترم منظم‌سازی^{۳۲} برابر ۰.۱ و نرخ یادگیری برابر ۰.۱ در مدل مورد استفاده قرار گرفت.

۳-۱-۵ جنگل عمیق

الگوریتم جنگل عمیق یک روش یادگیری عمیق مبتنی بر جنگل‌های تصمیم‌گیری است که به جای شبکه‌های عصبی، از گروهی از درختان تصمیم‌گیری برای یادگیری استفاده می‌کند. این الگوریتم با ساختار آبخاری^{۳۳}، داده‌ها را به صورت لایه به لایه پردازش کرده و ویژگی‌ها را در هر سطح بهبود می‌بخشد. هر لایه شامل چندین جنگل تصمیم‌گیری است که تنوع مدل را افزایش داده و توانایی تعمیم‌پذیری مدل را بهبود می‌بخشد. یکی از ویژگی‌های کلیدی جنگل عمیق، استفاده از اسکن چنددانه‌ای^{۳۴} است که با به‌کارگیری پنجره‌های لغزان، ویژگی‌های محلی داده‌ها را استخراج کرده و به لایه‌های بعدی منتقل می‌کند. عمق مدل و تعداد لایه‌ها نقش مهمی در عملکرد نهایی دارند و معمولاً به صورت تجربی تنظیم می‌شوند (Zhou & Feng, 2019). در این مطالعه، به منظور

-
- 27 Node-level Parallel Processing
 - 28 Regularization
 - 29 Overfitting
 - 30 Subsample and colsample_bytree
 - 31 L2 (lambda)
 - 32 L1 (alpha)
 - 33 Cascade
 - 34 Multi-grained Scanning

آمایش فضا و ژئوماتیک

تعیین ساختار بهینه مدل، از روش جستجوی شبکه ای استفاده شد و تعداد لایه های شبکه آبخاری برابر با ۳ انتخاب گردید تا تعادل مناسبی بین پیچیدگی مدل و صحت پیش بینی برقرار شود. همچنین برای جلوگیری از بیش برآزش و افزایش پایداری نتایج، از اعتبارسنجی متقاطع ۵-تایی^{۳۵} استفاده شد.

۱-۶-۳ ارزیابی صحت

برای ارزیابی عملکرد شبیه سازی دمای سطح زمین، تصاویر با قدرت تفکیک مکانی بالا که در تاریخ ۳۱ ژانویه ۲۰۲۳، ۲۰ ژانویه ۲۰۲۲، ۲ فوریه ۲۰۲۱ و ۸ مارس ۲۰۱۶ از ماهواره لندست ۸ و ۹ به دست آمده بودند، استخراج شد. برای سنجش کمی صحت نتایج، چهار شاخص استاندارد به کار گرفته شد: نسبت سیگنال به نویز اوج^{۳۶} (PSNR)، ضریب همبستگی^{۳۷} (CC)، خطای ریشه میانگین مربعات^{۳۸} (RMSE) و خطای مطلق میانگین^{۳۹} (MAE). معادلات (۱) تا (۵) روش محاسبه این شاخص ها را نشان می دهند.

علاوه بر این، برای بررسی ساختار مکانی خطاها و ارزیابی وجود خودهمبستگی مکانی در باقی مانده ها^{۴۰}، از شاخص موران^{۴۱} استفاده شد. این شاخص میزان خوشه بندی یا پراکندگی مکانی مقادیر را اندازه گیری می کند؛ به طوری که مقادیر مثبت نشان دهنده خوشه بندی مکانی خطاها، مقادیر منفی بیانگر الگوی پراکنده و مقادیر نزدیک به صفر نشان دهنده تصادفی بودن توزیع خطاها هستند. استفاده از این شاخص امکان بررسی این موضوع را فراهم می کند که آیا خطاهای مدل دارای ساختار مکانی حل نشده هستند یا خیر. (Moran, 1950).

$$RMSE = \sqrt{\frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [y(i,j) - x(i,j)]^2}$$

(۱)

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}$$

(۲)

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [y(i,j) - x(i,j)]^2$$

(۳)

$$CC = \frac{\sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (x(i,j) - \mu_x)(y(i,j) - \mu_y)}{\sqrt{\sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (x(i,j) - \mu_x)^2 (y(i,j) - \mu_y)^2}}$$

(۴)

35 5-fold cross-validation

36 Correlation Coefficient

37 Root Mean Square Error (RMSE)

38 Root Mean Square Error (RMSE)

39 Mean Absolute Error

40 Residual

41 Moran's I

$$\text{PSNR} = 20 \times \log_{10} \left(\frac{\text{MAX}_y}{\sqrt{\text{MSE}}} \right) \quad (5)$$

$$I = \frac{n \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} w_{ij}(x_i - \bar{x})(x_j - \bar{x})}{W \sum_{j=0}^{n-1} (x_i - \bar{x})^2} \quad (6)$$

ضریب همبستگی در بازه [۱- تا ۱] تعریف شده است و مقادیر نزدیک به ۱ بیانگر شباهت بیشتر جزئیات بافتی تصویر پیش‌بینی شده با تصویر واقعی و عملکرد بهتر مدل هستند. مقادیر بالاتر نسبت سیگنال به نویز اوج نشان‌دهنده کیفیت بهتر پیش‌بینی است. مقادیر کمتر خطای ریشه میانگین مربعات و خطای مطلق میانگین نشان‌دهنده صحت و کیفیت بالاتر تصاویر شبیه‌سازی شده می‌باشند (Guo et al., 2024; Zhu et al., 2021) که در آن:

- $X(i, j)$ = مقدار پیکسل واقعی در موقعیت (i, j)
- $Y(i, j)$ = مقدار پیکسل پیش‌بینی شده در موقعیت (i, j)
- m, n = تعداد سطرها و ستون‌های تصویر
- MAX_y = بیشینه مقدار پیکسل در تصویر
- μ_x, μ_y = مقادیر میانگین تصاویر واقعی و پیش‌بینی شده
- x_i, x_j = مقدار خطا در موقعیت‌های i و j
- \bar{x} = میانگین کل مقادیر
- w_{ij} = وزن مکانی بین دو موقعیت i و j

۴. نتایج

همان‌گونه که در جدول ۲ و شکل ۳ مشاهده می‌شود، نتایج ادغام مکانی-زمانی دمای سطح زمین برای سال‌های ۲۰۱۶، ۲۰۲۱، ۲۰۲۲ و ۲۰۲۳ ارائه شده است. فاصله زمانی بین تصاویر پایه به ترتیب ۸۰، ۴۸، ۳۲ و ۹۶ روز بوده است. نتایج نشان داد که در تمامی سال‌های مورد بررسی، الگوریتم ماشین بوستینگ گرادینتی بهترین عملکرد را از نظر صحت داشته و کمترین مقدار ریشه میانگین مربعات خطا را ثبت کرده است. مقادیر ریشه میانگین مربعات خطا در این مدل برای سال‌های ۲۰۱۶ تا ۲۰۲۳ به ترتیب ۲.۷۶۱۲، ۱.۶۰۵۹، ۱.۶۸۱۳ و ۱.۵۴۸۷ کلون به دست آمد. در مقابل، جنگل عمیق در اغلب سال‌ها بیشترین خطا را در میان روش‌های یادگیری همادی نشان داد. مقایسه الگوریتم همادی با الگوریتم ESTARFM نشان داد که روش ESTARFM نسبت به فاصله زمانی بین تصاویر پایه و شرایط زمانی برداشت داده‌ها

آمایش فضا و ژئوماتیک

حساسیت بیشتری دارد. در سال‌های ۲۰۱۶ و ۲۰۲۲، عملکرد ESTARFM نزدیک به بهترین مدل‌های یادگیری ماشین بود؛ به طوری که ریشه میانگین مربعات خطا آن به ترتیب ۲.۷۸۳۴ و ۱.۶۹۳۹ کلوین و برای ماشین بوستینگ گرادینانی برابر با ۲.۷۶۱۲ و ۱.۶۸۱۳ کلوین ثبت شد. با این حال، در سال‌های ۲۰۲۱ و ۲۰۲۳ اختلاف عملکرد به طور محسوسی افزایش یافت. به ویژه در سال ۲۰۲۱، ریشه میانگین مربعات خطا الگوریتم ESTARFM برابر با ۲.۹۱۵۷ کلوین بود، در حالی که ماشین بوستینگ گرادینانی مقدار ۱.۶۰۵۹ کلوین را نشان داد.

نتایج اثر فاصله زمانی بین تصاویر پایه بر خطای مدل‌ها (شکل ۴) نشان داد که اگرچه افزایش فاصله زمانی می‌تواند بر صحت پیش‌بینی تأثیرگذار باشد، اما این رابطه در تمامی مدل‌ها خطی و یکنواخت نیست. در مدل‌های یادگیری همادی، روند تغییر خطا در الگوریتم‌های مختلف تا حد زیادی مشابه و پایدار بود و با افزایش فاصله زمانی، روند مشخص و ثابتی در تغییر صحت نتایج مشاهده نشد. در مقابل، الگوریتم ESTARFM نسبت به مدل‌های یادگیری همادی رفتار ناپایدارتری نشان داد. به ویژه در سال‌های ۲۰۲۱ و ۲۰۲۳، این الگوریتم خطای بیشتری نسبت به مدل‌های یادگیری همادی ثبت کرد. همچنین، در الگوریتم ESTARFM با افزایش فاصله زمانی، صحت پیش‌بینی به طور کلی کاهش یافت، اگرچه میزان این کاهش در سال‌های مختلف متفاوت بود. نتایج همچنین نشان داد که در فاصله زمانی بلندتر سال ۲۰۲۳ (۹۶ روز)، مدل‌های یادگیری همادی صحت بالاتری نسبت به سال ۲۰۱۶ با فاصله زمانی ۸۰ روز داشتند، در حالی که در الگوریتم ESTARFM افزایش فاصله زمانی از ۳۲ روز به بعد با کاهش صحت پیش‌بینی همراه بود.

