

# 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

Department of Watershed Management Engineering, Faculty of Natural Resources and Marine Sciences, Tarbiat Modares University, Tehran, Iran  
corresponding author: [v.moosavi@modares.ac.ir](mailto:v.moosavi@modares.ac.ir)

Received: ۲۰۲۳, ۰۹, ۲۷

Accepted: ۲۰۲۴, ۰۵, ۲۰

## 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 rates and timing. 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 ۷۰ 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 ۱۷, ۲۰۲۰, with RMSE = ۱,۸۱°C,  $R^2 = ۰,۶۶$ , and NRMSE = ۱۱,۹۴%. For the Latyan Dam watershed, the most accurate predictions were recorded on June ۲۸, ۲۰۱۹, with RMSE = ۱,۶۱°C,  $R^2 = ۰,۸۳$ , and NRMSE = ۸,۶۵%. 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 (۳–۴ 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 ۱,۵°C and ۳°C) indicate a reasonably accurate estimation, given the natural variability of LST (۰°C to nearly ۳۰°C in the study areas). Additionally, the NRMSE values (mostly between ۸% and ۱۷%) 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  $\sim 1.5-3^\circ\text{C}$ ) 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

## بازسازی داده‌های دمای سطح زمین سنجنده‌ی ECOSTRESS با استفاده از یادگیری عمیق و رگرسیون بردار پشتیبان (مطالعه موردی: آبخیزهای باران‌ریه و لتیان)

فروغ احمدی نژاد باغبان، وحید موسوی\*، حمیدرضا مرادی

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

تاریخ پذیرش مقاله: ۱۴۰۳/۰۲/۳۱

تاریخ دریافت مقاله: ۱۴۰۲/۰۷/۰۵

\*نویسنده عهده دار مکاتبات: v.moosavi@modares.ac.ir

کد ارکید: ۱۱۷۸-۴۵۶۳-۰۰۰۲-۰۰۰۰

## چکیده

**سابقه و هدف :** دمای سطح زمین یک متغیر کلیدی در برنامه‌ریزی ناحیه‌ای و منطقه‌ای می‌باشد با توجه به اهمیت دمای سطح زمین در مطالعات تغییرات اقلیمی، مدل‌سازی هیدرولوژیکی، نظارت بر پوشش گیاهی، جزیره گرمای شهری، توسعه‌ی شهری، گرمایش جهانی، شرایط کشاورزی و همچنین تأثیر آن بر نرخ و زمان رشد گیاهان پارامتر ورودی به اکثر مدل‌ها است؛ هرچه دقت تخمین این متغیر بالاتر باشد خروجی مدل نیز همراه با دقت بالاتری خواهد بود؛ بنابراین مطالعه بهینه و مناسب تغییرات مکانی و زمانی دمای سطح زمین در شرایط جوی و آب و هوایی متفاوت ضروری است. با توجه به محدودیت ایستگاه‌های هواشناسی، سنسور از دور می‌تواند به عنوان پایه و اساس بسیاری از داده‌های هواشناسی مورد استفاده قرار گیرد. دمای سطح زمین در تصاویر ماهواره‌ای شامل میانگین دمای پیکسلی است که پوشش دهنده بخشی از سطح زمین بوده و بر اساس انرژی رسیده به سنجنده (رادیانس) در باند حرارتی محاسبه می‌شود. از این رو عدم وجود قدرت تفکیک زمانی و مکانی بالای داده‌های ماهواره‌ای به‌طور همزمان یک چالش اساسی در بررسی و تخمین متغیر دما مطرح می‌گردد.

**مواد و روش‌ها :** در این مطالعه سعی شد با استفاده از روش یادگیری عمیق و یادگیری ماشین، از تصاویر ماهواره‌ای MODIS، VIIRS و ECOSTRESS استفاده و نقشه‌های روزانه دمای سطح زمین سنجنده‌ی 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 گردد. مدل‌های مورد استفاده در پژوهش شامل مدل SVR به‌عنوان یک مدل محبوب یادگیری ماشین در زمینه‌های پیش‌بینی و رگرسیون و مدل LSTM یکی از قوی‌ترین مدل‌های یادگیری عمیق در حوزه پردازش سری‌های زمانی می‌باشند. برای این منظور سه جفت تاریخ برای هر حوضه (شش تاریخ) انتخاب شد. تصاویر هر جفت داده به‌طور همزمان در اختیار مدل‌ها قرار گرفتند. در نهایت با استفاده از آماره‌های RMSE،  $R^2$  و عملکرد هر مدل در هر تاریخ مورد ارزیابی قرار گرفت.

**نتایج و بحث:** بررسی ضرایب RMSE،  $R^2$  و NRMSE مربوط به مدل LSTM و SVR برای هر دو منطقه نشان‌دهنده برتری عملکرد مدل LSTM بود. بهترین نتیجه RMSE،  $R^2$  و NRMSE حاصل از مدل LSTM برای آبخیز بار-اریه در تاریخ‌های ۱۷ ژوئن ۲۰۲۰ به ترتیب ۱/۸۱ درجه سانتی‌گراد، ۰/۶۶ و ۱۱/۹۴ درصد و در حوزه آبخیز لتیان برای تاریخ ۲۸ ژوئن ۲۰۱۹ به ترتیب حدود ۱/۶۱ درجه سانتی‌گراد، ۰/۸۳ و ۸/۶۵ درصد بود. مدل LSTM با توجه به ساختار، ویژگی‌های خود و به‌عنوان یک مدل یادگیری عمیق قوی با استخراج ویژگی از درون داده‌های خام با در نظر گرفتن ماهیت سری زمانی بودن داده‌ها توانست بر پیچیدگی‌های فرآیند تحت مدل‌سازی غلبه نماید. ذکر این نکته ضروری است که با در نظر گرفتن پیچیدگی فرآیند و متشوع بودن عوامل موثر بر دمای سطح زمین نتایج به‌دست آمده از دقت و صحت قابل قبولی برخوردار هستند. بازسازی و پیش‌بینی دمای سطح زمین برای ۳ الی ۴ 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.

