

Original Article



Reconstruction of ECOSTRESS Land Surface Temperature Using Deep Learning and Support Vector regression (Case Study: Bar-Arieh and Latian Watersheds)

Forough Ahmadinezhad Baghban, Vahid Moosavi^{*}, Hamidreza Moradi

Affiliation

^{*}Department of Watershed Management Engineering, Faculty of Natural Resources and Marine Sciences, Tarbiat Modares University, Tehran, Iran

ABSTRACT

Introduction: Land surface temperature (LST) is a critical variable in regional and local planning, playing a key role in climate change studies, hydrological modeling, vegetation monitoring, urban heat island effects, urban development, global warming, agricultural conditions, and influencing plant growth and yield. As an essential input parameter for most environmental models, the accuracy of LST estimation directly impacts the reliability of model outputs. Therefore, a precise and optimized study of the spatiotemporal variations of LST under different weather and climatic conditions is necessary. However, due to the limited coverage of meteorological stations, remote sensing serves as a fundamental tool for acquiring large-scale meteorological data. LST derived from satellite imagery represents the average pixel temperature over a specific land surface area, calculated based on the thermal band radiance detected by the sensor. Despite its advantages, a major challenge in LST estimation is the lack of simultaneous high temporal and spatial resolution in satellite data, which complicates accurate temperature analysis.

Materials and Methods: This study utilized deep learning and machine learning techniques to generate daily LST maps from MODIS, VIIRS, and ECOSTRESS satellite imagery, focusing on data-gap periods in two watersheds: Bar-Arieh (Neyshabur, Razavi Khorasan Province) and Latyan Dam (Tehran Province). The ECOSTRESS sensor, with a high spatial resolution of 70 meters, was selected for its ability to provide detailed LST measurements. However, due to temporal gaps in ECOSTRESS data, reconstruction was necessary. Two prominent models were employed: Support Vector Regression (SVR), a widely used machine learning model for regression tasks, and Long Short-Term Memory (LSTM), a powerful deep learning model specialized in processing sequential and time-series data. For each watershed, three pairs of dates (six dates in total) were selected, ensuring that the images were temporally aligned for model training and validation. The models were fed with corresponding satellite data from MODIS, VIIRS, and ECOSTRESS to predict missing LST values. Performance evaluation was conducted using three statistical metrics: Root Mean Square Error (RMSE), coefficient of determination (R^2), and Normalized Root Mean Square Error (NRMSE).

Results and Discussion: The comparative analysis of RMSE, R^2 , and NRMSE values demonstrated the superior performance of the LSTM model over SVR in reconstructing LST values. In the Bar-Arieh watershed, the best results were obtained for June 17, 2020, with RMSE = 1.81°C, R^2 = 0.66, and NRMSE = 11.94%. For the Latyan Dam watershed, the most accurate predictions were recorded on June 28, 2019, with RMSE = 1.61°C, R^2 = 0.83, and NRMSE = 8.65%. The LSTM model's success can be attributed to its inherent ability to extract complex features from raw data while accounting for temporal dependencies, making it highly effective for time-series forecasting. Unlike traditional machine learning models, LSTM captures long-term patterns and nonlinear relationships within the data, enabling it to handle the inherent complexities of LST dynamics. The model's robustness was further validated by its ability to reconstruct LST for periods with missing data (3–4 days ahead), accounting for the temporal intervals between successive ECOSTRESS overpasses. Despite the challenges posed by the variability of factors influencing LST—such as land cover changes, atmospheric conditions, and diurnal temperature fluctuations—the model's predictions remained within an acceptable error range. The RMSE values (ranging between 1.5°C and 3°C) indicate a reasonably accurate estimation, given the natural variability of LST (0°C to nearly 35°C in the study areas). Additionally, the NRMSE values (mostly between 8% and 17%) confirm the model's reliability, especially considering the complexity of environmental processes.

Conclusion: The study highlights the effectiveness of deep learning, particularly the LSTM model, in reconstructing high-resolution LST data from multi-sensor satellite imagery. The evaluation metrics (R^2 , RMSE, and NRMSE) consistently demonstrated LSTM's superiority over SVR, reinforcing its suitability for time-series-based environmental modeling. Given the dynamic nature of LST and the multitude of influencing factors, the model's ability to maintain low error margins (RMSE ~1.5–3°C) and high explanatory power (R^2 up to 0.83) underscores its potential for operational use in remote sensing applications. Furthermore, the normalized error values (NRMSE between 8% and 17%) suggest that the model performs reliably even under complex environmental conditions. These results are particularly significant for applications requiring high spatiotemporal resolution LST data, such as urban heat island monitoring, precision agriculture, and climate change studies. Future research could explore the integration of additional satellite datasets or hybrid modeling approaches to further enhance prediction accuracy. Overall, this study provides a robust framework for LST estimation in data-scarce scenarios, contributing to improved environmental monitoring and decision-making processes.

Keywords: Land surface temperature (LST), Remote sensing, Temperature modeling, Deep learning.

Citation:

Ahmadinezhad Baghban, F., Moosavi, V., Moradi, H., Reconstruction of ECOSTRESS Land Surface Temperature Using Deep Learning and Support Vector regression (Case Study: Bar-Arieh and Latian Watersheds), *Iran J Remote Sens GIS*. 17(3):33-54.

* Corresponding Author: v.moosavi@modares.ac.ir
DOI: <https://doi.org/10.48308/gisj.2024.233210.1180>

Received: 2023.09.27
Accepted: 2024.05.20



Copyright: © 2025 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/>.



بازسازی داده‌های دمای سطح زمین سنجنده ECOSTRESS با استفاده از یادگیری عمیق و رگرسیون بردار پشتیبان (مطالعه موردی: آبخیزهای بار-اریه و لتیان)

فروغ احمدی‌نژاد باغبان، وحید موسوی^{*}، حمیدرضا مرادی

سمت

*گروه علوم و مهندسی آبخیزداری،
دانشکده منابع طبیعی و علوم دریایی
دانشگاه تربیت مدرس، تهران، ایران

چکیده

سابقه و هدف: دمای سطح زمین از متغیرهای کلیدی در برنامه‌ریزی ناحیه‌ای و منطقه‌ای است. با توجه به اهمیت دمای سطح زمین در مطالعات تغییرات اقلیمی، مدل‌سازی هیدرولوژیکی، نظارت بر پوشش گیاهی، جزیره گرمای شهری، توسعه شهری، گرمایش جهانی، شرایط کشاورزی و همچنین تأثیر آن در رشد و عملکرد گیاهان، پارامتر ورودی به بیشتر مدل‌ها محسوب می‌شود. هرچه دقت تخمین این متغیر بیشتر باشد، خروجی مدل نیز دقت بیشتری خواهد داشت؛ بنابراین مطالعه بهینه و مناسب تغییرات مکانی و زمانی آن، در شرایط جوی و آبوهوایی متفاوت، ضروری است. با توجه به محدودیت ایستگاه‌های هواشناسی، سنجش از دور را می‌توان به‌منزله پایه و اساس بسیاری از داده‌های هواشناسی به کار برد. دمای سطح زمین در تصاویر ماهواره‌ای شامل میانگین دمای پیکسلی است که بخشی از سطح زمین را پوشش می‌دهد و براساس انرژی رسیده به سنجنده (رادیانس)، در باند حرارتی محاسبه می‌شود. از این‌رو ضعف قدرت تفکیک زمانی و مکانی بالای داده‌های ماهواره‌ای، هم‌زمان، به‌منزله چالشی مهم در بررسی و تخمین متغیر دما مطرح می‌شود.

مواد و روش‌ها: در این مطالعه، سعی شد با روش یادگیری عمیق و یادگیری ماشین، تصاویر ماهواره‌ای مادیس، VIIRS و ECOSTRESS به کار رود و نقشه‌های روزانه دمای سطح زمین سنجنده ECOSTRESS با قدرت تفکیک مکانی ۷۰ متر در زمان‌های فاقد داده، در آبخیز بار-اریه نیشابور استان خراسان رضوی و آبخیز سد لتیان در استان تهران، تولید شود. مدل‌های مورد استفاده در پژوهش شامل مدل SVR، به‌منزله مدلی محبوب در یادگیری ماشین در زمینه‌های پیش‌بینی و رگرسیون و مدل LSTM، یکی از قوی‌ترین مدل‌های یادگیری عمیق در حوزه پردازش سری‌های زمانی می‌شود. برای این منظور، سه جفت تاریخ درمورد هر حوضه (شش تاریخ) انتخاب شد. تصاویر هر جفت داده به‌طور هم‌زمان در اختیار مدل‌ها قرار گرفت. در نهایت، با استفاده از آماره‌های R^2 ، RMSE و NRMSE عملکرد هر مدل در هر تاریخ ارزیابی شد.