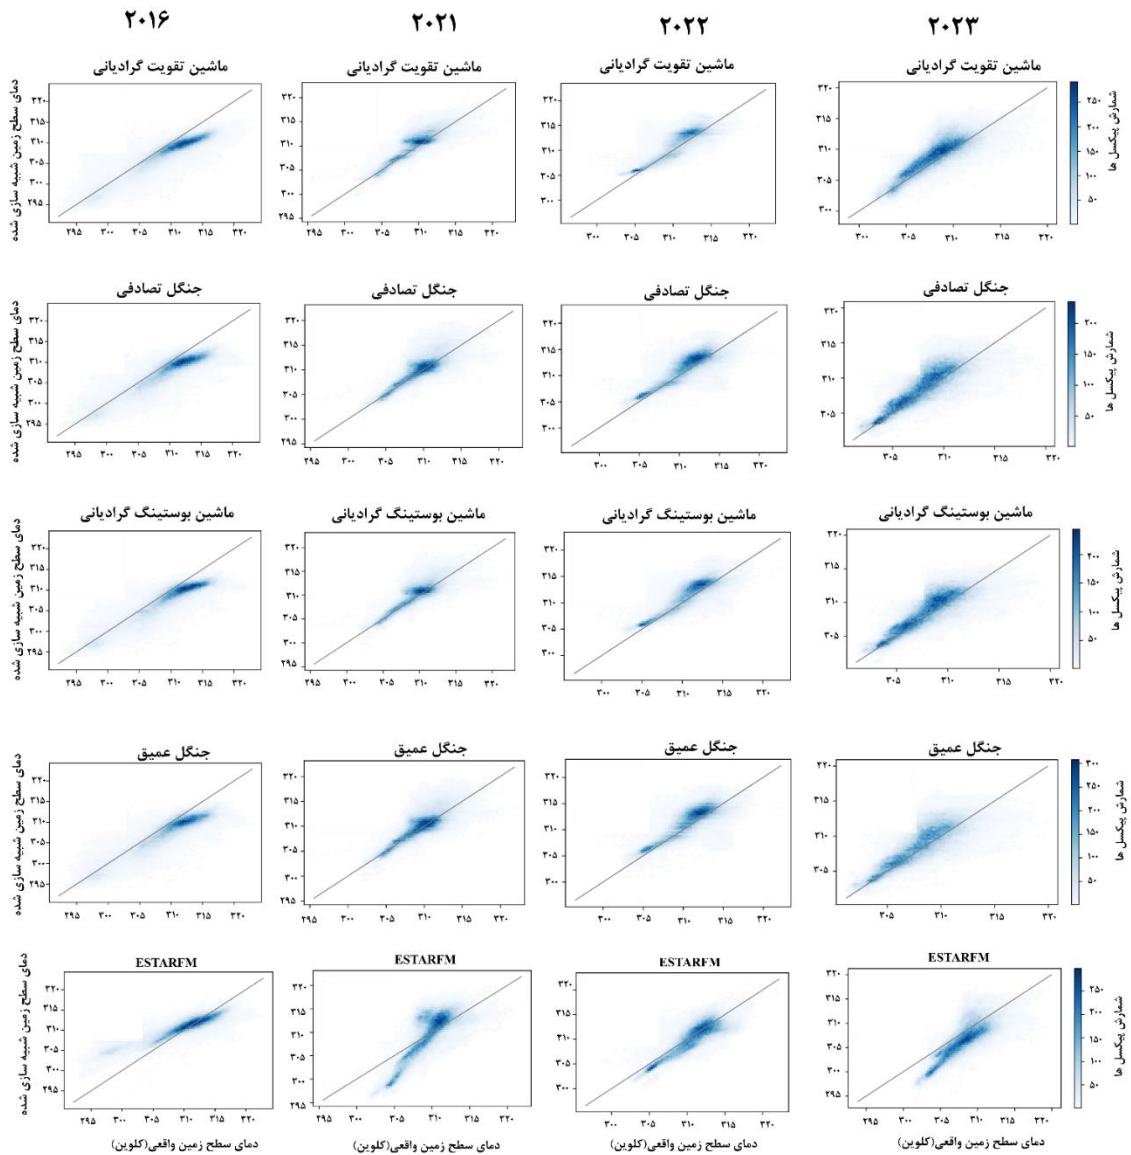
با وجود برتری عددی الگوریتم ماشین بوستینگ گرادینانی در اغلب شاخص‌ها، برای بررسی معناداری تفاوت عملکرد مدل‌ها از آزمون t زوجی در سطح اطمینان ۰.۰۵ استفاده شد. نتایج نشان داد که عملکرد ماشین بوستینگ گرادینانی نسبت به جنگل تصادفی ($p = 0.0012$)، جنگل عمیق ($p = 0.0015$) و ماشین تقویت گرادینانی ($p = 0.0341$) دارای تفاوت معنادار آماری است. در مقابل، تفاوت عملکرد ماشین بوستینگ گرادینانی با ESTARFM از نظر آماری معنادار نبود ($p = 0.1753$). این نتایج نشان می‌دهد که برتری ماشین بوستینگ گرادینانی نسبت به سایر مدل‌های یادگیری ماشین از نظر آماری قابل تأیید است، در حالی که اختلاف آن با روش فیزیکی ESTARFM در سطح معنی‌داری ۰.۰۵ قابل اثبات نیست.

جدول ۲. نتایج تولید داده های دمای سطح زمین با الگوریتم های یادگیری همادی در تاریخ های مختلف


Table 2. Results of LST data generation using Ensemble Learning algorithms on different dates

سال	روش	خطای ریشه میانگین مربعات	خطای مطلق میانگین	ضریب تعیین	نسبت سیگنال به نویز اوج	شاخص خودهمبستگی موران
۲۰۱۶	ESTARFM	۲/۷۸۳۴	۱/۹۷۰۷	۰/۹۰۲۳	۲۰/۸۳	۰/۹۱۱
	RF	۲/۸۵۱۲	۲/۳۳۴۱	۰/۹۱۰۱	۲۰/۶۲	۰/۸۲۹
	GBM	۲/۸۳۵۴	۲/۳۳۴۰	۰/۹۱۳۸	۲۰/۶۷	۰/۸۴۵
	XGBoost	۲/۷۶۱۲	۲/۲۶۰۶	۰/۹۱۵۱	۲۰/۹۰	۰/۸۵۶
	Deep Forest	۲/۸۹۲۸	۲/۳۶۶۳	۰/۹۰۵۸	۲۰/۴۹	۰/۸۱۷

سال	روش	خطای ریشه میانگین مربعات	خطای مطلق میانگین	ضریب تعیین	نسبت سیگنال به نویز اوج	شاخص خودهمبستگی موران
۲۰۲۱	ESTARFM	۲/۹۱۵۷	۲/۳۷۰۳	-/۸۱۴۸	۱۹/۱۱	-/۹۲۰
	RF	۱/۷۰۲۴	۱/۲۳۳۲	-/۸۲۷۶	۲۳/۷۸	-/۸۴۳
	GBM	۱/۶۴۷۸	۱/۲۵۷۴	-/۸۶۷۵	۲۴/۰۶	-/۸۷۸
	XGBoost	۱/۶۰۵۹	۱/۱۷۵۸	-/۸۵۲۱	۲۴/۲۹	-/۸۷۱
	Deep Forest	۱/۷۳۵۲	۱/۲۶۰۹	-/۸۲۳۷	۲۳/۶۲	-/۸۳۴
۲۰۲۲	ESTARFM	۱/۶۹۳۹	۱/۳۵۵۵	-/۸۶۰۲	۲۳/۵۹	-/۸۹۷
	RF	۱/۷۷۰۴	۱/۳۵۲۲	-/۸۳۳۹	۲۳/۲۰	-/۸۰۴
	GBM	۱/۷۴۱۹	۱/۳۹۷۹	-/۸۴۰۸	۲۳/۳۴	-/۸۶۰
	XGBoost	۱/۶۸۱۳	۱/۲۹۱۷	-/۸۵۴۴	۲۳/۶۵	-/۸۴۷
	Deep Forest	۱/۸۲۵۹	۱/۳۸۸۲	-/۸۲۶۲	۲۲/۹۴	-/۷۸۹
۲۰۲۳	ESTARFM	۲/۶۳۵۹	۲/۲۴۸۵	-/۸۳۰۹	۱۷/۰۶	-/۹۲۰
	RF	۱/۶۱۳۰	۱/۲۲۷۴	-/۸۳۹۹	۲۱/۳۲	-/۸۳۴
	GBM	۱/۶۸۸۹	۱/۳۳۳۰	-/۸۴۴۹	۲۰/۸۷	-/۸۶۹
	XGBoost	۱/۵۴۸۷	۱/۱۸۴۵	-/۸۵۱۳	۲۱/۶۸	-/۸۷۶
	Deep Forest	۱/۶۴۱۵	۱/۲۴۲۹	-/۸۳۴۴	۲۱/۱۷	-/۸۲۴



شکل ۳. نمودارهای پراکندگی تصاویر مرجع و نتایج پیش بینی دمای سطح زمین
 Figure 3. Scatter plots of reference images and predicted LST results



شکل ۴ تأثیر فاصله زمانی بین تصاویر پایه بر نتایج ادغام مکانی-زمانی

Figure 4. Effect of temporal interval between base images on Spatio-temporal fusion results