**نتیجه‌گیری:** بررسی نتایج و مقادیر  $R^2$  به‌عنوان یک معیار استاندارد برای ارزیابی تحلیل‌های رگرسیون، و نیز مقادیر RMSE و NRMSE نشان از برتری مدل LSTM در بازسازی مقادیر دمای سطح زمین ECOSTRESS می‌باشد. با توجه به دامنه تغییرات و مولفه‌های موثر، دمای سطح زمین در تاریخ‌های مورد بازسازی بین صفر تا بعضاً نزدیک به ۳۵ درجه سانتیگراد تغییر نمود، مقدار RMSE (نشان دهنده متوسط خطای مدل) برای مدل LSTM بین حدود ۱.۵ تا ۳ درجه سانتیگراد بوده که قابل قبول و مناسب به نظر می‌رسد. مقادیر نرمال شده RMSE یا همان NRMSE نیز در اغلب تاریخ‌ها بین ۸ تا ۱۷ درصد بوده که در مدل‌سازی‌های محیطی با توجه به پیچیدگی‌های بالای فرآیندها مقادیر قابل قبولی می‌باشند.

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

دمای سطح زمین ( $LST^1$ ) یک متغیر بسیار مهم در مطالعه‌ی مدل‌های تعادل انرژی در سطح زمین و فعل و انفعالات بین زمین و جو در سطح منطقه‌ای و جهانی است که نقش مهمی در کنترل فرآیندهای بیولوژیک، شیمیایی و فیزیکی زمین دارد (Wang et al., ۲۰۲۰; Li et al., ۲۰۲۱). اندازه‌گیری دمای سطح زمین در ایستگاه‌های هواشناسی صورت می‌گیرد؛ نکته‌ی قابل توجه این است که توزیع مکانی این ایستگاه‌ها، برای بسیاری از مطالعات و بررسی‌ها مناسب نمی‌باشد. همچنین دسترسی و پایش محیطی این متغیرها در برخی آب‌خیزها به دلیل وضعیت خاص توپوگرافی منطقه آسان نیست (Bakhshi & Khalookakaei, ۲۰۱۰). از این‌رو سنجش از دور حرارتی می‌تواند برای مطالعه‌ی دمای سطح زمین در مقیاس وسیع و در زمان‌های مختلف راه‌گشا باشد (Hejazizadeh et al., ۲۰۱۳). مشکل اصلی استفاده از تصاویر ماهواره‌ای، عدم تامین هم‌زمان قدرت تفکیک مکانی و زمانی بالا می‌باشد. بدین مفهوم که اگر از تصاویر با قدرت تفکیک مکانی متوسط مانند LANDSAT استفاده شود، با توجه به تغییرپذیری زمانی بالای متغیرهایی مانند دما، رطوبت خاک و تبخیر و تعرق، عدم وجود داده به صورت روزانه می‌تواند باعث ایجاد مشکلاتی در محاسبات مربوطه شود. از سوی دیگر در صورت استفاده از داده‌هایی با قدرت تفکیک زمانی بالا مانند MODIS، قدرت تفکیک مکانی نقش محدود کننده را ایفا خواهد کرد (Kaffash & Sanaci-Nejad, ۲۰۲۰). به همین علت، پژوهشگران به استفاده از روش‌های مختلف ریاضی و مدل‌سازی به منظور تلفیق تصاویر ماهواره‌ای و تولید محصولات که هم‌زمان قدرت تفکیک زمانی و مکانی مورد نیاز را داشته باشند. امروزه محققین و پژوهشگران مطالعات گسترده‌ای در زمینه‌ی استفاده هم‌زمان تصاویر ماهواره‌ای و مدل‌سازی دمای سطح زمین انجام داده‌اند. در سال‌های اخیر در بین پژوهشگران ایرانی مطالعاتی صورت پذیرفته است. به عنوان مثال در مطالعه‌ی کفاش و ثنائی نژاد (۲۰۲۰) به منظور تلفیق تصاویر دمای سطح زمین MODIS و LANDSAT-۸ از مدل تلفیقی مکانی-زمانی (STI-FM) استفاده کردند. در این پژوهش در ابتدا ضرایب رابطه‌ی خطی بین دو تصویر سنجنده‌ی MODIS در زمان‌های یک و دو مشخص شد؛ سپس ضرایب به تصویر سنجنده‌ی LANDSAT در زمان یک اعمال گردید تا تصویر در زمان دو به دست آید. نتایج این پژوهش نشان دهنده‌ی یک رابطه‌ی معنی‌دار بین تصاویر سنجنده‌ی MODIS در هر دو زمان می‌باشد. نتایج پژوهش‌های ذکر شده بیانگر اهمیت دمای سطح زمین در مدیریت مناطق اکولوژیکی و همچنین دستیابی به داده‌هایی با دقت بالا است. صالحی و شمس‌الدینی (۲۰۲۱) در پژوهشی دیگر به منظور تولید نقشه‌های تبخیر و تعرق روزانه با قدرت تفکیک مکانی ۱۰ متر به ترکیب تصاویر MODIS و SENTINEL-۲ پرداختند. برای این کار از دو روش STARFM<sup>۲</sup> و TsHARP<sup>۳</sup> اصلاح شده به منظور ریزمقیاس‌نمایی داده‌های سنجنده‌های MODIS و SENTINEL استفاده کردند. نتایج نشان داد استفاده از الگوریتم‌های مذکور به منظور تولید نقشه‌های تبخیر و تعرق روزانه برای مناطق همگن دارای نتایج مناسبی است. همچنین بذرگر بجستانی و طیبی (۲۰۲۱) به منظور ترکیب محصولات دمای سطح زمین سنجنده‌های MODIS و ASTER روشی جدید (STDFA<sup>۴</sup>\_SWT<sup>۵</sup>) بر مبنای روش STDFA و موجک دو بعدی ایستا ارائه کردند. ایشان نتایج حاصل از تلفیق را با نتایج دو روش ESTARFM<sup>۶</sup> و STDFA مقایسه کردند. نتایج تحقیق نشان دهنده دقت بالای روش پیشنهادی با ریشه میانگین مربعات خطای ۳ کلون، انحراف معیار ۲/۲ کلون و ضریب همبستگی ۰/۹۲ بین دمای سطح زمین واقعی منطقه