نتایج و بحث: بررسی ضرایب R^2 ، RMSE و NRSME مربوط به مدل LSTM و SVR، درمورد هر دو منطقه، نشان‌دهنده برتری عملکرد مدل LSTM بود. بهترین نتیجه R^2 ، RMSE و NRMSE حاصل از مدل LSTM برای آبخیز بار-اریه در تاریخ هفدهم ژوئن ۲۰۲۰، به‌ترتیب ۱/۸۱ درجه سانتی‌گراد، ۰/۶۶ و ۱۱/۹۴٪ و درمورد حوزه آبخیز لتیان، طی تاریخ ۲۸ ژوئن ۲۰۱۹، به‌ترتیب حدود ۱/۶۱ درجه سانتی‌گراد، ۰/۸۳ و ۸/۶۵٪ بود. مدل LSTM با توجه به ساختار و ویژگی‌هایش و به‌منزله مدل یادگیری عمیق قوی با استخراج ویژگی از درون داده‌های خام، با در نظر گرفتن ماهیت سری زمانی بودن داده‌ها، توانست بر پیچیدگی‌های فرایند تحت مدل‌سازی غلبه کند. باید به این نکته اشاره کنیم که با توجه به پیچیدگی فرایند و متنوع بودن عوامل مؤثر در دمای سطح زمین، نتایج دارای دقت و صحت مورد قبولی است. بازسازی و پیش‌بینی دمای سطح زمین طی سه تا چهار روز بعد انجام شده است (با توجه به فاصله زمانی بین دو تصویر متوالی ECOSTRESS). تنوع و جزئیات رویدادهایی که در این زمان می‌تواند رخ دهد گواهی دیگر بر مناسب بودن نتایج و کارایی مدل LSTM است.

استناد:

احمدی‌نژاد باغبان، ف.، موسوی، و.، مرادی، ح. بازسازی داده‌های دمای سطح زمین سنجنده ECOSTRESS با استفاده از یادگیری عمیق و رگرسیون بردار پشتیبان (مطالعه موردی: آبخیزهای بار-اریه و لتیان)، نشریه سنجش از دور و GIS ایران، سال ۱۷، شماره ۳، پاییز ۱۴۰۴: ۳۳-۵۴.

نتیجه‌گیری: بررسی نتایج و مقادیر R^2 به‌منزله معیاری استاندارد برای ارزیابی تحلیل‌های رگرسیون و نیز مقادیر RMSE و NRMSE گویای برتری مدل LSTM در بازسازی مقادیر دمای سطح زمین ECOSTRESS است. با توجه به دامنه تغییرات و مؤلفه‌های مؤثر، دمای سطح زمین در تاریخ‌های بازسازی شده، بین صفر تا گاه نزدیک به ۳۵ درجه سانتی‌گراد تغییر کرد؛ مقدار RMSE (نشان‌دهنده متوسط خطای مدل) برای مدل LSTM حدود ۱/۵ تا ۳ درجه سانتی‌گراد بود که مورد قبول و مناسب به نظر می‌رسد. مقادیر نرمال‌شده RMSE یا همان NRMSE نیز، در اغلب تاریخ‌ها، بین ۸٪ تا ۱۷٪ بود که در مدل‌سازی‌های محیطی، با توجه به پیچیدگی‌های زیاد فرایندها، مقداری مطلوب است.

واژه‌های کلیدی: دمای سطح زمین، سنجش از دور، مدل‌سازی دما، یادگیری عمیق.



۱- مقدمه

دمای سطح زمین (LST)^۱ متغیری بسیار مهم در مطالعه مدل‌های تعادل انرژی در سطح زمین و فعل‌وانفعالات بین زمین و جو در سطح منطقه‌ای و جهانی است که در کنترل فرایندهای بیولوژیک، شیمیایی و فیزیکی زمین نقش مهمی دارد (Wang et al., 2020; Li et al., 2021). دمای سطح زمین در ایستگاه‌های هواشناسی اندازه‌گیری می‌شود و نکته درخور توجه آن است که این ایستگاه‌ها، برای بسیاری از مطالعات و بررسی‌ها، توزیع مکانی مناسبی ندارند. همچنین دسترسی و پایش محیطی این متغیرها در برخی آب‌خیزها، به دلیل وضعیت خاص توپوگرافی منطقه، آسان نیست (Bakhshi & Khalookakaei, 2010). از این‌رو سنجش از دور حرارتی می‌تواند، در مطالعه دمای سطح زمین در مقیاس وسیع و زمان‌های متفاوت، راهگشا باشد (Hejazizadeh et al., 2013). مشکل اصلی استفاده از تصاویر ماهواره‌ای آن است که تأمین هم‌زمان قدرت تفکیک مکانی و زمانی بالا در آن مقدور نیست؛ بدین مفهوم که اگر از تصاویر با قدرت تفکیک مکانی متوسط، مانند لندست^۲ استفاده شود، با توجه به تغییرپذیری زمانی بالای متغیرهایی مانند دما، رطوبت خاک و تبخیر و تعرق، نبود داده‌های روزانه می‌تواند باعث ایجاد مشکلاتی در محاسبات مورد نظر شود. از سوی دیگر، در صورت استفاده از داده‌هایی با قدرت تفکیک زمانی بالا مانند مادیس، قدرت تفکیک مکانی نقش محدودکننده خواهد داشت (Kaffash & Sanaei-Nejad, 2020). به همین علت پژوهشگران امروزه، به منظور تلفیق تصاویر ماهواره‌ای و تولید محصولاتی با قدرت تفکیک زمانی و مکانی مورد نیاز، از روش‌های گوناگون ریاضی و مدل‌سازی استفاده می‌کنند. همچنین در زمینه استفاده هم‌زمان از تصاویر ماهواره‌ای و مدل‌سازی دمای سطح زمین، مطالعات گسترده‌ای صورت گرفته است و در سال‌های اخیر، پژوهشگران ایرانی نیز مطالعاتی در این حوزه انجام داده‌اند. برای نمونه، کفاش و ثنائی‌نژاد^۳ (۲۰۲۰) در مطالعه‌ای، به منظور تلفیق تصاویر مادیس و

لندست-۸ از دمای سطح زمین، مدل تلفیقی مکانی-زمانی (STI-FM) را به کار بردند. در این پژوهش، ابتدا ضرایب رابطه خطی بین دو تصویر سنجنده مادیس در زمان‌های ۱ و ۲ مشخص شد؛ سپس ضرایب به تصویر سنجنده لندست در زمان ۱ اعمال شد تا تصویر در زمان ۲ به دست آید. نتایج این پژوهش گویای رابطه‌ای معنی‌دار بین تصاویر سنجنده مادیس در هر دو زمان است. نتایج پژوهش‌های ذکر شده به اهمیت دمای سطح زمین در مدیریت مناطق اکولوژیکی و همچنین دستیابی به داده‌هایی با دقت بالا اشاره دارد. صالحی و شمس‌الدینی^۴ (۲۰۲۱)، به منظور تولید نقشه‌های تبخیر و تعرق روزانه با قدرت تفکیک مکانی ۱۰ متر، تصاویر مادیس و لندست-۲ را ترکیب کردند. برای این کار، از دو روش STARFM^۵ و TsHARP^۶ اصلاح شده بهره بردند تا داده‌های سنجنده‌های مادیس و لندست-۲ را ریزمقیاس‌نمایی کنند. طبق این پژوهش، استفاده از الگوریتم‌های مورد اشاره، به منظور تولید نقشه‌های تبخیر و تعرق روزانه برای مناطق همگن، نتایج مطلوبی در برداشت. همچنین بذرگر بجستانی و طیبی^۷ (۲۰۲۱)، به منظور ترکیب محصولات دمای سطح زمین سنجنده‌های مادیس و استر^۸، شیوه‌ای جدید (SWT)^۹ - STDFA^{۱۰} بر مبنای روش STDFA و موجک دوبعدی ایستا مطرح و نتایج تلفیق را با نتایج دو روش RFM^{۱۱} و ESTA^{۱۱} مقایسه کردند. نتایج تحقیق نشان‌دهنده دقت بالای روش پیشنهادی با ریشه

1. Land Surface Temperature
2. LANDSAT
3. Kaffash & Sanaei-Nejad
4. Saleh & Shamsoddini
5. Spatial and Temporal Adaptive Reflectance Fusion Model
6. Thermal Sharpen
7. Bazrgar Bajestani & Tayebi
8. ASTER
9. Stationary Wavelet Transforms
10. Spatial and Temporal Data Fusion Approach
11. Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model

محصولات تبخیر و تعرق ECOSTRESS را دارد. بررسی منابع مشخص کرد که تا کنون مطالعه‌ای در مورد بازسازی داده‌های دمای سطح زمین سنجنده ECOSTRESS در زمان‌های فاقد پوشش، با استفاده از داده‌های دمای سطح زمین تصاویر VIIRS، مادیس و ECOSTRESS و روش‌های یادگیری عمیق، انجام نشده است؛ از این رو، در این پژوهش، الگوریتم شبکه حافظه کوتاه- طولانی مدت (LSTM)^۶ به‌منزله یکی از قوی‌ترین الگوریتم‌های یادگیری عمیق و رگرسیون بردار پشتیبان (SVR)^۷ به‌منزله یکی از رایج‌ترین روش‌های یادگیری ماشین، در دو آبخیز بار- اریه نیشابور و لتیان تهران بررسی شد که هدف از آن مدل‌سازی دمای سطح زمین سنجنده ECOSTRESS و مقایسه کارایی هر دو مدل بوده است. در این مطالعه، تلاش شده است مدل‌های مورد اشاره با یکدیگر مقایسه و عملکرد هر مدل در مدل‌سازی دمای سطح زمین، طی زمان‌هایی که فرض می‌شود داده‌ای وجود ندارد، تخمین زده شود تا نتیجه پژوهش، به‌منزله بهترین تکنیک، در پژوهش‌های آینده به کار رود.