در جدول ۲، شاخص خودهمبستگی مکانی موران برای تمامی الگوریتم‌ها در سال‌های مختلف محاسبه شد. نتایج نشان داد که این شاخص در همه موارد مثبت و بالا و در بازه ۰.۷۸ تا ۰.۹۲ قرار دارد که بیانگر وجود ساختار مکانی معنادار و الگوی خوشه‌ای در خطاها است. در سال ۲۰۱۶، مقادیر شاخص موران در بازه ۰.۸۱ تا ۰.۹۱ قرار داشت؛ به طوری که جنگل عمیق کمترین مقدار (۰.۸۱۷) و ماشین بوستینگ گرادینانی بیشترین مقدار نسبی را نشان داد. در سال ۲۰۲۱، این شاخص افزایش یافته و به ۰.۸۳ تا ۰.۹۲ رسید که بیشترین مقدار مربوط به ESTARFM بود. در سال ۲۰۲۲ کاهش نسبی مشاهده شد (۰.۷۸ تا ۰.۸۹) و کمترین مقدار مربوط به جنگل عمیق (۰.۷۸۹) بود. در سال ۲۰۲۳ نیز شاخص موران در بازه ۰.۸۲ تا ۰.۹۲ قرار گرفت که ماشین بوستینگ گرادینانی و جنگل عمیق مقادیر پایین‌تری نسبت به ESTARFM نشان دادند. به طور کلی، مقادیر بالای شاخص موران نشان‌دهنده وجود وابستگی مکانی در خطاها است. با این حال، این شاخص باید در کنار معیارهای صحت مانند ریشه میانگین مربعات خطا و میانگین خطای مطلق تفسیر شود، زیرا الزاماً به معنای ضعف مدل نیست و می‌تواند ناشی از ساختار طبیعی داده‌های دمای سطح زمین باشد.

نتایج مربوط به مصرف حافظه و زمان اجرای الگوریتم‌ها (جدول ۳) نشان می‌دهد که بین روش‌های یادگیری همادی و روش ESTARFM از نظر کارایی محاسباتی تفاوت قابل توجهی وجود دارد. در میان مدل‌های همادی، ماشین بوستینگ گرادینانی کمترین مصرف حافظه (حدود ۲۵۰ مگابایت) و کوتاه‌ترین زمان پیش‌بینی (کمتر از ۰.۳ ثانیه) را در هر دو مرحله آموزش و پیش‌بینی نشان داد که بیانگر کارایی بالای آن در پردازش داده‌های مکانی-زمانی است. در مقابل، جنگل تصادفی بیشترین مصرف حافظه (حدود ۶۸۰۰ تا ۸۵۰۰ مگابایت) و زمان آموزش بالاتری نسبت به سایر مدل‌ها

آمایش فضا و ژئوماتیک

داشت، هرچند زمان پیش‌بینی آن در حد چند دهم ثانیه باقی ماند.

ماشین تقویت‌گرادیانی از نظر مصرف حافظه در سطح متوسط (حدود ۳۴۰۰ تا ۴۱۰۰ مگابایت) قرار گرفت اما با زمان پیش‌بینی بسیار سریع (حدود ۰.۱۵ تا ۰.۱۷ ثانیه) تعادل مناسبی بین صحت و کارایی محاسباتی نشان داد. جنگل عمیق نیز مصرف حافظه بالا (حدود ۴۰۰۰ تا بیش از ۵۴۰۰ مگابایت) و زمان آموزش نسبتاً طولانی‌تری داشت که بیانگر پیچیدگی ساختاری آن است. در مقابل، ESTARFM به‌عنوان روش مبتنی بر وزن، کمترین زمان پردازش (حدود ۰.۱۷ تا ۰.۲۰ ثانیه) و مصرف حافظه پایدار را نشان داد، اما این سرعت بالا با محدودیت‌هایی در صحت و انعطاف‌پذیری همراه است.

جدول ۳. مقایسه زمان اجرا و بیشترین مصرف حافظه الگوریتم‌های مختلف در فرآیند ادغام مکانی-زمانی

Table 3. Comparison of execution time and maximum memory consumption of various algorithms in Spatio-temporal data fusion

الگوریتم	تاریخ داده هدف	نوع اجرا	زمان اجرا (ثانیه)	بیشترین میزان حافظه در زمان اجرا (مگابایت)
XGBOOST	۲۰۲۳	آموزش	۱۳.۰۳	۲۵۳.۵۲
	۲۰۲۳	پیش‌بینی	۰.۲۴	۲۵۳.۴۵
	۲۰۲۲	آموزش	۱۲.۷۵	۲۶۱.۵۲
	۲۰۲۲	پیش‌بینی	۰.۲۳	۲۴۶.۶۹
	۲۰۲۱	آموزش	۱۶.۲۵	۲۵۴.۰۱
	۲۰۲۱	پیش‌بینی	۰.۲۷	۲۵۷.۳۴
	۲۰۱۶	آموزش	۱۵.۴۲	۲۵۰.۹۵
	۲۰۱۶	پیش‌بینی	۰.۱۸	۲۴۶.۳۰
RF	۲۰۲۳	آموزش	۸۷۳.۷۳	۸۴۴۶.۶۱
	۲۰۲۳	پیش‌بینی	۱۰.۳۶	۶۸۲۶.۷۷
	۲۰۲۲	آموزش	۸۸۸.۱۹	۸۴۵۲.۱۰
	۲۰۲۲	پیش‌بینی	۹.۲۷	۶۸۳۲.۵۹
	۲۰۲۱	آموزش	۹۳۶.۷۵	۸۴۹۴.۴۵
	۲۰۲۱	پیش‌بینی	۱۱.۲۳	۶۸۴۵.۸۱
	۲۰۱۶	آموزش	۹۱۲.۱۷	۸۴۵۸.۴۱
	۲۰۱۶	پیش‌بینی	۱۰.۵۲	۶۸۳۹.۲۷
GBM	۲۰۲۳	آموزش	۱۰۵۶.۱۳	۳۶۳۶.۱۲
	۲۰۲۳	پیش‌بینی	۰.۱۶	۳۶۲۴.۷۷
	۲۰۲۲	آموزش	۱۰۵۲.۲۷	۳۴۳۵.۳۴
	۲۰۲۲	پیش‌بینی	۰.۱۵	۳۴۱۵.۷۸
	۲۰۲۱	آموزش	۹۹۵۴.۶۲	۳۶۵۵.۶۷
	۲۰۱۶	پیش‌بینی	۰.۱۶	۳۷۱۴.۲۸
	۲۰۱۶	آموزش	۱۰۴۸.۱۱	۴۰۸۷.۵۶
	۲۰۱۶	پیش‌بینی	۰.۱۷	۳۹۳۷.۸۳

الگوریتم	تاریخ داده هدف	نوع اجرا	زمان اجرا (ثانیه)	بیشترین میزان حافظه در زمان اجرا (مگابایت)
DEEP FOREST	۲۰۲۳	آموزش	۳۳۵.۷۸	۵۴۱۰.۵۷
	۲۰۲۳	پیش بینی	۱.۴۴	۴۰۶۶.۴۱
	۲۰۲۲	آموزش	۳۳۵.۱۵	۴۰۶۷.۲۱
	۲۰۲۲	پیش بینی	۱.۳۱	۴۱۲۸.۱۰
	۲۰۲۱	آموزش	۳۳۸	۵۴۱۰.۴۲
	۲۰۱۶	پیش بینی	۱.۷۵	۵۴۱۵.۸۰
	۲۰۱۶	آموزش	۳۶۷.۰۲	۵۴۰۶.۷۴
	۲۰۱۶	پیش بینی	۱.۶۳	۵۴۱۵.۵۸
ESTARFM	۲۰۲۳	بازسازی	۰.۱۹	۴۱۳۸.۰۱
	۲۰۲۲	بازسازی	۰.۱۷	۴۱۳۵.۸۸
	۲۰۲۱	بازسازی	۰.۲۰	۴۱۴۰.۸۶
	۲۰۱۶	بازسازی	۰.۲۰	۴۱۴۳.۴۹

به‌طور کلی، ماشین بوستینگ گرادایانی از نظر تعادل بین صحت، سرعت و مصرف حافظه کارآمدترین روش بود، در حالی که جنگل تصادفی و جنگل عمیق هزینه محاسباتی بالاتری داشتند. ماشین تقویت گرادایانی نیز عملکردی میانی و متعادل از نظر کارایی و صحت ارائه داد.

نتایج آماری خطا شامل سوگیری^{۴۲}، انحراف معیار^{۴۳}، چولگی^{۴۴}، کشیدگی^{۴۵} و درصد خطاهای مطلق در بازه‌های مختلف در جدول ۴ نشان داده شده است و شکل ۶ توزیع هیستوگرام خطاهای باقیمانده را در چهار تاریخ مورد بررسی نشان می‌دهد.

به‌طور کلی، مقادیر سوگیری در اغلب مدل‌های یادگیری همادی نزدیک به صفر بوده که نشان‌دهنده نبود سوگیری سیستماتیک قابل توجه در پیش‌بینی‌ها است، در حالی که ESTARFM نوسانات بیشتری در مقدار سوگیری در سال‌های مختلف نشان داد. در سال ۲۰۱۶، مدل‌ها دارای انحراف معیار بالاتر و سوگیری عمدتاً منفی بودند که بیانگر پراکندگی بیشتر خطاها و عملکرد ضعیف‌تر در این سال است. در مقابل، از سال ۲۰۲۱ تا ۲۰۲۳ کاهش قابل توجهی در انحراف معیار مشاهده شد که نشان‌دهنده بهبود پایداری مدل‌های یادگیری ماشین است؛ به‌ویژه ماشین بوستینگ گرادایانی و ماشین

42 Bias

43 Standard Deviation (STD)

44 Skewness

45 Kurtosis

تقویت گرادایانی عملکرد باثبات تری نسبت به سایر روش ها داشتند. از نظر توزیع خطا، چولگی و کشیدگی نشان دادند که توزیع خطاها در برخی سال ها از نرمال فاصله دارد، به ویژه در سال ۲۰۱۶ که جنگل عمیق و جنگل تصادفی کشیدگی بالاتری را نشان دادند. با این حال، در سال های ۲۰۲۱ تا ۲۰۲۳ کاهش نسبی در چولگی و کشیدگی مشاهده شد که بیانگر کاهش نقاط پرت و بهبود توزیع خطا در مدل های یادگیری ماشین است.