<sup>۱</sup> Land surface temperature

<sup>۲</sup> Spatial and temporal adaptive reflectance fusion model

<sup>۳</sup> Thermal sharpen

<sup>۴</sup> Stationary Wavelet transforms

<sup>۵</sup> Spatial and Temporal Data Fusion Approach

<sup>۶</sup> Enhanced spatial and temporal adaptive reflectance fusion model

و تصاویر بازسازی شده در مقایسه با دو روش دیگر می‌باشد. در بین پژوهشگران خارج از کشور نیز سال‌هاست که مطالعاتی در این زمینه در حال انجام و توسعه می‌باشد. شائو و همکاران (۲۰۱۹) با استفاده از روش یادگیری عمیق به تلفیق داده‌های دمای سطح زمین حاصل از ماهواره‌های LANDSAT-۸ و SENTINEL-۲ پرداختند. در این پژوهش از الگوریتم<sup>۷</sup> ESRCNN به منظور تلفیق داده‌ها استفاده شد. نتایج، تاییدی بر کارایی الگوریتم یادگیری عمیق در تولید داده‌های یکنواخت و قابل مقایسه با قدرت تفکیک ۱۰ متری از LANDSAT-۸ و SENTINEL-۲ بود همچنین این شبکه‌ی توسعه یافته با هدف تلفیق تصاویر سنجنده‌های LANDSAT-۸ و SENTINEL-۲ به مراتب توانایی بالاتری در تولید داده‌های مشاهداتی بازتاب اجسام نسبت به داده‌های یک سنجنده به تنهایی دارا می‌باشد. در مطالعه‌ای دیگر شوئه و همکاران (۲۰۲۰) به منظور ریزمقیاس‌نمایی دمای سطح زمین سنجنده‌های ECOSTRESS و VIIRS از باندهای حرارتی ماهواره‌های LANDSAT و SENTINEL و یک رویکرد اصلاح شده‌ی داده‌کاوی تحت عنوان DMS<sup>۸</sup> استفاده کردند. نتایج حاصل از این پژوهش نشان داد که الگوریتم همجوشی هسته‌ای چند ساله، می‌تواند یک روش مناسب برای افزایش اطلاعات در مقیاس‌های میدانی و همچنین یک روش موثر برای بهبود دقت پایش خشکسالی باشد. از سویی دیگر آندرسون و همکاران (۲۰۲۱) قابلیت تلفیق تصاویر سنجنده‌های ECOSTRESS و LANDSAT به منظور ترسیم نقشه‌های تبخیر و تعرق در مقیاس‌های جزئی را مطالعه کردند. هدف از این پژوهش تولید تصاویری با قدرت تفکیک مکانی ۳۰ متر و قدرت تفکیک زمانی روزانه بود. ایشان یک الگوریتم تلفیق تصاویر سنجنده‌های LANDSAT و ECOSTRESS با استفاده از داده‌های ۵۰۰ متری سنجنده‌ی MODIS را بکار بردند. نتایج این روش با داده‌های زمینی اعتبارسنجی شد و نشان داد که روش مذکور توانایی ریزمقیاس‌نمایی زمانی-مکانی محصولات تبخیر و تعرق ECOSTRESS را دارا می‌باشد. تا جایی که مرور منابع نشان داد؛ تاکنون مطالعه‌ای در خصوص بازسازی داده‌های دمای سطح زمین سنجنده ECOSTRESS در زمان‌های فاقد پوشش با استفاده از داده‌های دمای سطح زمین تصاویر MODIS، VIIRS و ECOSTRESS و روش‌های یادگیری عمیق صورت نگرفته است. لذا در این پژوهش به بررسی الگوریتم شبکه حافظه طولانی-کوتاه مدت (LSTM<sup>۹</sup>) به عنوان یکی از قوی‌ترین الگوریتم‌های یادگیری عمیق و رگرسیون بردار پشتیبان (SVR<sup>۱۰</sup>) به عنوان یکی از رایج‌ترین روش‌های یادگیری ماشین در دو آبخیز بار-اریه نیشابور و لتیان تهران به منظور مدل‌سازی دمای سطح زمین سنجنده ECOSTRESS و مقایسه‌ی کارایی هر دو مدل پرداخته شد. در این مطالعه سعی بر این است که مدل‌های مذکور با یکدیگر مقایسه و عملکرد هر مدل در مدل‌سازی دمای سطح زمین در زمان‌هایی که فرض می‌شود داده‌ای موجود نیست؛ تخمین زده شود تا نتیجه‌ی پژوهش به عنوان بهترین تکنیک در پژوهش‌های آینده مورد استفاده قرار گیرد.

<sup>۷</sup> Extended super-resolution convolutional neural network

<sup>۸</sup> Data mining sharpener


<sup>۹</sup> Long-short term memory

<sup>۱۰</sup> Support vector regression

## ۲- مواد و روش ها

### ۲-۱- منطقه پژوهش

این پژوهش در دو آبخیز سد لتیان و بار-اریه نیشابور انجام شد. آبخیز سد لتیان دارای مساحت تقریبی ۴۳۶ کیلومترمربع است که شامل زیرآبخیزهای گرمابدر، میگون، آهار، امامه و رودک می‌باشد. این آبخیز معرف منطقه کوهستانی بوده و دارای دامنه ارتفاعی ۱۷۰۰ تا ۴۲۱۲ متر است همچنین متوسط بارندگی سالانه آن ۳۴۰ میلی‌متر می‌باشد (Sedighi et al., ۲۰۱۶; Gerami et al., ۲۰۲۲). آبخیز بار-اریه با مساحت ۵۳/۹۹ کیلومترمربع در جنوب رشته کوه بینالود در شمال غرب شهرستان نیشابور در استان خراسان رضوی قرار دارد. تغییرات ارتفاعی آبخیز بار-اریه از ۱۵۵۹ متر در خروجی تا ۲۸۷۰ در بلندترین ارتفاعات آن متغیر می‌باشد. متوسط بارندگی سالانه آن ۳۳۰/۴ میلی‌متر است (Ebahrani et al., ۲۰۱۵; Taei Semiromi et al., ۲۰۱۴). از آنجا که آبخیز سد لتیان به‌عنوان یک آبخیز دارای اقلیم سرد و مرطوب شناخته می‌شود و همچنین آبخیز بار-اریه معرف مناطق سرد و خشک است؛ لذا عملکرد هر دو مدل ذکر شده در مدل‌سازی دمای سطح زمین سنجنده‌ی ECOSTRESS در هر دو شرایط آب و هوایی معرفی شده مورد بررسی قرار گرفت. شکل ۱ موقعیت منطقه‌های مورد مطالعه را در کشور نشان می‌دهد.