۲- مواد و روش‌ها

۲-۱- منطقه مورد پژوهش

این پژوهش در دو آبخیز سد لتیان و بار- اریه نیشابور انجام شد. مساحت تقریبی آبخیز سد لتیان ۴۳۶ کیلومتر مربع است که شامل زیرآبخیزهای گرمابدر، میگون، آهار، امامه و رودک می‌شود. این آبخیز معرف منطقه کوهستانی است، دامنه ارتفاعی ۱۷۰۰ تا ۴۲۱۲ متر دارد و متوسط بارندگی سالیانه آن ۳۴۰ میلی‌متر است (Sedighi et al., 2016; Gerami et al., 2022).

میانگین مربعات خطای ۳ کلوین، انحراف معیار ۲/۲ کلوین و ضریب همبستگی ۰/۹۲ بین دمای سطح زمین واقعی منطقه و تصاویر بازسازی‌شده، در مقایسه با دو روش دیگر است. در بین پژوهشگران خارج از کشور نیز سال‌هاست که مطالعاتی در این زمینه در حال انجام شدن و توسعه است. شائو^۱ و همکاران (۲۰۱۹)، با استفاده از روش یادگیری عمیق، داده‌های دمای سطح زمین حاصل از ماهواره‌های لندست- ۸ و سنتینل- ۲ را تلفیق کردند. در این پژوهش، از الگوریتم ESRCNN^۲ برای تلفیق داده‌ها استفاده شد و نتایج تأییدی بر کارایی الگوریتم یادگیری عمیق در تولید داده‌های یکنواخت و قابل مقایسه با قدرت تفکیک دهمتری از این دو سنجنده بود؛ همچنین توانایی این شبکه توسعه‌یافته، با هدف تلفیق تصاویر سنجنده‌های لندست- ۸ و سنتینل- ۲، در تولید داده‌های مشاهداتی بازتاب اجسام، به‌مراتب بیشتر از داده‌های یک سنجنده به‌تنهایی است. شوئه^۳ و همکاران (۲۰۲۰)، به‌منظور ریزمقیاس‌نمایی دمای سطح زمین دریافت‌شده از سنجنده‌های ECOSTRESS و VIIRS، از باندهای حرارتی ماهواره‌های لندست و سنتینل و رویکرد اصلاح‌شده داده‌کاوی DMS^۴ بهره بردند. نتایج این پژوهش نشان داد که الگوریتم هم‌جوشی هسته‌ای چندساله روش مناسبی برای افزایش اطلاعات در مقیاس‌های میدانی و همچنین شیوه‌ای مؤثر برای بهبود دقت پایش خشکسالی است. ازسوی دیگر اندرسون^۵ و همکاران (۲۰۲۱) قابلیت تلفیق تصاویر سنجنده‌های ECOSTRESS و LANDSAT را به‌منظور ترسیم نقشه‌های تبخیر و تعرق در مقیاس‌های جزئی، مطالعه کردند. هدف این پژوهش تولید تصاویری با قدرت تفکیک مکانی ۳۰ متر و قدرت تفکیک زمانی روزانه بود. آنها از الگوریتم تلفیق تصاویر سنجنده‌های لندست و ECOSTRESS، با استفاده از داده‌های ۵۰۰ متری سنجنده مادیس، بهره بردند. نتایج این روش با داده‌های زمینی اعتبارسنجی شد و نشان داد که روش مذکور توانایی ریزمقیاس‌نمایی زمانی- مکانی

1. Shao

2. Extended Super-Resolution Convolutional Neural Network

3. Xue

4. Data Mining Sharpener

5. Anderson

6. Long-Short Term Memory


7. Support Vector Regression

سنجنده ECOSTRESS، در هر دو شرایط آب‌وهوایی مورد اشاره، بررسی شد. شکل ۱ موقعیت منطقه‌های مورد مطالعه را در کشور نشان می‌دهد.

۲-۲- داده‌های مورد استفاده

در پژوهش حاضر، از تصاویر سه سنجنده مادیس و VIIRS و ECOSTRESS استفاده شد. ویژگی‌های سنجنده‌های مورد نظر در جدول ۱ آمده است. مادیس یکی از سنجنده‌های ماهواره‌های ترا^۱ و آکوا^۲ است. این سنجنده ۳۶ باند دارد که دو باند آن دارای قدرت تفکیک

آبخیز بار- اریه، با مساحت ۵۳/۹۹ کیلومترمربع، در جنوب رشته‌کوه بینالود در شمال‌غرب شهرستان نیشابور، استان خراسان رضوی، قرار دارد. تغییرات ارتفاعی این آبخیز از ۱۵۵۹ متر در خروجی تا ۲۸۷۰ در بلندترین ارتفاعات آن، متغیر است و میانگین بارندگی سالیانه آن به ۳۳۰/۴ میلی‌متر می‌رسد (Taei, Semiromi et al., 2014; Ebahrami et al., 2015). از آنجاکه آبخیز سد لتیان دارای اقلیم سرد و مرطوب و بار- اریه معرف مناطق سرد و خشک است، عملکرد هر دو مدل یادشده در مدل‌سازی دمای سطح زمین



شکل ۱. موقعیت مناطق مورد مطالعه: آبخیز بار- اریه در استان خراسان رضوی (الف)؛ آبخیز لتیان در استان تهران (ب)

1. Terra
2. Aqua

می‌گیرند؛ به‌این‌صورت که پس از تعیین خطوط پشتیبان، الگوریتم سعی در ایجاد معادله‌ای می‌کند که بیشترین فاصله میان کلاس‌ها را دارد (Hasanlou et al., 2018). روش رگرسیون بردار پشتیبان را اولین بار ولادیمیر واپنیک^۲ و جمعی از همکارانش مطرح کردند (Malik et al., 2020). SVM مدلی رگرسیونی از $F(x)$ شمرده می‌شود که هدف آن یافتن تابع $F(x)$ در داده‌های آموزش $T = \{(x_1, y_1), \dots, (x_l, y_l)\}$ است. $x_i \in \mathbb{R}^n$ ورودی، $y_i \in \mathbb{R}$ خروجی و $i = 1, 2, 3, \dots$ است تا، به‌ازای هر x ، یک مقدار y از تابع $y = f(x)$ حاصل شود؛ به‌گونه‌ای که کمترین خطا در داده‌های آزمایش رخ دهد.

۲-۳-۲- حافظه کوتاه- طولانی مدت

مجموعه دیگری از الگوریتم‌های یادگیری ماشین، با نام یادگیری عمیق، مدل‌های انتزاعی پیچیده را از طریق چندین تبدیل غیرخطی مدل‌سازی می‌کنند. در الگوریتم یادگیری عمیق، ویژگی‌های هر لایه استخراج و به‌صورت ورودی، در لایه بعدی به کار می‌رود؛ به‌این‌ترتیب، ویژگی‌های استنباطی لایه‌های بعدی از طریق ویژگی‌های لایه‌های پایین‌تر حاصل می‌شود (Dehid Havei, 2020). یکی از انواع مدل‌های یادگیری عمیق، شبکه‌های عصبی بازگشتی عمیق (RNN)^۳ است. در این شبکه، خروجی هر لایه ورودی لایه بعدی است و لایه‌ها کاملاً به هم مرتبط‌اند. ازسویی، شبکه‌های عصبی بازگشتی فقط قادر به ذخیره اطلاعات تعداد لایه‌های محدودی‌اند؛ ازاین‌رو استفاده از این مدل، در پیش‌بینی سری‌های زمانی طولانی‌مدت، کارایی لازم را ندارد. برای حل این مشکل، شبکه حافظه کوتاه- طولانی مدت پیشنهاد شد. شکل ۲ نمایی کلی از LSTM را نشان می‌دهد؛ در لایه میانی RNN قرار می‌گیرد و توانایی یادگیری و ثبت

جدول ۱. مشخصات مکانی و زمانی داده‌های ماهواره‌ای مورد استفاده

سنجنده	قدرت تفکیک مکانی	قدرت تفکیک زمانی	دسترسی
ECOSTRESS	۷۰ متر	۳-۴ روز	+۲۰۱۸
MODIS	۱۰۰۰ متر	روزانه	+۱۹۹۹
VIIRS	۷۵۰ متر	روزانه	+۲۰۱۷

مکانی ۲۵۰ متر، پنج باند دارای قدرت تفکیک ۵۰۰ متر و ۲۹ باند دیگر دارای قدرت تفکیک مکانی ۱۰۰۰ متر است. قدرت تفکیک زمانی آن روزانه و قدرت تفکیک رادیومتری آن نیز دوازده بیت است. سنجنده VIIRS دارای ۲۲ باند طیفی است که قدرت تفکیک مکانی باندهای مرئی آن ۳۷۵ متر و سایر باندهای آن ۷۵۰ متر است. سنجنده ECOSTRESS دارای پنج باند طیفی در فروسرخ حرارتی و یک باند در فروسرخ کوتاه است و چرخه تکرار حدوداً چهارروزه و قدرت تفکیک مکانی ۷۰ متر دارد (Rawat et al., 2019; Jaafar et al., 2022).