از نظر درصد خطاهای مطلق، ماشین بوستینگ گرادایانی و ماشین تقویت گرادایانی در اغلب سال ها سهم بیشتری از پیکسل ها را در محدوده خطای پایین (درصد $|خطا| \geq 1$ و درصد $|خطا| \geq 2$) پوشش دادند. به عنوان نمونه، در سال ۲۰۲۳ بیش از ۵۲.۶۹٪ از خطاهای ماشین بوستینگ گرادایانی در محدوده ± 1 و بیش از ۹۳.۷۶٪ در محدوده ± 3 قرار داشتند، در حالی که ESTARFM در تمامی سال ها کمترین درصد خطاهای کوچک را نشان داد.

در مجموع، ترکیب شاخص های آماری نشان می دهد که مدل های یادگیری ماشین نه تنها از نظر کاهش سوگیری و انحراف معیار عملکرد بهتری دارند، بلکه توزیع خطاهای آن ها نیز متعادل تر و به نرمال نزدیک تر است. این نتایج در کنار شاخص های مکانی مانند موران نشان می دهد که این مدل ها توانسته اند ساختار خطا را بهتر کنترل کرده و پیش بینی های پایدارتر و قابل اعتمادتر تولید کنند.

درواقع در میان روش های بررسی شده، ماشین بوستینگ گرادایانی و ماشین تقویت گرادایانی بهترین عملکرد کلی را از نظر صحت، پایداری و درصد خطاهای کوچک داشته اند، در حالی که جنگل تصادفی عملکرد متوسط و جنگل عمیق ضعیف ترین نتایج را ارائه داده است.

جدول ۴. مقایسه شاخص های آماری خطا (سوگیری، انحراف معیار، چولگی، کشیدگی و درصد خطا) در الگوریتم های مختلف ادغام مکانی-زمانی

Table 4. Comparison of statistical error metrics (Bias, STD, Skewness, Kurtosis, and error percentages) across different spatiotemporal fusion algorithms

سال	روش	سوگیری	انحراف معیار	چولگی	کشیدگی	درصد $ خطا \geq 1$	درصد $ خطا \geq 2$	درصد $ خطا \geq 3$
۲۰۱۶	Deep Fores	-۲/۰۲۵	۲/۰۶۵	۰/۰۷۶	۲/۰۱۳	۲۳/۲۳۹	۴۷/۵۳۴	۶۸/۷۷۳
	ESTARFM	۰/۷۹۹	۲/۹۳۱	۱/۰۲۳	۲/۰۵۵	۳۴/۱۶۹	۶۱/۹۸۹	۷۸/۳۹۵
	GBM	-۲/۰۰۶	۲/۰۰۲	۰/۶۶۳	۴/۹۱۷	۲۳/۵۴۱	۴۷/۶۰۸	۶۹/۵۲۲
	RF	-۲/۰۰۷	۲/۰۲۴	۰/۰۴۷	۲/۰۱۵	۲۳/۴۸۷	۴۸/۱۷۶	۶۹/۴۱۹
	XGBOOST	-۱/۹۲۶	۱/۹۷۸	۰/۱۳۸	۲/۰۸۸	۲۴/۳۹۶	۴۹/۶۲۸	۷۱/۲۲۹
۲۰۲۱	Deep Fores	۰/۴۳۱	۱/۶۸۰	۰/۵۵۳	۱/۵۶۶	۵۴/۳۴۸	۷۹/۵۳۵	۹۱/۰۸۸
	ESTARFM	-۰/۰۸۹	۲/۹۹۷	-۰/۰۵۱	-۰/۵۳۲	۲۵/۳۷۸	۴۸/۵۱۹	۶۵/۹۳۲
	GBM	۰/۶۳۷	۱/۴۰۲	۰/۳۴۰	۰/۹۰۶	۵۶/۱۴۷	۸۱/۴۹۸	۹۳/۶۴۶
	RF	۰/۴۳۷	۱/۶۴۵	۰/۵۷۵	۱/۶۹۳	۵۵/۳۸۷	۸۰/۴۴۹	۹۱/۵۳۳
	XGBOOST	۰/۵۴۵	۱/۵۱۰	۰/۵۰۵	۱/۴۴۸	۵۶/۶۳۷	۸۱/۳۰۶	۹۲/۵۲۵
۲۰۲۲	Deep Fores	۰/۶۶۲	۱/۷۰۱	-۰/۴۲۸	۳/۱۰۰	۴۶/۱۹۸	۷۶/۲۵۵	۹۰/۸۴۸
	ESTARFM	-۰/۵۸۲	۱/۵۹۰	۰/۳۸۸	۱/۳۰۲	۴۳/۱۲۸	۷۷/۶۵۸	۹۲/۸۷۵
	GBM	۰/۵۶۴	۱/۵۱۸	۰/۱۹۳	۱/۴۶۶	۴۸/۲۹۴	۷۹/۵۸۰	۹۳/۸۸۰
	RF	۰/۶۳۳	۱/۶۵۳	-۰/۳۳۶	۲/۷۳۱	۴۷/۱۹۲	۷۷/۳۲۷	۹۱/۵۵۷

سال	روش	سوگیری	انحراف معیار	چولگی	کشیدگی درصد خطا ≥ 1 درصد خطا ≥ 2 درصد خطا ≥ 3
	XGBOOST	۰/۶۵۳	۱/۵۴۹	-۰/۰۷۰	۲/۳۶۹
	Deep Fores	۰/۵۴۲	۱/۵۴۹	-۰/۰۹۶	۱/۴۷۶
۲۰۲۳	ESTARFM	-۱/۳۰۸	۲/۳۵۱	۰/۳۰۵	۰/۴۲۰
	GBM	۰/۸۰۵	۱/۴۹۵	-۰/۰۰۰	۱/۰۷۱
	RF	۰/۵۵۷	۱/۵۱۳	-۰/۱۳۲	۱/۵۴۶
	XGBOOST	۰/۵۳۷	۱/۴۵۲	-۰/۲۴۲	۱/۴۵۰

نتایج واریوگرام (شکل ۷) برای سال‌های ۲۰۱۶، ۲۰۲۱، ۲۰۲۲ و ۲۰۲۳ نشان داد که در تمامی مدل‌ها نیم‌واریانس با افزایش فاصله مکانی^{۴۶} افزایش یافته و سپس به ناحیه آستانه^{۴۷} نزدیک می‌شود. با توجه به قدرت تفکیک مکانی ۱۰۰ متری داده‌ها، این الگو بیانگر وجود خودهمبستگی مکانی معنادار در خطاها در مقیاس‌های کوتاه‌برد است.


در تمامی سال‌ها، الگوریتم ESTARFM مقادیر آستانه بالاتری نسبت به سایر روش‌ها نشان داد (به‌طور مثال ۷.۶۱ در ۲۰۱۶ و ۷.۶۷ در ۲۰۲۱)، که بیانگر وابستگی مکانی قوی‌تر و ناهمگنی بیشتر در خطاهای این روش است. در مقابل، مدل‌های یادگیری همادی به‌ویژه ماشین بوستینگ گرادایانی و ماشین تقویت گرادایانی مقادیر پایدار پایین‌تر و پایدارتری (حدود ۱.۸۵ تا ۳.۳۶) داشتند که نشان‌دهنده کاهش ساختار مکانی در باقی‌مانده‌ها است.

پارامتر اثر قطعه‌ای^{۴۸} در مدل‌های یادگیری ماشین به‌ویژه ماشین بوستینگ گرادایانی در اغلب سال‌ها کمتر بوده (۰.۱۹ تا ۰.۴۲)، که بیانگر کاهش خطای تصادفی و افزایش پایداری پیش‌بینی‌هاست. در مقابل، ESTARFM در برخی سال‌ها مانند ۲۰۱۶ مقدار اثر قطعه‌ای بالاتری نشان داد که به حساسیت بیشتر آن به ناهمگنی‌های محلی اشاره دارد. از نظر برد واریوگرام^{۴۹} نیز مدل‌های یادگیری ماشین به‌ویژه ماشین بوستینگ گرادایانی مقادیر بزرگ‌تر و پایدارتر (تا ۲۴ پیکسل و حدود ۲.۴ کیلومتر) نسبت به سایر روش‌ها نشان دادند که بیانگر تداوم بهتر ساختار مکانی خطاها در این مدل‌هاست.

در مجموع، اگرچه خطاهای ESTARFM همچنان دارای ساختار مکانی قوی‌تری هستند، مدل‌های یادگیری ماشین به‌ویژه ماشین بوستینگ گرادایانی توانسته‌اند بخش بیشتری از الگوهای مکانی داده را مدل‌سازی کرده و در نتیجه وابستگی مکانی باقی‌مانده‌های آن‌ها را کاهش دهند.