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

## ۲-۲- داده‌های مورد استفاده :

در پژوهش حاضر از تصاویر سه سنجنده‌ی MODIS، VIIRS و ECOSTRESS استفاده شد. ویژگی‌های سنجنده‌های مورد نظر در جدول ۱ آمده است. سنجنده‌ی MODIS یکی از سنجنده‌های موجود در ماهواره‌های Aqua و Terra می‌باشد. این سنجنده دارای ۳۶ باند است که دو باند آن با قدرت تفکیک مکانی ۲۵۰ متر، پنج باند با قدرت تفکیک ۵۰۰ متر و ۲۹ باند دیگر آن دارای قدرت تفکیک مکانی ۱۰۰۰ متر می‌باشند. همچنین قدرت تفکیک زمانی آن روزانه و قدرت تفکیک رادیومتری آن ۱۲ بیت است. سنجنده‌ی VIIRS دارای ۲۲ باند طیفی می‌باشد؛ باندهای مرئی این سنجنده دارای قدرت تفکیک مکانی ۳۷۵ متر و سایر باندهای آن دارای قدرت تفکیک مکانی ۷۵۰ متر می‌باشند. سنجنده‌ی ECOSTRESS شامل پنج باند طیفی در مادون قرمز حرارتی و یک بلند در مادون قرمز کوتاه است. همچنین دارای چرخه تکرار حدوداً چهار روزه و قدرت تفکیک مکانی ۷۰ متر می‌باشد (Rawat et al., ۲۰۱۹; Jaafar et al., ۲۰۲۲).

جدول ۱. مشخصات مکانی و زمانی داده‌های ماهواره‌ای مورد استفاده

| Sensor    | Spatial resolution | Temporal resolution | Available |
|-----------|--------------------|---------------------|-----------|
| ECOSTRESS | ۷۰ m               | ۳-۴ daily           | +۲۰۱۸     |
| MODIS     | ۱۰۰۰ m             | daily               | +۱۹۹۹     |
| VIIRS     | ۷۵۰ m              | daily               | +۲۰۱۷     |

## ۲-۳- معرفی مدل‌ها :

### ۲-۳-۱- رگرسیون بردار پشتیبان (SVR):


واژه هوش مصنوعی اولین بار توسط جان مک کارتی ارائه شد. هوش مصنوعی دانش ساختن سامانه‌ها یا برنامه‌های هوشمندی است که توانایی درک شرایط پیچیده و شبیه‌سازی مدل‌های انتزاعی سطح بالا را دارند (Kim, ۲۰۲۲). یکی از شاخه‌های پیشرفته و پرکاربرد هوش مصنوعی در علوم مختلف یادگیری ماشین است که در آن به مرتب‌سازی و ایجاد روش‌هایی پرداخته می‌شود که با استفاده از آن‌ها ماشین قدرت تفکر و شناسایی الگورا می‌آموزد. از جمله‌ی این روش‌ها، ماشین بردار پشتیبان (SVM<sup>۱۱</sup>) است. در این الگوریتم به صورت خطی یا ابر صفحه، جداکننده‌ای بدست می‌آید که فاصله‌ی میان داده‌ها را از هم به بیشترین حد برساند. در این حالت داده‌هایی که به ابر صفحه‌ی جدا کننده نزدیک و یا بر روی آن قرار گرفته‌اند؛ بردار پشتیبان نامیده و مبنای یادگیری و ساختن مدل قرار خواهند گرفت. به این صورت که پس از تعیین خطوط پشتیبان، الگوریتم سعی در ایجاد یک معادله به منظور یافتن بیشترین فاصله میان کلاس‌ها را دارد (Hasanlou et al., ۲۰۱۸). روش رگرسیون بردار پشتیبان (SVR<sup>۱۲</sup>) برای اولین بار توسط ولادیمیر واپنیک و جمعی از همکاران او ارائه شد (Malik et al., ۲۰۲۰). SVR یک مدل رگرسیونی از SVM می‌باشد که هدف آن یافتن تابع  $F(x)$  در داده‌های آموزش  $T = \{(x_1, y_1), \dots, (x_l, y_l)\}$  بوده که  $x_i \in \mathbb{R}^n$  ورودی و  $y_i \in \mathbb{R}$  خروجی و  $i = 1, 2, 3, \dots$  است؛ تابع  $y$  از تابع  $y = f(x)$  حاصل شود؛ بطوریکه کمترین خطا در داده‌های آزمایش رخ دهد.