۲-۳-۲- معرفی مدل‌ها

۲-۳-۱- رگرسیون بردار پشتیبان (SVR)

اصطلاح «هوش مصنوعی» را اولین بار جان مک‌کارتی^۱ مطرح کرد. هوش مصنوعی دانش ساختن سامانه‌ها یا برنامه‌های هوشمندی است که توانایی درک شرایط پیچیده و شبیه‌سازی مدل‌های انتزاعی سطح بالا را دارند (Kim, 2022). یکی از شاخه‌های پیشرفته و پرکاربرد هوش مصنوعی، در دانش‌های گوناگون، یادگیری ماشین است؛ این شاخه به مرتب‌سازی و ایجاد روش‌هایی می‌پردازد که با استفاده از آنها، ماشین قدرت تفکر و شناسایی الگو را می‌آموزد. ازجمله این روش‌ها، ماشین بردار پشتیبان است. در این الگوریتم، به‌صورت خطی یا ابرصفحه، جداکننده‌ای به دست می‌آید که فاصله میان داده‌ها از هم را به بیشترین حد برساند. در این حالت، داده‌هایی که به ابرصفحه جداکننده نزدیک شده یا روی آن قرار گرفته‌اند بردار پشتیبان نامیده می‌شوند و مبنای یادگیری و ساختن مدل قرار

1. John McCarthy


2. Vladimir N. Vapnik

3. Recurrent Neural Network

۴-۲- روش پژوهش


در این مطالعه، با هدف بازسازی داده‌های دمای سطح زمین در آبخیزهای بار-اریه نیشابور و سد لتیان تهران در مقیاس روزانه، از دو مدل یادگیری عمیق و ماشین بردار پشتیبان استفاده شد. به‌منظور استخراج مقادیر دمای سطح زمین، تصاویر از هر سه سنجنده در زمان‌هایی که هر دو منطقه مدنظر بدون پوشش ابر بودند، انتخاب و دریافت شد. سنجنده‌های مادیس و VIIRS دارای قدرت تفکیک زمانی روزانه‌اند اما سنجنده ECOSTRESS در بازه زمانی سه تا چهار روز و گاه طولانی (هشت تا ده‌روزه) تصویر ارائه می‌دهد.

اطلاعات لایه‌های بسیاری، مثلاً ۱۰۰۰ گام زمانی را دارد. LSTM ساختاری به‌نام واحد حافظه برای ذخیره اطلاعات فراهم می‌کند. علاوه‌براین، محل ورودی و خروجی و ذخیره موقت در LSTM تشکیل می‌شود تا مشخص شود اطلاعات گذشته باید حذف شوند یا خیر. در این روش، LSTM ورودی داده‌های جدید را که باید به حالت سلول اضافه شوند، مدیریت می‌کند و همچنین داده‌های خروجی سلول و اطلاعات موقتی را که باید با حالت سلول ذخیره شوند، کنترل می‌کند (Li et al., 2021). شکل ۳ ساختار سلول لایه پنهان LSTM را نشان می‌دهد.



شکل ۲. شمای کلی از ساختار RNN و LSTM

منبع: Yasrab et al., 2020




شکل ۳. ساختار سلول لایه پنهان LSTM

منبع: Yan, 2018

جدول ۲. تاریخ زمانی داده‌های ماهواره‌ای مورد استفاده	
جفت‌داده	
آبخیز لتیان	آبخیز بار-اریه
۲۰۲۰/۰۶/۱۹	۲۰۲۰/۰۶/۱۷
۲۰۲۰/۰۶/۱۵	۲۰۲۰/۰۶/۱۳
۲۰۲۰/۰۶/۲۶	۲۰۲۱/۰۶/۲۲
۲۰۲۰/۰۶/۲۲	۲۰۲۱/۰۶/۱۸
۲۰۱۹/۰۶/۲۸	۲۰۲۰/۰۶/۲۴
۲۰۱۹/۰۶/۲۴	۲۰۲۰/۰۶/۲۰

پس از دریافت تصاویر برای تهیه جفت‌داده در زمان‌های t_1 و t_2 ، تصاویر هر سه سنجنده در نرم‌افزار Envi5.3 برای هر دو آبخیز ترکیب شد. در این مرحله، ابعاد پیکسل تصاویر (تعداد سطر و ستون) تصاویر مادیس و VIIRS به ابعاد پیکسل تصویر ECOSTRESS تبدیل شد؛ بدین ترتیب ابعاد پیکسل جفت‌داده‌های t_1 و t_2 با هم متناسب و یکسان‌اند. سپس در محیط برنامه‌نویسی ۲۰۲۱ MATLAB، الگوریتم‌های LSTM و SVR برای بازسازی داده‌های دمای سطح زمین کدنویسی شد. داده‌های ورودی به مدل شامل داده‌های ECOSTRESS، مادیس و VIIRS

همچنین این سنجنده از سال ۲۰۱۸ به جو پرتاب شد؛ بنابراین فقط تصاویر سال‌های اخیر این سنجنده، یعنی از ۲۰۱۹ تا ۲۰۲۲، در دسترس است. با در نظر گرفتن این نکته که برای محاسبه LST، در اولین اقدام باید به حذف تشعشعات ابری (پاک‌سازی ابرها) پرداخت و مناطق دارای پوشش ابری را حذف کرد، در پژوهش حاضر، داده‌های دمای سطح زمین از سال‌های اخیر و در فصل تابستان که کمترین میزان ابر در مناطق مورد مطالعه وجود دارد، بهره گرفته شد. دمای سطح زمین تصاویر سنجنده‌های ECOSTRESS و VIIRS از سایت earthexplorer.usgs.gov و تصاویر مادیس از سایت ladsweb.modaps.eosdis.nasa.gov/search دریافت شد. به منظور توسعه مدل یادشده ابتدا جفت‌داده، در زمان‌هایی که هر سه سنجنده دارای تصویر بودند، تهیه شد. شکل ۴ نمای شماتیک جفت‌داده‌های مورد نظر را نشان می‌دهد. موارد همراه با تیک سبز بیانگر وجود داده است و موارد دارای ضربدر قرمز یعنی فرض می‌شود، در آن زمان، داده ECOSTRESS وجود ندارد و باید بازسازی انجام شود. البته این کار در زمان‌هایی انجام شده است که داده ECOSTRESS در زمان t_2 نیز وجود داشته، تا داده بازسازی‌شده با داده واقعی مقایسه و صحت مدل‌سازی مشخص شود (جدول ۲).



شکل ۴. نمایش شماتیک جفت‌داده‌ها

حوضه بار-اریه، به‌ترتیب حدود ۱/۸۱ درجه سانتی‌گراد، ۰/۶۶ و ۱۱/۹۴٪ بود. در شکل ۵-الف، نمودار مدل‌سازی نیز گویای همین نکته است. مدل LSTM تاحدودی توانسته است نقاط حدی را تشخیص دهد که نشان‌دهنده دقت بازسازی داده‌ها با استفاده از مدل است، اما نمودار بازسازی کاملاً روی داده‌های بازسازی منطبق نشده است. جعبه تغییرات و پراکندگی داده‌ها نیز همین مسئله را تأیید می‌کند. همچنین در شکل ۵-ب، نتایج مدل SVR آمده و میزان ضرایب، به‌ترتیب، ۲/۳۴ درجه سانتی‌گراد و ۰/۱۷ و ۱۵/۳۹٪ است. بررسی ضرایب در هر مدل نشان داد که مقادیر RMSE و NRMSE برای هر دو مدل بالاست. این مقادیر نشان‌دهنده میانگین تفاوت بین مقادیر پیش‌بینی‌شده با مدل و مقادیر واقعی اندازه‌گیری‌شده است؛ یعنی توانایی مدل را در پیش‌بینی مقدار هدف، تخمین می‌زند. بنابراین می‌توان گفت که مدل LSTM عملکردی متوسط و مدل SVR عملکردی ضعیف داشته است. درنهایت، عملکرد مدل LSTM، در قیاس با مدل شبکه SVR در این تاریخ، بهتر ارزیابی شد.