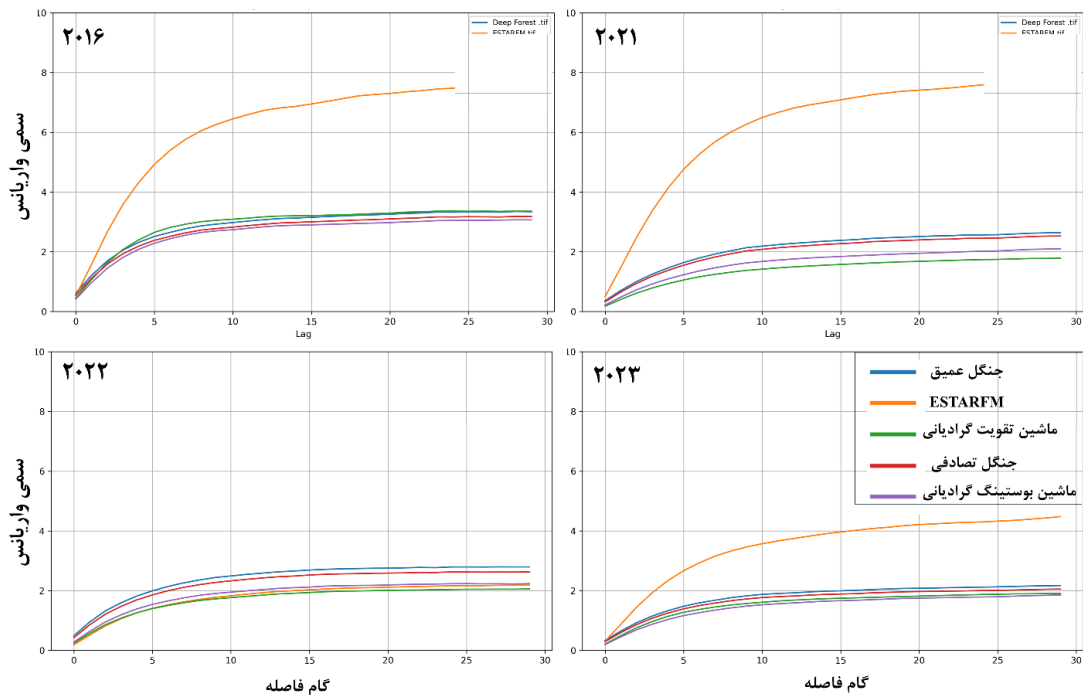
46 lag
47 sill
48 Nugget
49 range

آمایش فضا و ژئوماتیک



شکل ۶. توزیع هیستوگرام خطاهای باقیمانده برای مدل‌های ادغام مکانی زمانی مختلف

Figure 6. Histogram distribution of residual errors for different spatiotemporal fusion models.

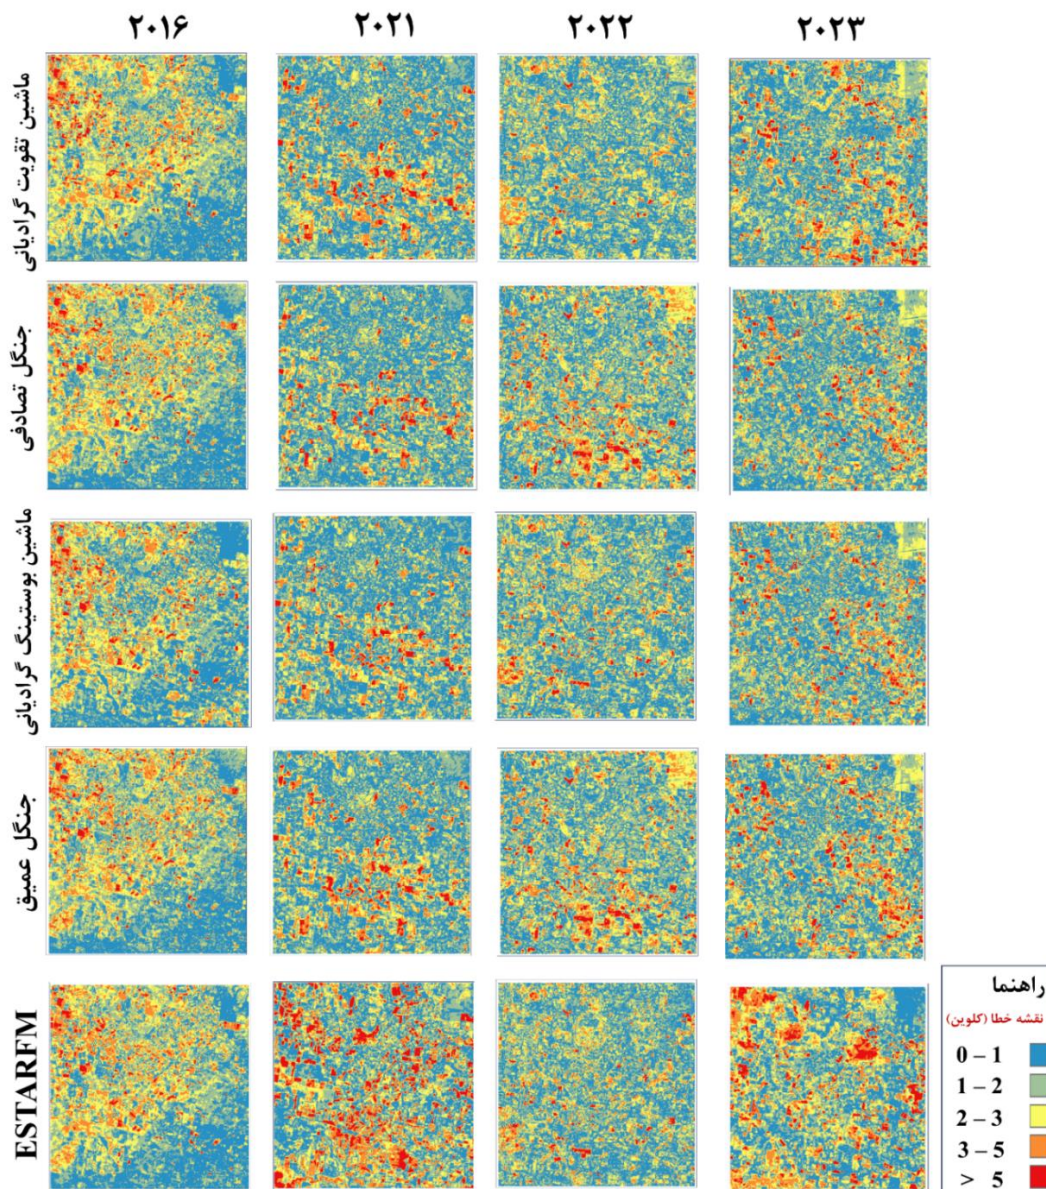


شکل ۷. نقشه‌های واریوگرام خطاهای باقیمانده در مدل‌های مختلف ادغام مکانی-زمانی

Figure 7. Variogram maps of residual errors in different spatiotemporal fusion models.

شکل ۴ توزیع مکانی مقادیر مجذور میانگین مربعات خطا حاصل از شبیه‌سازی‌های دمای سطح زمین با استفاده از تکنیک‌های مختلف ادغام مکانی-زمانی را نشان می‌دهد. در این شکل، نواحی قرمز رنگ خطاهای بالاتر از ۵ کلوین و نواحی آبی رنگ خطاهای کمتر از ۱ کلوین را نمایش می‌دهند. به دلیل ویژگی متنوع چشم‌اندازهای کشاورزی، توزیع خطا غیر یکنواخت بوده و در سراسر تصویر پراکنده است. همان‌طور که در شکل قابل مشاهده است، برخی قطعات کشاورزی دارای خطاهایی بیش از ۵ کلوین هستند که نشان‌دهنده تغییرات ناگهانی مانند برداشت محصول در بازه زمانی بین جفت تصاویر پایه مورد استفاده برای الگوریتم‌های ادغام مکانی-زمانی است. در واقع، خطاها در سال‌های ۲۰۱۶ بیشتر از سایر سال‌ها بودند، که احتمالاً به تغییرات بیشتر در مزارع طی این سال مربوط می‌شود.

آمایش فضا و ژئوماتیک



شکل ۵. نقشه میانگین مجذور مربعات خطای دمای سطح زمین تولید شده در تاریخ های مختلف

Figure 5. RMSE map of generated LST images on different dates

۵. بحث

همان طور که در جدول ۲ و نمودارهای پراکندگی شکل ۳ مشاهده می شود، تفاوت قابل توجهی میان عملکرد الگوریتم ESTARFM و مدل های یادگیری همادی وجود دارد؛ به طوری که الگوریتم ماشین بوستینگ گرادیانی در اغلب شاخص ها عملکرد بهتری نسبت به سایر روش ها نشان داده است. این برتری تنها به شاخص های آماری محدود نبوده، بلکه از نظر محاسباتی نیز مشهود است؛ به گونه ای که ماشین بوستینگ گرادیانی با زمان اجرای کمتر و مصرف حافظه

پایین‌تر، توازن مناسبی میان صحت پیش‌بینی و هزینه محاسباتی برقرار کرده است. این موضوع در مطالعات ادغام مکانی-زمانی دمای سطح زمین، که معمولاً با حجم بالای داده و محدودیت منابع پردازشی همراه هستند، اهمیت ویژه‌ای دارد. همچنین برتری این مدل در شرایط دارای تغییرات شدید مکانی-زمانی نیز تا حد زیادی حفظ شد که نشان‌دهنده انعطاف‌پذیری بیشتر روش‌های یادگیری همادی در مواجهه با ناهمگنی‌های پیچیده سطح زمین است. برای بررسی دقیق‌تر الگوی مکانی خطاها، شاخص موران و ساختار خوشه‌بندی خطاها نیز مورد ارزیابی قرار گرفت. نتایج نشان داد مقادیر بالای شاخص موران در تمامی مدل‌ها بیانگر وجود خودهمبستگی مکانی و الگوی خوشه‌ای در خطاها است. این الگو در اراضی کشاورزی رفتاری طبیعی محسوب می‌شود، زیرا این مناطق از نظر ویژگی‌های فنولوژیکی، رشد پوشش گیاهی و شرایط دمایی، تا حد زیادی به صورت قطعه‌ای و خوشه‌ای سازمان‌دهی شده‌اند. بنابراین، در صورت بروز خطا در یک قطعه (که می‌تواند ناشی از ناتوانی مدل در بازنمایی رفتار پیچیده دمایی آن قطعه باشد؛ برای مثال در شرایطی مانند آبیاری که تغییرات ناگهانی دما رخ می‌دهد و مدل قادر به پیش‌بینی دقیق آن نیست)، این خطا معمولاً به صورت مکانی در همان محدوده گسترش یافته و به شکل خوشه‌ای ظاهر می‌شود. در مجموع، اگرچه ساختار خطاها دارای وابستگی مکانی است، مدل‌های یادگیری همادی، به‌ویژه ماشین بوستینگ گرادینانی، توانسته‌اند شدت و گستره این خوشه‌بندی خطا را نسبت به الگوریتم ESTARFM کاهش دهند.