<sup>۱۱</sup> Support vector mashine

<sup>۱۲</sup> Support vector regression


## ۲-۳-۲- حافظه کوتاه - طولانی مدت (LSTM):

مجموعه‌ی دیگری از الگوریتم‌های یادگیری ماشین با نام یادگیری عمیق، مدل‌های انتزاعی پیچیده را به‌وسیله‌ی چندین تبدیل غیرخطی مدل‌سازی می‌کنند. در الگوریتم یادگیری عمیق ویژگی‌های هر لایه استخراج و بعنوان ورودی در لایه‌ی بعدی استفاده می‌شود به این ترتیب ویژگی‌های استنباطی لایه‌های بعدی به‌وسیله‌ی ویژگی‌های لایه‌های پایین‌تر حاصل می‌شود (Dehid Havei, ۲۰۲۰). یکی از انواع مدل‌های یادگیری عمیق، شبکه‌های عصبی بازگشتی عمیق ( $RNN^{۱۳}$ ) است. در این شبکه، خروجی هر لایه ورودی لایه‌ی بعدی است و لایه‌ها کاملاً بهم مرتبط هستند. اما شبکه‌های عصبی بازگشتی تنها قادر به ذخیره‌ی اطلاعات تعداد لایه‌های محدودی است. از این‌رو استفاده از این مدل در پیش‌بینی سری‌های زمانی طولانی مدت کاربرد لازم را ندارد. به منظور حل این مشکل، شبکه حافظه طولانی-کوتاه مدت (LSTM) ارائه شد. شکل ۲ نمایشی کلی از LSTM را نشان می‌دهد که LSTM در لایه‌ی میانی RNN قرار می‌گیرد و توانایی یادگیری و ثبت اطلاعات لایه‌های بسیاری مثلاً ۱۰۰۰ گام زمانی را دارد. LSTM ساختاری به نام واحد حافظه برای ذخیره اطلاعات فراهم می‌کند. علاوه بر این، محل ورودی، خروجی و ذخیره موقت در LSTM تشکیل می‌شود تا مشخص شود آیا اطلاعات گذشته باید حذف شوند یا خیر. در این روش LSTM، ورودی مقدار داده جدید که می‌تواند به حالت سلول اضافه شود و در خروجی نیز داده‌های خروجی سلول و ذخیره موقت اطلاعاتی را که باید توسط حالت سلول ذخیره شود را کنترل می‌کند (Li et al., ۲۰۲۱). شکل ۳ ساختار سلول لایه پنهان LSTM را نشان می‌دهد.



شکل ۲. شمای کلی از ساختار RNN و LSTM (Yasrab et al, ۲۰۲۰)


شکل ۳. ساختار سلول لایه پنهان LSTM (Yan, S. ۲۰۱۸)



<sup>۱۳</sup> Recurrent neural network

## ۲-۴-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 موجود از هر سه سنجنده در زمان‌هایی که هر دو منطقه‌ی مدنظر بدون پوشش ابر بوده؛ انتخاب و دریافت شد. سنجنده‌های MODIS و VIIRS دارای قدرت تفکیک زمانی روزانه هستند اما سنجنده‌ی ECOSTRESS در بازه‌ی زمانی ۳ الی ۴ روز و گاهی بازه‌ی زمانی طولانی (۸ الی ۱۰ روزه) تصویر ارائه می‌دهد همچنین سنجنده‌ی ECOSTRESS از سال ۲۰۱۸ به‌جای پرتاب شد؛ بنابراین در حال حاضر فقط در سال‌های اخیر یعنی از ۲۰۱۹ تا ۲۰۲۲ تصاویر این سنجنده موجود می‌باشد. با در نظر گرفتن این نکته که به‌منظور محاسبه‌ی LST در ابتدا باید به حذف تشعشعات ابری (پاکسازی ابرها) به‌عنوان اولین اقدام پرداخت و مناطق دارای پوشش ابری را حذف نمود؛ در پژوهش حاضر داده‌های دمای سطح زمین از سال‌های اخیر و در فصل تابستان که کمترین میزان ابر در مناطق مورد مطالعه موجود است؛ بهره گرفته شد. دمای سطح زمین تصاویر سنجنده ECOSTRESS و VIIRS از سایت [earthexplorer.usgs.gov](http://earthexplorer.usgs.gov) و تصاویر سنجنده MODIS از سایت [ladsweb.modaps.eosdis.nasa.gov/search](http://ladsweb.modaps.eosdis.nasa.gov/search) دریافت شدند. به‌منظور توسعه مدل مذکور ابتدا جفت داده در زمان‌هایی که هر سه سنجنده دارای تصویر بودند؛ تهیه شد. شکل ۴ نمای شماتیک جفت داده‌های مورد نظر را نشان می‌دهد. موارد همراه با تیک سبز یعنی داده وجود دارد و موارد همراه با ضربدر قرمز یعنی فرض می‌شود در آن زمان داده ECOSTRESS موجود نیست و باید بازسازی صورت پذیرد. البته این کار در زمان‌هایی صورت گرفته که داده ECOSTRESS در زمان  $t_2$  نیز موجود بوده تا داده بازسازی شده با داده واقعی مقایسه گردد و صحت مدل-سازی مشخص شود (جدول ۲).



شکل ۴. نمایش شماتیک جفت داده‌ها

جدول ۲. تاریخ زمانی داده‌های ماهواره‌ای مورد استفاده

| جفت داده    |               |
|-------------|---------------|
| آبخیز لتیان | آبخیز باراریه |
| ۱۹/۰۶/۲۰۲۰  | ۱۷/۰۶/۲۰۲۰    |
| ۱۵/۰۶/۲۰۲۰  | ۱۳/۰۶/۲۰۲۰    |
| ۲۶/۰۶/۲۰۲۰  | ۲۲/۰۶/۲۰۲۱    |
| ۲۲/۰۶/۲۰۲۰  | ۱۸/۰۶/۲۰۲۱    |
| ۲۸/۰۶/۲۰۱۹  | ۲۴/۰۶/۲۰۲۰    |
| ۲۴/۰۶/۲۰۱۹  | ۲۰/۰۶/۲۰۲۰    |

پس از دریافت تصاویر برای تهیه‌ی جفت داده در زمان‌های  $t_1$  و  $t_2$  اقدام به ترکیب تصاویر هر سه سنجنده در نرم افزار  $Enviro^3$  برای هر دو آبخیز بار-اریه و لتیان گردید. در این مرحله ابعاد پیکسل تصاویر (تعداد سطر و ستون) تصاویر MODIS و VIIRS به ابعاد پیکسل تصویر ECOSTRESS تبدیل شد. بدین ترتیب ابعاد پیکسل جفت داده‌های  $t_1$  و  $t_2$  باهم متناسب و یکسان هستند. سپس در محیط برنامه‌نویسی MATLAB ۲۰۲۱ الگوریتم‌های LSTM و SVR برای بازسازی داده‌های دمای سطح زمین کدنویسی شد. داده‌های ورودی به مدل شامل داده‌های ECOSTRESS، MODIS و VIIRS در زمان  $t_1$  به همراه داده‌های MODIS و VIIRS در زمان  $t_2$  و داده‌های خروجی مدل شامل داده‌های ECOSTRESS در زمان  $t_2$  می‌باشد. دمای سطح زمین سنجنده‌ی ECOSTRESS بازسازی و مدل‌سازی در زمان‌های  $t_2$  انجام شد. ۷۰ درصد داده‌ها برای آموزش مدل و ۳۰ درصد داده‌ها برای ارزیابی استفاده شدند.