شکل ۶ گویای نتایج مدل شبکه عصبی LSTM و مدل SVR، طی برآورد دمای سطح زمین سنجنده ECOSTRESS از آبخیز بار-اریه، در تاریخ ۲۲ ژوئن ۲۰۲۱ است. میزان ضرایب RMSE، R^2 و NRMSE برای مدل LSTM به‌ترتیب، ۱/۷۸ درجه سانتی‌گراد، ۰/۳۴ و ۱۶/۷۲٪ و برای مدل SVR نیز (شکل ۵-ب)، این مقادیرها به‌ترتیب، ۲/۱۳ درجه سانتی‌گراد، ۰/۲۳ و ۱۷/۴۵٪ است. در تاریخ مدنظر، هر دو مدل عملکردی نزدیک‌به‌هم و ضعیف داشتند؛ اگرچه، در این تاریخ خاص، مدل LSTM همچنان نتیجه‌ای بهتر از مدل SVR در تخمین دمای سطحی سنجنده ECOSTRESS دربرداشت، عملکرد هر دو مدل ضعیف ارزیابی شد.

در زمان t_1 ، به‌همراه داده‌های مادیس و VIIRS در زمان t_2 و داده‌های خروجی شامل داده‌های ECOSTRESS در زمان t_2 می‌شود. دمای سطح زمین سنجنده ECOSTRESS بازسازی شد و مدل‌سازی در زمان‌های t_2 نیز انجام شد. ۷۰٪ داده‌ها برای آموزش مدل و ۳۰٪ داده‌ها برای ارزیابی به کار رفتند.

پس از اینکه هر دو مدل با داده‌های دمای سطح زمین هر سه سنجنده، یعنی مادیس و VIIRS و ECOSTRESS در زمان t_1 آموزش داده شد، دمای سطح زمین سنجنده ECOSTRESS در زمان t_2 به‌طور جداگانه با هر مدل تخمین زده شد. درنهایت، با استفاده از معیارهای RMSE، R^2 و NRMSE براساس روابط (۱)، (۲) و (۳) مدل‌ها ارزیابی و اعتبارسنجی شدند (Hadadian Sanu et al., 2015; Dastjerdi et al., 2019).

$$RMSE = \sqrt{\frac{1}{n} \sum (O_i - P_i)^2} \quad \text{رابطه (۱)}$$


$$R^2 = \left[\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right]^2 \quad \text{رابطه (۲)}$$

$$NRMSE = \frac{RMSE}{\text{Mean}(X_{obsi})} \quad \text{رابطه (۳)}$$

در معادلات (۱) و (۲)، O_i مقدار مشاهداتی، میانگین مقادیر مشاهده‌ای، n تعداد کل داده‌ها، P_i مقدار تخمین‌زده‌شده و $\bar{P}$ میانگین مقدار تخمین‌زده‌شده است. همچنین در رابطه (۳)، X_{obsi} نشان‌دهنده مقادیر مشاهداتی است.

۳- نتایج و بحث

شکل ۵ نتایج حاصل از مدل شبکه عصبی LSTM و مدل SVR را در تخمین دمای سطح زمین سنجنده ECOSTRESS در آبخیز بار-اریه نشان می‌دهد. همان‌طور که مشاهده می‌شود، در بخش (الف) میزان ضرایب RMSE، R^2 و NRMSE برای مدل LSTM در




شکل ۵. نتایج مدل‌سازی دمای سطح زمین حوضه آبخیز بار- اریه در تاریخ هفدهم ژوئن ۲۰۲۰: مدل LSTM (الف); مدل SVR (ب)

میزان ضرایب $RMSE$ ، R^2 و $NRMSE$ در مدل LSTM برابر با ۲/۴۱ درجه سانتی‌گراد، ۰/۲۳ و ۲۰/۱۴٪ است. برای مدل SVR نیز این مقادیر، به ترتیب، ۴/۳۶ درجه سانتی‌گراد، ۰/۰۶ و ۳۶/۳۳٪ است. در مدل LSTM، گراف‌های مقادیر مدل‌سازی و مقادیر واقعی بر یکدیگر منطبق نشده‌اند و نقاط پیک

بررسی میزان آماره‌های خطای مرتبط با مدل‌های شبکه عصبی LSTM و SVR در شکل ۷، به‌منظور پیش‌بینی دمای سطح زمین سنجنده ECOSTRESS در تاریخ ۲۴ ژوئن ۲۰۲۰، نیز عملکرد ضعیف مدل LSTM و عملکرد بسیار ضعیف مدل SVR در مدل‌سازی دمای سطح زمین را بیان می‌کند.


آبخیز لتیان، طی تاریخ ۱۹ ژوئن ۲۰۲۰، نشان داده شده است. دامنهٔ اختلاف در ضرایب آماره‌های حاصل از روش‌های LSTM و SVR متفاوت و افزایشی بود. میزان ضرایب RMSE، R^2 و NRMSE برای مدل LSTM در حوضهٔ لتیان، ۳/۰۷ درجهٔ سانتی‌گراد، ۰/۷ و ۱۱/۲۴٪ و برای مدل SVR نیز، به‌ترتیب ۴/۲ درجهٔ سانتی‌گراد، ۰/۲ و ۱۵/۳۸٪ بود. بنابراین می‌توان نتیجه گرفت که مدل LSTM عملکردی بهتر از مدل SVR داشته است.

آنها از یکدیگر فاصلهٔ زیادی دارد. در مدل SVR، گراف‌های مقادیر مدل‌سازی و مقادیر واقعی شباهت بسیار اندکی به یکدیگر دارند. نمودار خطی دامنهٔ تغییرات بالایی را در معیارهای خطا نشان می‌دهد که ممکن است ناشی از ضعف روش SVR در دسته‌بندی داده‌های آموزشی در تاریخ مورد اشاره باشد. در شکل ۸، عملکرد روش‌های LSTM و SVR در مدل‌سازی دمای سطح زمین سنجندهٔ ECOSTRESS از



شکل ۶. نتایج مدل‌سازی دمای سطح زمین حوضهٔ آبخیز بار- اریه در تاریخ ۲۲ ژوئن ۲۰۲۱: مدل LSTM (الف)؛ مدل SVR (ب)

1. Error Bar





شکل ۷. نتایج مدل‌سازی دمای سطح زمین در حوضه آبخیز بار- اریه در تاریخ ۲۴ ژوئن ۲۰۲۰: مدل LSTM (الف)؛ مدل SVR (ب)

در هر دو، گراف‌های مقادیر مدل‌سازی و مقادیر واقعی بسیار نزدیک به هم ترسیم شده‌اند و نقاط پیک هر دو نمودار نیز تقریباً به همدیگر نزدیک است. علت آن ممکن است به دامنه تغییرات داده‌های دمای سطح زمین در تاریخ مورد نظر بازگردد. بررسی هر سه معیار


در شکل ۹، نتایج مدل‌سازی دمای سطح زمین روزانه سنجنده ECOSTRESS در آبخیز لتیان، طی ۲۶ ژوئن ۲۰۲۰، نشان داده شده است. نتایج مدل LSTM با نتایج مدل SVR تفاوت چندانی نداشت و در این تاریخ، هر دو مدل عملکردی بسیار نزدیک به هم داشتند.

LSTM به‌ترتیب، $1/81$ درجه سانتی‌گراد، $0/56$ و $1/10/91$ برای مدل SVR به‌ترتیب، $1/85$ درجه سانتی‌گراد، $0/54$ و $1/11/18$ است.

خطا، یعنی RMSE و R^2 و NRMSE، در هر دو مدل و نزدیکی تخمین آنها به یکدیگر نیز بر موضوع مطرح‌شده تأکید می‌کند. مقادیر RMSE، R^2 و NRMSE در مدل




شکل ۸. نتایج مدل‌سازی دمای سطح زمین حوضه آبخیز لتیان در ۱۹ ژوئن ۲۰۲۰: مدل LSTM (الف)؛ مدل SVR (ب)



شکل ۹. نتایج مدل‌سازی دمای سطح زمین حوضه آبخیز لتیان در ۲۶ ژوئن ۲۰۲۰: مدل LSTM (الف)؛ مدل SVR (ب)

۱۵/۵۸٪ است. میان مقادیر آماره‌های خطا در هر دو مدل تفاوت محسوسی وجود دارد. درواقع، هر سه معیار در مدل SVR دوبرابر شده که نشان‌دهنده دوبرابر شدن خطا در این مدل و تاریخ یادشده است؛ بنابراین مدل LSTM با عملکردی بسیار خوب و مدل SVR دارای عملکردی متوسط ارزیابی شد.