از طرفی، تحلیل نتایج واریوگرام نیز نشان داد که اگرچه در تمامی مدل‌ها نوعی خودهمبستگی مکانی در خطاها وجود دارد، شدت این ساختار مکانی در الگوریتم ESTARFM بیشتر از مدل‌های یادگیری ماشین است. مقادیر بالاتر اثر قطعه‌ای و آستانه در ESTARFM نشان می‌دهد که این روش در بازنمایی کامل ناهمگنی‌های مکانی-زمانی، به‌ویژه در محیط‌های کشاورزی پویا، با محدودیت بیشتری مواجه بوده و بخشی از ساختار مکانی خطا در باقی‌مانده‌ها به جا مانده است. در مقابل، مدل‌های یادگیری ماشین، به‌ویژه روش‌های مبتنی بر تقویت گرادینانی، با کاهش مقادیر آستانه و اثر قطعه‌ای توانسته‌اند وابستگی مکانی خطاها را بهتر کنترل کنند که بیانگر توان بیشتر آن‌ها در مدل‌سازی روابط پیچیده مکانی-زمانی است.

از نظر تئوریک، عملکرد بهتر ماشین بوستینگ گرادینانی به ساختار تقویت گرادینانی آن مرتبط است که با ترکیب ترتیبی درخت‌های تصمیم‌گیری و بهینه‌سازی خطاهای باقی‌مانده، امکان مدل‌سازی روابط غیرخطی را فراهم می‌کند (Chen & Guestrin, 2016) این ویژگی باعث بهبود تدریجی صحت و پایداری مدل می‌شود.

یافته‌های این مطالعه با پژوهش‌های پیشین نیز همخوانی دارد. برای مثال، فیلیگیراس^{۵۰} و همکاران (۲۰۲۰) نشان دادند که روش‌های یادگیری همادی در بازسازی محصولات سنجش‌ازدور، به‌ویژه در مناطق دارای تغییرات شدید پوشش گیاهی، عملکرد بهتری نسبت به مدل‌های خطی دارند (Filgueiras et al., 2020).

همچنین ساهین (۲۰۲۰) و بامری نژاد و همکاران (۱۴۰۳) بر برتری روش های مبتنی بر گرادیان بوستینگ در مدل سازی پدیده های پیچیده محیطی تأکید کرده اند. علاوه بر این، حق شناس و شمس الدینی (۲۰۲۶) نیز عملکرد بهتر ماشین بوستینگ گرادیی را در ریزمقیاس نمایی دمای سطح زمین حاصل از سنتینل ۳ و لندست گزارش کرده اند.

در بخش اثر فاصله زمانی بین تصاویر پایه و پویایی فنولوژیکی، نتایج نشان داد که فاصله زمانی بین مشاهدات یکی از عوامل کلیدی در کنترل صحت مدل های ادغام مکانی-زمانی است. با این حال، صرف افزایش فاصله زمانی به تنهایی تعیین کننده میزان خطا نیست و شدت و ماهیت تغییرات فنولوژیکی و ناهمگنی سطح زمین و رفتار ناهمگنی حرارتی در مقیاس زیر پیکسل، تأثیر رطوبت خاک و تبخیر تعرق، نیز نقش اساسی در این رابطه دارند. به عبارت دیگر، زمانی که تغییرات سطح زمین در بازه های زمانی مختلف شدیدتر و پیچیده تر باشد، عدم تطابق بین اطلاعات پایه افزایش یافته و در نتیجه بازسازی دمای سطح زمین با خطای بیشتری همراه می شود؛ موضوعی که به ویژه در الگوریتم ESTARFM به دلیل اتکای آن بر فرضیات ایستایی و روابط خطی بیشتر نمود پیدا می کند. (Xie et al., 2018; Yang et al., 2024) طبق نتایج در سال های دارای پویایی فنولوژیکی بیشتر، به خصوص ۲۰۲۱ و ۲۰۲۳، خطای الگوریتم ESTARFM به طور محسوسی بالاتر از مدل های یادگیری همادی بوده است که این امر بیانگر محدودیت این روش در مواجهه با تغییرات غیر خطی و شرایط متغیر سطح زمین است. در مقابل، مدل های یادگیری همادی روندی پایدارتر نسبت به افزایش فاصله زمانی نشان دادند و تغییرات خطای آن ها در سال های مختلف از الگوی مشخص و یکنواختی پیروی نمی کرد.

به طور خاص، در فاصله زمانی بلندتر سال ۲۰۲۳ (۹۶ روز)، مدل های یادگیری همادی همچنان عملکرد مناسبی ارائه دادند و حتی نسبت به سال ۲۰۱۶ با فاصله زمانی کوتاه تر (۸۰ روز) صحت بالاتری نشان دادند، در حالی که در الگوریتم ESTARFM از فاصله زمانی حدود ۳۲ روز به بعد کاهش صحت پیش بینی مشاهده شد. این نتایج در راستای یافته های حق شناس و شمس الدینی (۲۰۲۴) است که کاهش عملکرد ESTARFM را در مناطق کشاورزی و کلاس های کاربری پویا، به ویژه در داده های سنتینل-۲، گزارش کرده اند. در واقع حساسیت ESTARFM به فاصله زمانی و تغییرات فنولوژیکی بیشتر است، در حالی که مدل های یادگیری همادی با ترکیب چندین یادگیرنده توانسته اند اثر این ناهمگنی ها را بهتر مدیریت کرده و عملکرد پایدارتری در شرایط متغیر و مواجهه با چالش های پیچیده ادغام مکانی-زمانی ارائه دهند. (Galar et al., 2011).

از دیدگاه فیزیکی، غالب بودن اراضی کشاورزی باعث شده تغییرات فنولوژیکی ناشی از کاشت، رشد و برداشت محصولات، همراه با تغییرات رطوبت خاک و آبیاری، رفتار دمای سطح زمین را به شدت پویا و غیر خطی کند (Tao et al., 2021; Zhu et al., 2010) در چنین شرایطی، روش های کلاسیک مانند ESTARFM که مبتنی بر فرض تغییرات خطی هستند، با محدودیت مواجه می شوند. در واقع خطاهای روش ESTARFM عمدتاً در مرزهای کاربری و مناطق ناهمگن متمرکز هستند (Liu et al., 2019).

در مطالعات پیشین، از جمله شمس الدینی و نحوی (۱۴۰۰)، عملکرد الگوریتم های ادغام مکانی-زمانی عمدتاً در مناطق نسبتاً همگن با کشت تک محصولی (نیسکر) مورد بررسی قرار گرفته است. در آن مطالعه، به دلیل یکنواختی نسبی سطح زمین و ثبات شرایط زمانی تصاویر، روش های مبتنی بر وزن مانند STARFM در باندهای بازتابی نتایج قابل قبولی ارائه

دادند، در حالی که برای باندهای حرارتی، الگوریتم SADFAT عملکرد بهتری نشان داد. در مقابل، مطالعه حاضر بر یک منطقه ناهمگن با تغییرات مکانی-زمانی بالا تمرکز دارد. نتایج نشان می‌دهد که در چنین شرایطی، روش‌های مبتنی بر وزن مانند ESTARFM در مقایسه با الگوریتم‌های یادگیری همادی عملکرد ضعیف‌تری دارند.

طبق شکل ۴، پراکنش مکانی خطا (ریشه میانگین مربعات خطا) را می‌توان ناشی از تنوع محصولات کشاورزی، تفاوت در زمان برداشت و همچنین فاصله‌های زمانی بین تصاویر پایه دانست. به‌طور کلی نیز نوع کاربری زمین نقش مهمی در تغییرات دمای سطح زمین دارد؛ به‌طوری‌که اراضی بایر گرم‌تر و پوشش‌های متراکم گیاهی به دلیل اثر خنک‌کنندگی، دمای پایین‌تری نسبت به سطوح بدون پوشش دارند (جمالی و همکاران (۱۳۹۸)).

اگرچه در سال‌های اخیر، روش‌های مبتنی بر یادگیری عمیق مانند شبکه‌های عصبی کانولوشنی، شبکه‌های مولد تخصصی^۱ و مدل‌های پیشرفته‌ای نظیر U-STFM و STF-DCNN در ادغام مکانی-زمانی دمای سطح زمین توسعه یافته‌اند و در بسیاری از مطالعات، عملکرد بهتری نسبت به روش‌های کلاسیک مانند STARFM و ESTARFM از خود نشان داده‌اند. این برتری عمدتاً ناشی از توانایی این مدل‌ها در یادگیری روابط غیرخطی پیچیده و استخراج ویژگی‌های عمیق مکانی-زمانی است (Chen et al., 2022; Tan et al., 2019; Guo et al., 2024; Zhang et al., 2020).