پس از اینکه هر دو مدل با داده‌های دمای سطح زمین هر سه سنجنده یعنی MODIS، VIIRS و ECOSTRESS در زمان  $t_1$  آموزش داده شد؛ اقدام به تخمین دمای سطح زمین سنجنده‌ی ECOSTRESS در زمان  $t_2$  به‌طور جداگانه با هر مدل گردید. در نهایت با استفاده از معیارهای RMSE،  $R^2$  و NRMSE براساس روابط ۱، ۲ و ۳ ارزیابی و اعتبارسنجی مدل‌ها صورت پذیرفت (Dastjerdi et al., ۲۰۱۹; Hadadian Santu et al., ۲۰۱۵).

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

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


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

که در روابط ۱ و ۲  $O_i$  مقدار مشاهداتی،  $\bar{O}$  میانگین مقادیر مشاهده‌ای،  $n$  تعداد کل داده‌ها،  $P_i$  مقدار تخمین زده شده و  $\bar{P}$  میانگین مقدار تخمین زده شده است. همچنین در رابطه ۳  $X_{obsi}$  نشان دهنده 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 سنجنده‌ی ECOSTRESS


در آبخیز بار-اریه نشان می‌دهد. همانطور که مشاهده می‌شود در قسمت (الف) میزان ضرایب RMSE،  $R^2$  و NRMSE برای مدل LSTM در حوزه بار-اریه به ترتیب حدود ۱/۸۱ درجه سانتی‌گراد، ۰/۶۶ و ۱۱/۹۴ درصد بود. در شکل الف نمودار مدل‌سازی نیز گویای همین امر است. مدل LSTM تا حدودی توانسته است نقاط حدی را تشخیص دهد که نشان دهنده دقت بازسازی داده‌ها توسط مدل می‌باشد اما نمودار بازسازی کاملاً بر روی داده‌های بازسازی منطبق نشده است. جعبه‌ی تغییرات و پراکندگی داده‌ها نیز همین امر را تایید میکند. همچنین در قسمت (ب) که نشان دهنده نتایج مدل SVR می‌باشد میزان ضرایب به ترتیب ۲/۳۴ درجه سانتی‌گراد و ۰/۱۷ و ۱۵/۳۹ درصد است. بررسی میزان ضرایب در هر مدل نشان داد که مقادیر RMSE و NRMSE برای هر دو مدل بالا می‌باشد که نشان دهنده میانگین تفاوت بین مقادیر پیش‌بینی شده توسط یک مدل و مقادیر واقعی را اندازه‌گیری می‌کند. تخمینی از اینکه مدل چقدر قادر به پیش‌بینی مقدار هدف است را ارائه می‌دهد. بنابراین می‌توان گفت که مدل LSTM عملکردی متوسط و مدل SVR یک عملکرد ضعیف داشته است. نهایتاً عملکرد مدل LSTM نسبت به مدل شبکه SVR در این تاریخ بهتر ارزیابی شد.



شکل (۵) نتایج حاصل از مدل سازی دمای سطح زمین حوزه آبخیز بار-اره الف) مدل LSTM ب) مدل SVR در تاریخ ۱۷ ژوئن

۲۰۲۰


شکل (۶) نشان دهنده نتایج حاصل از مدل شبکه عصبی LSTM و مدل SVR در برآورد دمای سطح زمین سنجندهی ECOSTRESS مربوط به آبخیز بار-اره و در تاریخ ۲۲ ژوئن ۲۰۲۱ می باشند. میزان ضرایب RMSE و  $R^2$  برای مدل LSTM به ترتیب ۱/۷۸ درجه سانتی گراد، ۰/۳۴ و ۱۶/۷۲ درصد است. همچنین برای مدل SVR در قسمت (ب)، میزان ضرایب به ترتیب ۲/۱۳ درجه سانتی گراد، ۰/۲۳ و ۱۷/۴۵ درصد است. در تاریخ مدنظر هر دو مدل دارای عملکردی نزدیک به هم و ضعیف بودند؛ اگرچه بازهم در این تاریخ خاص مدل LSTM نسبت به مدل SVR در تخمین دمای سطحی سنجندهی ECOSTRESS نتیجهی بهتری ارائه نمود اما عملکرد هر دو مدل ضعیف ارزیابی شد.



شکل (۶) نتایج حاصل مدل‌سازی دمای سطح زمین حوزه آبخیز بار-اریه الف) مدل LSTM ب) مدل SVR در تاریخ ۲۲ ژوئن ۲۰۲۱

بررسی میزان آماره‌های خطای مرتبط با مدل‌های شبکه عصبی LSTM و SVR در شکل (۷) به منظور پیش‌بینی دمای سطح زمین سنجنده‌ی ECOSTRESS در تاریخ ۲۴ ژوئن ۲۰۲۰ نیز نشان از عملکرد ضعیف مدل LSTM و بسیار ضعیف مدل SVR در مدل‌سازی دمای سطح زمین می‌باشد. میزان ضرایب RMSE،  $R^2$  و NRMSE در مدل LSTM، ۲/۴۱ درجه سانتی‌گراد، ۰/۲۳ و ۲۰/۱۴ درصد است. برای مدل SVR نیز این مقادیر به ترتیب ۴/۳۶ درجه سانتی‌گراد، ۰/۰۶ و ۳۶/۳۳ درصد می‌باشد. در مدل LSTM گراف‌های مقادیر مدل‌سازی و مقادیر واقعی بر یکدیگر منطبق نشده و نقاط پیک آن‌ها از یکدیگر فاصله‌ی زیادی دارند. در مدل SVR گراف‌های مقادیر مدل‌سازی و مقادیر واقعی شباهت‌های بسیار اندکی به یکدیگر دارند. Error Bar نیاز دامنه‌ی


تغییرات زیادی را در معیارهای خطا نشان می‌دهد. علت این امر می‌تواند ضعف روش SVR در دسته‌بندی داده‌های آموزشی در تاریخ مذکور باشد.