شکل ۱۰ بیانگر نتایج مدل‌سازی دمای سطح زمین روزانه سنجنده ECOSTRESS در آبخیز لتیان، طی ۲۸ ژوئن ۲۰۱۹ است. همان‌طور که مشاهده می‌شود، در مدل LSTM هر سه معیار خطا، یعنی $RMSE$ ، R^2 و $NRMSE$ به ترتیب، ۱/۶۱ درجه سانتی‌گراد، ۰/۸۳ و ۸/۶۵٪ برای مدل SVR به ترتیب، ۲/۵۱ درجه سانتی‌گراد، ۰/۴۱ و



شکل ۱۰. نتایج مدل‌سازی دمای سطح زمین حوضه آبخیز لتیان در ۲۸ سپتامبر ۲۰۱۹: مدل LSTM (الف)؛ مدل SVR (ب)

ECOSTRESS نداشته است. عملکرد این مدل در این حوضه، برای تشخیص مقادیر کمینه و بیشینه دمای سطح زمین، مطلوب نبود و دارای خطایی بیشتر از مدل LSTM بود. مدل SVR در تاریخ ۲۲ ژوئن ۲۰۲۱، در قیاس با دو تاریخ دیگر، قدری بهبود داشت اما، در مجموع، عملکرد بسیارضعیفی از خود نشان داد. عملکرد مدل LSTM، در تشخیص الگوی تغییرات

شکل‌های ۱۱ و ۱۲ تصاویر دمای سطح زمین سنجنده ECOSTRESS به همراه تصاویر بازسازی‌شده از طریق دو الگوریتم SVR و LSTM را در دو حوضه یادشده نشان می‌دهد. مطابق این شکل‌ها، در حوضه بار-اریه و در همه تاریخ‌های مورد نظر، نقشه‌های دمای سطح زمین بازسازی‌شده با استفاده از مدل SVR انطباق مناسبی با تصاویر واقعی دمای سطح زمین

۲۶ ژوئن ۲۰۲۰، نتایج هر دو مدل بسیار نزدیک به هم بوده و این مدل‌ها عملکرد تقریباً مشابهی داشته‌اند. میزان ضریب R^2 ، برای هر دو مدل، بیش از ۵۰٪ است و اگرچه می‌تواند مورد قبول باشد، گویای دقت نه‌چندان بالای این مدل است. در مجموع، عملکرد مدل LSTM با دارا بودن چندصدم بیشتر مقدار R^2 ، در تشخیص الگوی تغییرات دمای سطح زمین، مناسب‌تر از مدل SVR بوده است. نقشه‌های حاصل از روش LSTM، تقریباً در تمامی تاریخ‌های آبخیز لتیان، از الگوی تصاویر واقعی ECOSTRESS پیروی می‌کند که نشان‌دهنده توانایی بالای این مدل در تشخیص رفتار پدیده مورد مطالعه است. با توجه به نتایج پژوهش، حوضه نیشابور در مجموع، برای هر دو مدل صرفاً در یک تاریخ شبیه‌سازی صحیح داشته و این حوضه، برخلاف حوضه لتیان، نتوانسته است نتایج مورد قبولی به دست دهد که علت آن ممکن است درک و آموزش نادرست مدل از داده‌ها باشد. در این راستا، به‌منظور مدل‌سازی داده‌های مبتنی بر زمان، شبکه عصبی مورد استفاده باید بتواند در ذخیره‌سازی اطلاعات مرتبط با


دمای سطح زمین، مناسب‌تر از مدل SVR بود و در تاریخ ۱۷ ژوئن ۲۰۲۰ بیشترین ضریب همبستگی، یعنی ۰/۵۶ را داشت و نقشه حاصل از آن از الگوی تصویر واقعی ECOSTRESS پیروی می‌کند. با توجه به نتایج پژوهش آبخیز بار-اریه، در کل، برای هر دو مدل فقط در یک تاریخ شبیه‌سازی صحیح وجود داشت و این حوضه نتوانست نتایج مورد قبولی به دست آورد؛ این مسئله ممکن است ناشی از درک و آموزش نادرست مدل در مورد داده‌ها باشد. در آبخیز لتیان و طی همه تاریخ‌های مورد نظر نیز، نقشه‌های دمای سطح زمین بازسازی‌شده با استفاده از مدل SVR انطباق مناسبی با تصاویر واقعی دمای سطح زمین ECOSTRESS نداشته است و مدل SVR نتوانسته الگوی تغییرات مکانی دمای سطح زمین را تشخیص دهد. این مدل، در تشخیص کمینه و بیشینه دمای سطح زمین نیز، عملکرد چندان مناسبی نشان نداده است. گرچه هر دو مدل LSTM و SVR دامنه تغییرات دمای سطح زمین را کمتر از میزان واقعی تخمین زده‌اند، مدل SVR خطای بیشتری در این مورد داشته است. البته در

جدول ۳. مقادیر آماره‌های خطای تمامی سناریوها در هر شش تاریخ


ایستگاه	تاریخ		LSTM	SVR
بار-اریه	2020/06/17	R^2	۰/66	۰/۱۷
		RMSE	1/81	۲/۳۴
		NRMSE	%11/94	۱۵/۳۹
	2021/06/22	R^2	0/34	۰/۲۳
		RMSE	1/78	۲/۱۳
		NRMSE	%16/72	۱۷/۴۵
	2020/06/24	R^2	0/23	۰/۰۶
		RMSE	2/41	۴/۳۶
		NRMSE	%20/14	۳۶/۳۳
	2020/06/19	R^2	0/7	۰/۲
		RMSE	3/07	۴/۲
		NRMSE	%11/24	۱۵/۳۸
لتیان	2020/06/26	R^2	0/56	۰/۵۴
		RMSE	1/81	۱/۸۵
		NRMSE	%10/91	۱۱/۱۸
	2019/06/28	R^2	0/83	۰/۴۱
		RMSE	1/61	۲/۵۱
		NRMSE	%8/65	۱۵/۵۸

ورودی‌های گذشته، به مدت طولانی عملکرد موفقی از خود نشان دهد. در صورت نداشتن این توانایی، شبکه عصبی قادر به مدل‌سازی ساختارهای بلندمدت نیست و هنگام تولید دنباله، در معرض ناپایداری قرار خواهد گرفت. همچنین در صورتی که پیش‌بینی‌های شبکه فقط به چند ورودی اخیر وابسته باشد و خود این ورودی‌ها نیز از طریق شبکه تولید شده باشند، در تصحیح و جبران اشتباهات گذشته از طریق شبکه، موفقیت چندانی به دست نخواهد آمد. زمان مواجهه با داده‌ای اعشاری، این مسئله نمود بیشتری خواهد یافت زیرا پیش‌بینی‌ها می‌توانند، از ساختار چندبعدی درونی که داده‌های آموزشی روی آن قرار گرفته است، فاصله بگیرند.

بنابراین می‌توان نتیجه گرفت که مدل‌های دارای لایه‌های عمیق زیاد، در بررسی و مدل‌سازی ویژگی‌های سری زمانی، کارآمدتر خواهند بود و با داشتن حافظه‌ای بلندمدت‌تر، عملکرد بهتری خواهند داشت. شبکه، حتی در صورت درک نادرست از تاریخچه اخیر خود، همچنان قادر خواهد بود با نگاه به گذشته پیش‌بینی، خود را کامل کند. در همین راستا، در پژوهش حاضر، عملکرد مدل SVR با مدل LSTM مقایسه شد. همان‌طور که در شکل‌های ۵ تا ۱۰ مشاهده می‌شود، مدل LSTM توانست در اغلب تاریخ‌های یادشده و برای هر دو منطقه، نتایجی بهتر از روش SVR دربر داشته باشد. مدل LSTM، برای منطقه بار-اریه در ۱۷ ژوئن ۲۰۲۰



شکل ۱۱. نقشه‌های بازسازی‌شده و واقعی دمای سطح زمین سنجنده ECOSTRESS در حوضه آبخیز بار-اریه



شکل ۱۲. نقشه‌های بازسازی‌شده و واقعی دمای سطح زمین سنجنده ECOSTRESS در حوضه آبخیز لتیان