با این حال، مرور مطالعات اخیر نشان می‌دهد که این روش‌ها با محدودیت‌های مهمی نیز مواجه هستند. نخست، اغلب مدل‌های مبتنی بر شبکه‌های عصبی کانولوشنی و شبکه‌های مولد تخصصی به حجم بالایی از داده‌های آموزشی و تعداد زیادی جفت تصویر مرجع نیاز دارند، که در کاربردهای سنجنش‌ازدور حرارتی به‌ویژه در حضور پوشش ابری و داده‌های ناقص، به‌سختی قابل تأمین است (Bouaziz et al., 2024; Sun et al., 2025). دوم، این روش‌ها از نظر محاسباتی سنگین بوده و نیازمند منابع پردازشی^۲ و زمان آموزش بالا هستند، که استفاده عملیاتی آن‌ها را محدود می‌کند (Tan et al., 2024). سوم، در شرایط ناهمگنی شدید سطح زمین و تغییرات سریع فنولوژیکی، پایداری برخی از این مدل‌ها کاهش یافته و احتمال بیش‌برازش افزایش می‌یابد (Sun et al., 2025). بنابراین در عمل، برای مسائل ادغام مکانی-زمانی، به‌ویژه در مناطقی با پوشش ابری بالا و نیاز به پردازش سریع، استفاده از الگوریتم‌هایی با توازن مناسب میان سرعت و صحت مانند ماشین بوسستینگ گرادینانی می‌تواند گزینه‌ای کارآمد و مقرون‌به‌صرفه باشد.

در مطالعه حاضر جنگل عمیق در مقایسه با سایر روش‌های یادگیری همادی، به‌ویژه ماشین بوسستینگ گرادینانی، بهبود عملکرد قابل توجهی در ادغام مکانی-زمانی دمای سطح زمین ارائه نکرد. با وجود ساختار چندلایه و ماهیت آبخاری این مدل، نتایج حاصل از آن در مجموع با سایر الگوریتم‌های همادی قابل مقایسه بود و برتری مشخصی مشاهده نشد. همچنین، تا حد آگاهی نویسنده‌گان، کاربرد جنگل عمیق در چارچوب ادغام مکانی-زمانی دمای سطح زمین تاکنون گزارش نشده

51 Generative Adversarial Network

52 GPU

است؛ بنابراین، نتایج این پژوهش را می‌توان به‌عنوان یک ارزیابی اولیه از قابلیت این الگوریتم در این حوزه در نظر گرفت. یکی از دلایل احتمالی این موضوع می‌تواند به پیچیدگی ساختار آبخاری جنگل عمیق در شرایط محدودیت داده مربوط باشد. در این پژوهش، برای هر سال تنها دو جفت تصویر پایه مورد استفاده قرار گرفت و این احتمال وجود دارد که مدل، به دلیل ساختار عمیق‌تر خود، نسبت به حجم و تنوع داده حساس‌تر بوده و بیشتر در معرض بیش‌برازش قرار گیرد. علاوه بر این، افزایش تعداد لایه‌ها و یادگیرنده‌ها، هزینه محاسباتی مدل را نیز افزایش داده، بدون آن‌که بهبود متناظری در صحت پیش‌بینی ایجاد کند. در مقابل، الگوریتم‌های مبتنی بر گرادیان بوس‌تینگ، به‌ویژه ماشین بوس‌تینگ گرادینانی، توانستند با ساختاری ساده‌تر و هزینه محاسباتی کمتر، روابط پیچیده مکانی-زمانی را با پایداری بیشتری مدل‌سازی کنند. این نتایج نشان می‌دهد که در مسائل ادغام مکانی-زمانی دمای سطح زمین، افزایش عمق و پیچیدگی مدل‌های همادی لزوماً به بهبود عملکرد منجر نمی‌شود و در بسیاری از موارد، «تجمع مؤثر یادگیرنده‌های ساده‌تر» می‌تواند کارایی بالاتری نسبت به ساختارهای عمیق‌تر داشته باشد.

محدودیت‌ها:

یکی از محدودیت‌های این مطالعه، استفاده از داده‌های محدود به دوره‌های زمانی خاص (عمدتاً تابستان و پاییز) است. به دلیل وجود ابر و محدودیت در دسترسی به تصاویر بدون ابر، امکان استفاده کامل از داده‌های زمستان و بهار فراهم نبوده است؛ موضوعی که دامنه تعمیم‌پذیری نتایج را محدود می‌کند.

با توجه به اینکه رفتار فنولوژیکی و حرارتی سطح زمین در فصل‌های مختلف تغییرات قابل توجهی دارد، انتظار می‌رود عملکرد مدل‌ها در فصل‌های کم‌فعال (زمستان) یا دوره‌های گذار (بهار) متفاوت از نتایج این مطالعه باشد. بنابراین بررسی چندفصلی می‌تواند به ارزیابی دقیق‌تر پایداری مدل‌ها کمک کند.

علاوه بر این، یکی دیگر از محدودیت‌های این پژوهش، عدم دسترسی به داده‌های دقیق و تفکیک‌شده از انواع کاربری و پوشش زمین (از جمله اراضی کشاورزی آبی و دیم، مراتع و اراضی بایر) در منطقه مطالعه می‌باشد. این محدودیت امکان انجام تحلیل خطا به تفکیک کلاس‌های مختلف پوشش زمین و ارزیابی رفتار مدل‌ها در شرایط متنوع سطح زمین را فراهم نکرده است. در نتیجه، ارزیابی عملکرد مدل‌ها با تفکیک نوع محصول یا کلاس‌های مختلف پوشش گیاهی انجام نشده است و اثر ناهمگنی‌های ناشی از نوع کاربری زمین در تحلیل خطاها به‌طور صریح مورد بررسی قرار نگرفته است.

۶. نتیجه گیری

در این مطالعه، عملکرد الگوریتم‌های یادگیری همادی در مقایسه با روش کلاسیک ESTARFM برای ادغام مکانی-زمانی دمای سطح زمین با استفاده از داده‌های مادیس، لندست ۸ و لندست ۹ در سال‌های ۲۰۱۶، ۲۰۲۱، ۲۰۲۲ و ۲۰۲۳ ارزیابی شد. نتایج نشان داد که به‌طور کلی مدل‌های یادگیری همادی نسبت به ESTARFM از صحت، پایداری و سازگاری بالاتری برخوردار بوده‌اند. در میان روش‌های بررسی‌شده، الگوریتم ماشین بوس‌تینگ گرادینانی در اغلب شاخص‌های خطا بهترین عملکرد را ارائه داد و در تمامی سال‌ها کمترین میزان خطا و بیشترین پایداری زمانی را نشان داد. این برتری بیانگر توان بالای این الگوریتم در مدل‌سازی روابط غیرخطی و پیچیده مکانی-زمانی دمای سطح زمین است.

در مقابل، الگوریتم ESTARFM در شرایط دارای تغییرات مکانی-زمانی محدود، عملکرد قابل قبولی داشت، اما در دوره‌هایی با تغییرات شدید فنولوژیکی و ناهمگنی سطح زمین، صحت آن کاهش یافت. این موضوع نشان می‌دهد که کارایی روش‌های کلاسیک به شدت به شرایط زمانی و میزان پویایی سطح زمین وابسته است. همچنین نتایج نشان داد که افزایش پیچیدگی مدل لزوماً به بهبود عملکرد منجر نمی‌شود؛ به طوری که الگوریتم جنگل عمیق در مقایسه با روش‌های ساده‌تر مبتنی بر گرادیان بوسستینگ، بهبود قابل توجهی ایجاد نکرد. این نتیجه بیانگر آن است که در مسائل ادغام مکانی-زمانی دمای سطح زمین، مدل‌های یادگیری همادی مبتنی بر ترکیب یادگیرنده‌های قوی و بهینه، نسبت به ساختارهای عمیق‌تر و پیچیده‌تر کارآمدتر هستند. در مجموع، یافته‌های این پژوهش نشان می‌دهد که الگوریتم‌های یادگیری همادی، به‌ویژه ماشین بوسستینگ گرادینانی، گزینه‌ای مناسب و عملی برای تولید سری‌های زمانی دمای سطح زمین در مناطق کشاورزی و ناهمگن هستند؛ زیرا علاوه بر صحت بالا، از نظر محاسباتی نیز کارایی مناسبی دارند. با این حال، تعمیم‌پذیری نتایج نیازمند ارزیابی در مناطق جغرافیایی و شرایط فنولوژیکی متنوع‌تر و همچنین بررسی الگوریتم‌های پیشرفته‌تر در مطالعات آینده است.

مراجع

- بامری‌نژاد، ف؛ محمدیان بهبهانی، ع؛ بایرام‌کمکی، چ؛ پاپی، ر؛ و درویشی بلورانی، ع. (۱۴۰۴). ارزیابی الگوریتم‌های یادگیری ماشین برای نقشه‌برداری از حساسیت منابع گردوغبار با تلفیق سنجش‌ازدور و پارامترهای محیطی (مطالعه موردی: حوضه خلیج قره‌بغاز). آمایش فضا و ژئوماتیک، ۲۹(۲)، ۸۵-۱۰۷.
- جمالی، ز؛ اونق، م؛ و سلمان‌ماهینی، ع. (۱۳۹۸). بررسی ارتباط دمای سطح زمین با کاربری اراضی و شاخص اختلاف گیاهی نرمال‌شده در دشت گرگان. آمایش فضا و ژئوماتیک، ۲۳(۳)، ۱۷۵-۱۹۴.
- حق‌شناس، ن؛ و شمس‌الدینی، ع. (۱۴۰۳). ارزیابی الگوریتم‌های ریزمقیاس‌نمایی مکانی-زمانی داده‌های مادیس به داده‌های سنتینل-۲ در کلاس‌های متفاوت پوشش زمین. نشریه سنجش‌از دور و GIS ایران، ۱۵(۴)، ۱۰۰-۱۸۳.
- شمس‌الدینی، ع؛ و نحوی، س. (۱۴۰۰). مقایسه الگوریتم‌های ریزمقیاس‌نمایی داده‌های مادیس به لندست-۸ به منظور برآورد تبخیر-تعرق. آمایش فضا و ژئوماتیک، ۲۵(۴)، ۱۴۱-۱۷۳.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Bamerinejad, F., Mohammadian Behbahani, A., Bayram Komaki, C., Papi, R., & Darvishi Boloorani, A. (2025). Evaluation of machine learning algorithms for dust source susceptibility mapping by integrating remote sensing and environmental parameters (Case study: Kara-Bogaz-Gol Basin). *The Journal of Spatial Planning and Geomatics*, 29(2), 85-107.
- Chen, G., Lu, H., Di, D., Li, L., Emam, M., & Jing, W. (2022). StfMLP: Spatiotemporal fusion multilayer perceptron for remote-sensing images. *IEEE Geoscience and Remote Sensing Letters*, 20, 1-5.