شکل (۷) نتایج حاصل از مدل‌سازی دمای سطح زمین حوزه آبخیز باراریه الف) مدل LSTM ب) مدل SVR در تاریخ ۲۴ ژوئن


۲۰۲۰

در شکل (۸) عملکرد روش‌های LSTM و SVR در مدل‌سازی دمای سطح زمین سنجنده ECOSTRESS آبخیز لتیان در تاریخ ۱۹ ژوئن ۲۰۲۰، نشان داده شده است. دامنه‌ی اختلاف در ضرایب آماره‌های حاصل از روش LSTM و ضرایب حاصل از روش SVR متفاوت و افزایشی بود. میزان ضرایب  $RMSE$  و  $R^2$  برای مدل LSTM در حوزه لتیان ۳/۰۷ درجه سانتی‌گراد، ۰/۷ و ۱۱/۲۴ درصد بود همچنین برای مدل SVR به ترتیب ۴/۲ درجه سانتی‌گراد، ۰/۲ و ۱۵/۳۸ درصد است. بنابراین می‌توان نتیجه گرفت که مدل LSTM نسبت به مدل SVR عملکرد بهتری ارائه داده است.




شکل (۸) نتایج حاصل از مدل سازی دمای سطح زمین حوزه آبخیز لتیان الف) مدل LSTM ب) مدل SVR در تاریخ ۱۹ ژوئن ۲۰۲۰

شکل (۹) نتایج مدل سازی دمای سطح زمین روزانه سنجنده‌ی ECOSTRESS در آبخیز لتیان برای تاریخ ۲۶ ژوئن ۲۰۲۰ نشان داده شده است. نتایج حاصل از مدل LSTM در مقایسه با نتایج حاصل از مدل SVR تفاوت چندانی نداشت. در این تاریخ هر دو مدل عملکردی بسیار نزدیک به هم داشتند. در هر دو مدل گراف‌های مقادیر مدل سازی و مقادیر واقعی بسیار نزدیک به هم ترسیم شده‌اند. نقاط پیک هر دو نمودار نیز تقریباً به هم دیگر نزدیک است. علت این امر می‌تواند در دامنه‌ی تغییرات داده‌های دمای سطح زمین در تاریخ مذکور باشد. بررسی هر سه معیار خطا یعنی RMSE،  $R^2$  و NRMSE در هر دو مدل و نزدیکی تخمین آن‌ها به یکدیگر نیز تاکید کننده‌ی موضوع مطرح شده است. مقادیر RMSE،  $R^2$  و NRMSE در مدل LSTM به ترتیب شامل ۱/۸۱ درجه سانتی‌گراد، ۰/۵۶ و ۱۰/۹۱ درصد و برای مدل SVR به ترتیب ۱/۸۵ درجه سانتی‌گراد، ۰/۵۴ و ۱۱/۱۸ درصد است.



شکل (۹) نتایج حاصل از مدل سازی دمای سطح زمین حوزه آبخیز لتیان الف) مدل LSTM ب) مدل SVR در تاریخ ۲۶ ژوئن ۲۰۲۰

شکل (۱۰) نشان دهنده نتایج مدل سازی دمای سطح زمین روزانه سنجنده‌ی ECOSTRESS در آبخیز لتیان برای تاریخ ۲۸ ژوئن ۲۰۱۹ می‌باشد. همانطور که مشاهده می‌شود در مدل LSTM هر دو معیار خطای یعنی  $R^2$ ، RMSE و NRMSE به ترتیب ۱/۶۱ درجه سانتی‌گراد، ۰/۸۳ و ۸/۶۵ درصد می‌باشد. این ضرایب برای مدل SVR به ترتیب ۲/۵۱ درجه سانتی‌گراد، ۰/۴۱ و ۱۵/۵۸ درصد است. میان مقادیر آماره‌های خطا در هر دو مدل تفاوت محسوسی وجود دارد. درواقع هر سه معیار در مدل SVR برابر شده که نشان‌دهنده‌ی دو برابر شدن خطا در این مدل و برای تاریخ مذکور می‌باشد. بنابراین مدل LSTM عملکردی خیلی خوب و مدل SVR دارای یک عملکرد متوسط ارزیابی شد.



شکل (۱۰) نتایج حاصل از مدل سازی دمای سطح زمین حوزه آبخیز لتیان الف) مدل LSTM ب) مدل SVR در تاریخ ۲۸ سپتامبر


۲۰۱۹

شکل های ۱۱ و ۱۲ تصاویر دمای سطح زمین سنجنده ECOSTRESS به همراه تصاویر بازسازی شده توسط دو الگوریتم SVR و LSTM را در دو حوزه بار-اریه نیشابور و لتیان تهران نشان می دهد. همانطور که در این شکل ها دیده می شود در حوزه باراریه و در همه ی تاریخ های مورد نظر نقشه های دمای سطح زمین بازسازی شده توسط مدل SVR انطباق مناسبی با تصاویر واقعی دمای سطح زمین ECOSTRESS نداشته است. این مدل در این حوزه برای تشخیص مقادیر کمینه و بیشینه دمای سطح زمین عملکرد مناسبی نداشته و دارای خطای بالاتری نسبت به مدل LSTM بود. مدل SVR در تاریخ ۲۲ ژوئن ۲۰۲۱ نسبت به دو تاریخ دیگر کمی بهبود پیدا کرد اما در مجموع عملکرد بسیار ضعیفی از خود نشان داد. عملکرد مدل LSTM در تشخیص الگوی تغییرات دمای سطح زمین مناسب تر از مدل SVR بود. در تاریخ ۱۷ ژوئن ۲۰۲۰ دارای بیشترین ضریب همبستگی یعنی ۰/۵۶ و نقشه ی حاصل از آن از الگوی تصویر واقعی ECOSTRESS پیروی می کند. با توجه به نتایج پژوهش آبخیز باراریه