مجموعه کلاس‌های هدف دارای هم‌پوشانی خواهند بود. همین نکته ممکن است سبب افزایش خطای مدل شود و نتایج پژوهش حاضر نیز مؤید آن است. درواقع، به‌منظور مدل‌سازی داده‌های سری زمانی، به‌ویژه داده‌هایی که با فاصله‌های طولانی از یکدیگر تهیه و پردازش خواهند شد، مدل LSTM بهتر توانست ویژگی‌های شاخص‌های مهم در دنباله ورودی، در گام‌های ابتدایی را تشخیص دهد و این اطلاعات را به‌سادگی، طی مسیری طولانی، منتقل کند. همچنین به‌منظور مدل‌سازی، وابستگی‌های بلندمدت احتمالی را به‌خوبی دریافت و حفظ می‌کند و درنهایت، عملکردی مطلوب‌تر از مدل SVR دارد. با توجه به این نکته، در تحلیل

و نیز منطقه لتیان در تاریخ ۲۸ ژوئن ۲۰۱۹، بهترین نتیجه را عرضه کرد. طبق نتایج، استفاده از مدل LSTM افزایش کیفیت پیش‌بینی را در قیاس با مدل SVR، داشته است؛ چراکه در مدل SVR، با هدف مدل‌سازی روابط پیچیده و پدیده‌های غیرخطی، از توابع کرنل استفاده می‌شود و به‌عبارتی، با تغییر غیرخطی از محیط ورودی به محیطی با ابعاد بیشتر، می‌توان با استفاده از تبدیل غیرخطی، ویژگی‌های ورودی مورد نظر را ابتدا تفکیک و سپس مدل‌سازی کرد. اما با توجه به پراکنش بالای داده‌ها در محث رگرسیون و تعداد زیاد داده‌ها، در صورتی که ابرصفحه از تمامی داده‌ها در طبقه‌بندی و مدل‌سازی استفاده کند،

برای بررسی متغیرهای اقلیمی، دچار محدودیت‌های کاربردی‌اند. اغلب سنجنده‌ها مانند لندست و مادیس و دیگر سنجنده‌های اپتیکالی با مشکل پوشش ابری گسترده در تصاویر مواجه‌اند و بنابراین گاه استفاده از این دسته از داده‌ها ناممکن می‌شود. بدین ترتیب، با توجه به پیچیدگی‌های مدیریتی خاص هر حوضه و متأثر بودن آنها از متغیرهای فراوان و همچنین محدودیت‌های استفاده از تصاویر سنجنش از دور، برای پژوهش‌هایی در زمینه برآورد متغیرهایی توصیه می‌شود که اطلاع دقیق از میزان تغییرات روزانه یا ساعتی آن‌ها، مانند دمای هوا، رطوبت خاک و دمای سطح زمین، ضروری است.

۴- نتیجه‌گیری و پیشنهادها

دمای سطح زمین مؤلفه‌ای است که در بسیاری از مطالعات، مانند بیان انرژی، تبخیر و تعرق و بسیاری از مطالعات هیدرولوژی استفاده می‌شود. در پژوهش حاضر، عملکرد مدل LSTM و SVR در بازسازی داده‌های دمای سطح زمین سنجنده ECOSTRESS، با استفاده از داده‌های سنجنده‌های مادیس، VIIRS و ECOSTRESS در آبخیزهای بار-اریه و لتیان، ارزیابی و بررسی شد. نتایج پژوهش نشان داد عملکرد مدل‌ها، به جز در یک تاریخ، با یکدیگر متفاوت بوده و مدل LSTM در مجموع، در هر دو حوضه، عملکرد بهتری در بازسازی دمای سطح زمین داشته است؛ این نکته توانایی بالای LSTM را می‌رساند. مدل‌های مورد استفاده از مدل‌های بسیار قوی و پرکاربرد در مدل‌سازی‌های محیطی‌اند. SVR مدلی قدرتمند در زمینه یادگیری ماشین و LSTM از مؤثرترین مدل‌های یادگیری عمیق است. باید در نظر داشت که با توجه به پیچیدگی فرایند و تعدد عوامل مؤثر در دمای سطح زمین، نتایج به دست آمده دقت و صحت مورد

سری‌های زمانی، باید به درک و مدل‌سازی پارامترهای غیرخطی و مؤثر در رخداد پدیده‌ها پرداخت تا بتوان، برای پیش‌بینی مقادیر آینده سری که بر مبنای گذشته انجام می‌شود، به اقدامات مدیریتی مناسب روی آورد. حاجی‌زاده طحان^۱ و همکاران (۲۰۲۰)، در مطالعه‌ای، توانایی الگوریتم LSTM را در پیش‌بینی سری‌های زمانی طولانی بررسی کردند و نتایج تحقیق آنها بیانگر تأیید پژوهش حاضر است. ژانگ^۲ و همکاران (۲۰۱۷) و خلیل^۳ و همکاران (۲۰۲۲) نیز عملکرد الگوریتم LSTM را برای مدل‌سازی دمای سطح دریا و دمای سطح زمین، بررسی کردند؛ نتایج مطالعه این افراد نیز در راستای نتایج این پژوهش است. با توجه به مطالعه انجام‌شده و بررسی عملکرد مدل LSTM در برآورد و بازسازی دمای سطح زمین، می‌توان به این نتیجه رسید که این مدل، در برآورد دمای سطح زمین سنجنده ECOSTRESS با آموزش داده‌های مادیس، VIIRS و ECOSTRESS در زمان t2، عملکردی خوب و مناسب داشته است؛ این نکته دقت مدل در مدل‌سازی دمای سطح زمین را بیان می‌کند. طبق این پژوهش، استفاده از داده‌های ماهواره‌ای می‌تواند باعث صرفه‌جویی در وقت و هزینه و افزایش دقت در تصمیم‌گیری‌های مدیریتی شود. البته نباید فراموش کرد که طبق مطالب گفته‌شده و پژوهش‌های انجام‌گرفته (Zhang et al., Khalil et al., 2022)، مدل دارای پارامترهای فیزیکی است و برای هر حوزه و با توجه به ماهیت داده‌ها، به واسنجی پارامترها نیاز است. پایش بهنگام دمای سطح زمین، در حوضه‌های آبخیز کوهستانی و شهری و دیگر مناطق، ویژگی‌ها و پارامترهای متعدد متغیرهای مناطق را نشان می‌دهد. از این رو با بهره‌گیری از نقشه‌های دمای سطح زمین به منزله یکی از پتانسیل‌های حوضه در زمینه بهره‌برداری از منابع آب و خاک آن، می‌توان مدیریت مناسب‌تری اعمال کرد. تصاویر ماهواره‌ای، به‌رغم مزایا و ویژگی‌های فراوان مانند سهل‌الوصول بودن، ارائه محصولات به صورت روزانه و ایجاد راهکارهایی مفید

1. Hajizadeh Tahan
2. Zhang
3. Khalil

- Sensing of Environment, 252, PP. 112-189, <https://doi.org/10.1016/j.rse.2020.112189>.
- Bakhshi, E. & Khalookakaei, R., 2010, **Application of Artificial Neural Networks in Remote Sensing**, Geomatics Conference, Tehran. <https://civilica.com/doc/102419>.
- Bazrgar Bajestani, A. & Tayebi, M., 2021, **Presentation of a New Method for the Fusion of Spatial-Temporal Land Surface Temperature Products of ASTER and MODIS Sensors Based on a Two-Dimensional Stationary Wavelet Transform**, Iranian Journal of Remote Sensing and GIS, 12(4), PP. 93-114, <https://doi.org/10.52547/gisj.12.4.93>.
- Dastjerdi, F., Azarakhshi, M. & Bashiri, M., 2019, **Comparison of Efficiency for Hydrological Models (AWBM & SimHyd) and Neural Network (MLP & RBF) in Rainfall-Runoff Simulation (Case Study: Bar Aryeh Watershed -Neyshabur)**, Jwmseir, 13(45), PP. 107-117, DOI: 20.1001.1.20089554.1398.13.45.13.7 (In Persian).
- Dehid Havei, H., 2020, **Forecasting Crude Oil Prices Using Improved DeepBelief Network (IDBN) And Long-Term Short-Termemory Network (LSTM)**, Imam Reza International University.
- Ebahrami, S., Amir-Ahmadi, A., Habibolahian, M. & Ebrahimi M., 2015, **Analyzing the Criticality Related to the Landslide Incidence Using the Probability Models for the Weight to Evidence (Bayesian Theory) (Case Study: Bar Basin of Neyshabur)**, Geography and Environmental Planning, 25(4), PP. 125-144, DOI: 20.1001.1.20085362.1393.25.4.8.6 (In Persian).
- Gerami, Z., Peyrowan, H.R. & Partovi, A., 2022, **Introducing Suitable Places for Establishing Rainwater Catchment Systems in Latyan Watershed**, Journal of Rainwater Catchment Systems, 9(4), PP. 33-42, 20.1001.1.24235970.1400.9.4.1.9 (In Persian).
- Hadadian Sanu, H., Karimi, A., Esfandiapour Borujeni, I. & Haqnia, G., 2015, **Comparing the Efficiency of RMSE and NRMSE to Calculate the Effective Error Value of Models with Different Training Data Sets**, The 14th Congress of Soil Sciences of Iran.