آمایش فضا و ژئوماتیک

- Bouaziz, S., Hafiane, A., Canals, R., & Nedjai, R. (2026). *Deep learning for spatio-temporal fusion in land surface temperature estimation: A comprehensive survey, experimental analysis, and future trends*. *Remote Sensing*, 18(2), 289. <https://doi.org/10.3390/rs18020289>
- Chen, G., Lu, H., Di, D., Li, L., Emam, M., & Jing, W. (2022). *StfMLP: Spatiotemporal fusion multilayer perceptron for remote-sensing images*. *IEEE Geoscience and Remote Sensing Letters*, 20, 1–5. <https://doi.org/10.1109/LGRS.2022.3230720>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
- Ebrahimi, H., & Azadbakht, M. (2019). Downscaling MODIS land surface temperature over a heterogeneous area: An investigation of machine learning techniques, feature selection, and impacts of mixed pixels. *Computers & Geosciences*, 124, 93–102. <https://doi.org/10.1016/j.cageo.2019.01.004>
- Filgueiras, R., Mantovani, E. C., Fernandes-Filho, E. I., Cunha, F. F., Althoff, D., & Dias, S. H. B. (2020). Fusion of MODIS and Landsat-like images for daily high spatial resolution NDVI. *Remote Sensing*, 12(8), 1297. <https://doi.org/10.3390/rs12081297>
- Galar, M., Fernández, A., Barrenechea, E., Bustince, H., & Herrera, F. (2011). A review on ensembles for the class imbalance problem: Bagging-, boosting-, and hybrid-based approaches. *IEEE Transactions on Systems, Man, and Cybernetics, Part C*, 42(4), 463–484. <https://doi.org/10.1109/TSMCC.2011.2161285>
- Gao, F., Masek, J., Schwaller, M., & Hall, F. (2006). On the blending of Landsat and MODIS surface reflectance: Predicting daily Landsat surface reflectance. *IEEE Transactions on Geoscience and Remote Sensing*, 44(8), 2207–2218. <https://doi.org/10.1109/TGRS.2006.872081>
- Guo, S., Li, M., Li, Y., Chen, J., Zhang, H. K., Sun, L., et al. (2024). The improved U-STFM: A deep learning-based nonlinear spatiotemporal fusion model for land surface temperature downscaling. *Remote Sensing*, 16(2), 322. <https://doi.org/10.3390/rs16020322>
- Haghshenas, N., & Shamsoddini, A. (2024). Evaluation of spatio-temporal downscaling algorithms of MODIS data to Sentinel-2 data in different land cover classes. *Iranian Journal of Remote Sensing and GIS*, 15(4), 100–183.
- Haghshenas, N., & Shamsoddini, A. (2026). Evaluating the capability of Sentinel-3 as an alternative to MODIS for downscaling high spatiotemporal resolution LST data using ESTARFM and XGBoost models. *International Journal of Geomatics*. <https://doi.org/10.32604/riig.2026.076139>
- Jamali, Z., Ownegh, M., & Salman Mahini, A. R. (2019). Investigation the relationship between surface temperature and land use and NDVI in Gorgan Plain. *The Journal of Spatial Planning and Geomatics*, 23(3), 175–194.
- Knauer, K., Gessner, U., Fensholt, R., & Kuenzer, C. (2016). An ESTARFM fusion framework for the generation of large-scale time series in cloud-prone and heterogeneous landscapes. *Remote Sensing*, 8(5), 425. <https://doi.org/10.3390/rs8050425>
- Konstantinov, A. V., & Utkin, L. V. (2021). Interpretable machine learning with an ensemble of gradient boosting machines. *Knowledge-Based Systems*, 222, 106993. <https://doi.org/10.1016/j.knosys.2021.106993>
- Li, K., Guan, K., Jiang, C., Wang, S., Peng, B., & Cai, Y. (2021). Evaluation of four new land surface temperature (LST) products in the US Corn Belt. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 9931–9945. <https://doi.org/10.1109/JSTARS.2021.3114613>

- Li, M., Guo, S., Chen, J., Chang, Y., Sun, L., Zhao, L., et al. (2023). Stability analysis of unmixing-based spatiotemporal fusion model. *Remote Sensing*, 15(4), 901. <https://doi.org/10.3390/rs15040901>
- Liou, Y. A., & Kar, S. K. (2014). Evapotranspiration estimation with remote sensing and various surface energy balance algorithms—A review. *Energies*, 7(5), 2821–2849. <https://doi.org/10.3390/en7052821>
- Liu, W., Zeng, Y., Li, S., Pi, X., & Huang, W. (2019). An improved spatiotemporal fusion approach based on multiple endmember spectral mixture analysis. *Sensors*, 19(11), 2443. <https://doi.org/10.3390/s19112443>
- Liu, Y., Wu, S., Wu, Z., & Zhou, S. (2024). Application of gradient boosting machine in satellite-derived bathymetry. *Journal of Sea Research*, 201, 102538. <https://doi.org/10.1016/j.seares.2024.102538>
- Moran, P. A. P. (1950). Notes on continuous stochastic phenomena. *Biometrika*, 37(1–2), 17–23. <https://doi.org/10.1093/biomet/37.1-2.17>
- Sahin, E. K. (2020). Assessing predictive capability of ensemble tree methods for landslide susceptibility mapping. *SN Applied Sciences*, 2(7), 1308.
- Sun, E., Cui, Y., Liu, P., & Yan, J. (2025). *A decade of deep learning for remote sensing spatiotemporal fusion: Advances, challenges, and opportunities*. *Information Fusion*, 103675. <https://doi.org/10.1016/j.inffus.2025.103675>
- Shamsoddini, A., & Nahvi, S. (2021). Comparison of MODIS to Landsat-8 downscaling algorithms for evapotranspiration estimation. *The Journal of Spatial Planning and Geomatics*, 25(4), 141–173.
- Senanayake, I., Yeo, I.-Y., Walker, J., & Willgoose, G. (2021). Estimating catchment scale soil moisture using remote sensing and machine learning. *Science of the Total Environment*, 776, 145924. <https://doi.org/10.1016/j.scitotenv.2021.145924>
- Tan, Z., Di, L., Zhang, M., Guo, L., & Gao, M. (2019). *An enhanced deep convolutional model for spatiotemporal image fusion*. *Remote Sensing*, 11(24), 2898. <https://doi.org/10.3390/rs11242898>
- Tan, Z., Di, L., Zhang, M., Guo, L., & Gao, M. (2019). An enhanced deep convolutional model for spatiotemporal image fusion. *Remote Sensing*, 11(24), 2898. <https://doi.org/10.3390/rs11242898>
- Tao, G., Jia, K., Wei, X., Xia, M., Wang, B., Xie, X., et al. (2021). Improving spatiotemporal fusion accuracy of fractional vegetation cover. *International Journal of Applied Earth Observation and Geoinformation*, 101, 102362. <https://doi.org/10.1016/j.jag.2021.102362>
- Wang, Q., Tang, Y., Ge, Y., Xie, H., Tong, X., & Atkinson, P. M. (2023). A comprehensive review of spatiotemporal-spectral reconstruction techniques. *Science of Remote Sensing*, 8, 100102. <https://doi.org/10.1016/j.srs.2023.100102>
- Woodcock, C. E., Loveland, T. R., Herold, M., & Bauer, M. E. (2020). Transitioning from change detection to monitoring with remote sensing. *Remote Sensing of Environment*, 238, 111558. <https://doi.org/10.1016/j.rse.2019.111558>
- Xie, D., Gao, F., Sun, L., & Anderson, M. C. (2018). Improving spatial-temporal data fusion by choosing optimal input image pairs. *Remote Sensing*, 10, 1142.

<https://doi.org/10.3390/rs10071142>

- Yang, M., Zhou, Y., Xie, Y., Shao, W., & Luo, F. (2024). Accuracy evaluation of four spatiotemporal fusion methods for different time scales. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. <https://doi.org/10.1109/JSTARS.2024.3385998>
- Zhang, H., Song, Y., Han, C., & Zhang, L. (2020). *Remote sensing image spatiotemporal fusion using a generative adversarial network*. *IEEE Transactions on Geoscience and Remote Sensing*, 59(7), 5953–5968. <https://doi.org/10.1109/TGRS.2020.3010530>
- Zhou, Z.-H. (2021). Ensemble learning. In *Machine Learning* (pp. 181–210). Springer.
- Zhou, Z.-H., & Feng, J. (2019). Deep forest. *National Science Review*, 6(1), 74–86. <https://doi.org/10.1093/nsr/nwy108>
- Zhu, X., Chen, J., Gao, F., Chen, X., & Masek, J. G. (2010). An enhanced spatial and temporal adaptive reflectance fusion model (ESTARFM). *Remote Sensing of Environment*, 114(11), 2610–2623. <https://doi.org/10.1016/j.rse.2010.05.032>
- Zhu, X., Song, X., Leng, P., Li, X., Gao, L., Guo, D., & Cai, S. (2021). A framework for generating high spatiotemporal resolution land surface temperature. *Remote Sensing*, 13(19), 3885. <https://doi.org/10.3390/rs13193885>