قبولی دارند. تأکید بر این نکته که مدل‌سازی و پیش‌بینی دمای سطح زمین برای سه یا چهار روز بعد انجام شده است (با توجه به فاصله زمانی بین دو تصویر متوالی ECOSTRESS) و اتفاقات پیچیده‌ای که طی این مدت ممکن است به وقوع بپیوندد، می‌تواند بر مناسب بودن نتایج و کارایی مدل‌های مورد استفاده صحت بگذارد. توجه به مقادیر R^2 به‌منزله معیار استاندارد برای ارزیابی تحلیل‌های رگرسیون، و نیز مقادیر RMSE و NRMSE نشان‌دهنده توانایی مطلوب مدل LSTM در بازسازی مقادیر دمای سطح زمین ECOSTRESS است. با توجه به دامنه تغییرات دمای سطح زمین در تاریخ‌های مدل‌سازی که بین ۰ تا ۳۵ درجه سانتی‌گراد تغییر کرده است، مقدار RMSE (که متوسط خطای مدل را بیان می‌کند) برای مدل LSTM حدود ۱/۵ تا ۳ درجه سانتی‌گراد بوده که مورد قبول و مناسب به نظر می‌رسد. مقادیر نرمال‌شده RMSE، یا همان NRMSE نیز، در اغلب تاریخ‌ها بین ۸ تا ۱۷٪ بود که در مدل‌سازی‌های محیطی، با توجه به پیچیدگی‌های بالای فرایندها، مقداری مورد قبول است. اما قطعاً، به‌منظور بررسی و پیش‌بینی سری زمانی، به الگوریتم‌های دقیق‌تر و پیشرفته‌تری نیاز است؛ بنابراین چه‌بسا استفاده از برخی پیش‌پردازش‌ها مانند موجک و کرولت، با توجه به ماهیت کشف ویژگی پیش‌پردازش‌های مدنظر از داده‌های سری زمانی، مناسب باشد و از این‌رو برای استفاده در پژوهش‌های مشابه پیشنهاد می‌شود. درواقع، پیش‌پردازش‌های یادشده مؤلفه‌های گوناگونی مانند فرکانس بالا و فرکانس پایین را از سیگنال اصلی استخراج و به‌صورت ورودی، در اختیار مدل قرار می‌دهند که می‌تواند سبب افزایش عملکرد مدل‌های داده‌محور شود.

۵- منابع

- Anderson, M.C., Yang, Y., Xue, J., Knipper, K.R., Yang, Y., Gao, F. & Rey-Sanchez, C., 2021, **Interoperability of ECOSTRESS and Landsat for Mapping Evapotranspiration Time Series at Sub-Field Scales**, Remote

- Hajizadeh Tahan, M., Ghasemzadeh, M. & Rezaeian, M., 2020, **An Evolutionary Attention-Based Deep Long Short-Term Memory for Time Series Prediction**, Computational Intelligence in Electrical Engineering, 11(4), PP. 15-28, DOI: 10.22108/isee.2020.121597.1334 (In Persian).
- Hasanlou, M., Jamshidi, M. & Sattari, M., 2018, **Urmia Lake Salinity Mapping Using Support Vector Regression and Landsatimagery**, Hydrogeomorphology, 5(14), PP. 43-65, DOI: 20.1001.1.23833254. 1397.5.14.3.7 (In Persian).
- Hejazizadeh, Z., Ziaian, P. & Shirkhani, A., 2013, **Estimation of Surface Temperature Using Thermal-Band Data in the West of Tehran Province and Qazvin**, Geography, 11(38), PP. 33-49, ISSN: 2783-3739 (In Persian).
- Jaafar, H., Mourad, R. & Schull, M., 2022, **A Global 30-m ET Model (HSEB) Using Harmonized Landsat and Sentinel-2, MODIS and VIIRS: Comparison to ECOSTRESS ET and LST**, Remote Sensing of Environment, 274, P. 112995, <https://doi.org/10.1016/j.rse.2022.112995>.
- Kaffash, M. & Sanaei-Nejad, S.H., 2020, **Fusion of MODIS and Landsat-8 Land Surface Temperature Images Using Spatio-Temporal Image Fusion Model**, Iranian Journal of Soil and Water Research, 51(3), PP. 763-773, DOI: 10.22059/ijswr.2019.291016.668360 (in Persian).
- Khalil, U., Azam, U., Aslam, B., Ullah, I., Tariq, A., Li, Q. & Lu, L., 2022, **Developing a Spatiotemporal Model to Forecast Land Surface Temperature: A Way Forward for Better Town Planning**, Sustainability, 14(19), P. 11873, <https://doi.org/10.3390/su141911873>.
- Kim, H., 2022, **4 Tracing the Origins of Artificial Intelligence: A Kantian Response to McCarthy's Call for Philosophical Help**, Kant and Artificial Intelligence, 129, DOI: 10.1515/9783110706611-004 (In Book: Kant and Artificial Intelligence).
- Li, H., Wu, G., Xu, F. & Li, S., 2021, **Landsat-8 and Gaofen-1 Image-Based Inversion Method for the Downscaled Land Surface Temperature of Rare Earth Mining Areas**, Infrared Physics & Technology, 113, P. 103658, <https://doi.org/10.1016/j.infrared.2021.103658>.
- Malik, A., Tikhamarine, Y., Souag-Gamane, D., Kisi, O. & Pham, Q.B., 2020, **Support Vector Regression Optimized by Meta-Heuristic Algorithms for Daily Streamflow Prediction**, Stochastic Environmental Research and Risk Assessment, 34, PP. 1755-1773, DOI: 10.1007/s00477-020-01874-1.
- Rawat, K.S., Sehgal, V.K. & Ray, S.S., 2019, **Downscaling of MODIS Thermal Imagery**, The Egyptian Journal of Remote Sensing and Space Science, 22(1), PP. 49-58, <https://doi.org/10.1016/j.ejrs.2018.01.00>.
- Salehi, H. & Shamsoddini, A., 2021, **MODIS and Sentinel-2 Data Fusion For 10-m Daily Evapotranspiration Mapping**, Iranian Journal of Irrigation & Drainage, 14(6), PP. 1881-1892, DOI: 20.1001.1.20087942.2021.14.6.20.1 (In Persian).
- Sedighi, F., Vafakhah, M. & Javadi, M.R., 2016, **Application of Artificial Neural Network for Snowmelt-Runoff (Case Study: Layan Dam Watershed)**, Journal of Watershed Management Research, 6(12), PP. 43-54 (In Persian).
- Shao, Z., Cai, J., Fu, P., Hu, L. & Liu, T., 2019, **Deep Learning-Based Fusion of Landsat-8 and Sentinel-2 Images for a Harmonized Surface Reflectance Product**, Remote Sensing of Environment, 235, PP. 111-425, <https://doi.org/10.1016/j.rse.2019.111425>.
- Taei Semiromi, S., Moradi, H. & Khodaghali, M., 2014, **Simulation and Prediction Some of Climate Variable by Using Multi Line SDSM and Global Circulation Models (Case Study: Bar Watershed Nayshabour)**, Human & Environment, 12(28, Spring 2014), PP. 1-15 (In Persian).
- Wang, j., Schmitz, O., Lu, M. & Karssenberg, D., 2020, **Thermal Unmixing Based Downscaling for Fine Resolution Diurnal Land Surface Temperature Analysis**, ISPRS Journal of Photogrammetry and Remote Sensing, 161, PP. 76-89, <https://doi.org/10.1016/j.isprsjprs.2020.01.014>.
- Xue, J., Anderson, M.C., Gao, F., Hain, C., Sun, L., Yang, Y. & Schull, M., 2020, **Sharpening ECOSTRESS and VIIRS Land Surface Temperature Using Harmonized Landsat-Sentinel Surface Reflectances**, Remote Sensing of Environment, 251, PP. 112-055, <https://doi.org/10.1016/j.rse.2020.112055>.

- Yan, S., 2018, **Understanding LSTM and Its Diagrams**, Available Online: <https://medium.com/mlreview/understanding-lstm-and-its-diagrams-37e2f46f1714> (Accessed on 26 June 2018).
- Yasrab, R., Pound, M.P., French, A.P. & Pridmore, T.P., 2020, **PhenomNet: Bridging Phenotype-Genotype Gap: A CNN-LSTM Based Automatic Plant Root Anatomization System**, BioRxiv, 2020-05, <https://doi.org/10.1101/2020.05.03.075184>.
- Zhang, Q., Wang, H., Dong, J., Zhong, G. & Sun, X., 2017, **Prediction of Sea Surface Temperature Using Long Short-Term Memory**, IEEE Geoscience and Remote Sensing Letters, 14(10), PP. 1745-1749, DOI: 10.1109/LGRS.2017.2733548.