در مجموع برای هر دو مدل تنها در یک تاریخ شبیه سازی صحیح داشته است و این حوضه نتوانست نتایج قابل قبولی دریافت کند این امر می تواند ناشی از درک و آموزش نادرست مدل از داده ها باشد. در آبخیز لتیان و در همه ی تاریخ های مورد نظر نیز نقشه های دمای سطح زمین بازسازی شده توسط مدل SVR انطباق مناسبی با تصاویر واقعی دمای سطح زمین ECOSTRESS نداشته است. مدل SVR نتوانسته است الگوی تغییرات مکانی دمای سطح زمین را تشخیص دهد. این مدل در تشخیص کمینه و بیشینه دمای سطح زمین نیز عملکرد خیلی مناسبی نداشته است. گرچه هر دو مدل LSTM و SVR دامنه تغییرات دمای سطح زمین را کمتر از میزان واقعی تخمین زده اند ولی مدل SVR خطای بالاتری در این مورد داشت. البته در تاریخ ۲۶ ژوئن ۲۰۲۰ هر دو مدل نتایج بسیار نزدیک بهم داشته و تقریباً عملکرد مشابهی داشتند. میزان ضریب  $R^2$  برای هر دو مدل بیش از پنجاه درصد می باشد که اگرچه می تواند قابل قبول باشد اما نشان دهنده دقت نه چندان بالای این مدل است. در مجموع عملکرد مدل LSTM با دارا بودن چند صدم بیشتر در تشخیص الگوی تغییرات دمای سطح زمین مناسب تر از مدل SVR بود. نقشه های حاصل از روش LSTM تقریباً در تمامی تاریخ های آبخیز لتیان از الگوی تصاویر واقعی ECOSTRESS پیروی می کند. این امر نشان دهنده توانایی بالای این مدل در تشخیص رفتار پدیده مورد مطالعه می باشد. با توجه به نتایج پژوهش حوضه نیشابور در مجموع برای هر دو مدل تنها در یک تاریخ شبیه سازی صحیح داشته است و این حوضه علاوه بر حوضه لتیان نتوانسته است نتایج قابل قبولی دریافت کند این امر می تواند ناشی از درک و آموزش نادرست مدل از داده ها باشد. در این راستا به منظور مدل سازی داده های مبتنی بر زمان، شبکه عصبی مورد استفاده باید بتواند در ذخیره سازی اطلاعات مرتبط با ورودی های گذشته به مدت طولانی عملکرد موفقی از خود نشان دهد. در صورت عدم دارا بودن این توانایی، شبکه عصبی قادر به مدل سازی ساختارهای بلند مدت نبوده و در زمان تولید دنباله در معرض ناپایداری قرار خواهد گرفت. همچنین در صورتی که پیش بینی های شبکه تنها وابسته به چند ورودی اخیر باشد و این ورودی ها خود نیز توسط شبکه تولید شده باشند؛ شانس بسیار کمی برای تصحیح و جبران اشتباهات گذشته توسط شبکه وجود دارد. در زمان مواجهه با داده اعشاری این مسئله نمود بیشتری پیدا خواهد کرد چرا که پیش بینی ها می توانند از مانیفولدی که داده های آموزشی بر روی آن قرار گرفته اند؛ فاصله بگیرند.

| جدول ۳. مقادیر آماره های خطای تمامی سناریوها و برای هر شش تاریخ |            |       |         |       |
|-----------------------------------------------------------------|------------|-------|---------|-------|
| ایستگاه                                                         | تاریخ      |       | LSTM    | SVR   |
| باراریه                                                         | ۱۷/۰۶/۲۰۲۰ | $R^2$ | ۰/۶۶    | ۰/۱۷  |
|                                                                 |            | RMSE  | ۱/۸۱    | ۲/۳۴  |
|                                                                 |            | NRMSE | ۱۱/۹۴ % | ۱۵/۳۹ |
|                                                                 |            | $R^2$ | ۰/۳۴    | ۰/۲۳  |
|                                                                 |            | RMSE  | ۱/۷۸    | ۲/۱۳  |
|                                                                 |            | NRMSE | ۱۶/۷۲ % | ۱۷/۴۵ |
|                                                                 | ۲۲/۰۶/۲۰۲۱ | $R^2$ | ۰/۲۳    | ۰/۰۶  |
|                                                                 |            | RMSE  | ۲/۴۱    | ۴/۳۶  |
|                                                                 |            | NRMSE | ۲۰/۱۴ % | ۳۶/۳۳ |
|                                                                 | ۲۴/۰۶/۲۰۲۰ | $R^2$ | ۰/۷     | ۰/۲   |
|                                                                 |            | RMSE  | ۳/۰۷    | ۴/۲   |
|                                                                 |            | NRMSE | ۱۱/۲۴ % | ۱۵/۳۸ |
|                                                                 |            | $R^2$ | ۰/۵۶    | ۰/۵۴  |
|                                                                 |            | RMSE  | ۱/۸۱    | ۱/۸۵  |
|                                                                 |            | NRMSE | ۱۰/۹۱ % | ۱۱/۱۸ |
| لتیان                                                           | ۲۶/۰۶/۲۰۲۰ | $R^2$ | ۰/۸۳    | ۰/۴۱  |
|                                                                 |            | RMSE  | ۱/۶۱    | ۲/۵۱  |
|                                                                 | ۲۸/۰۶/۲۰۱۹ | RMSE  |         |       |





شکل ۱۲. نقشه‌های بازسازی شده و واقعی دمای سطح زمین سنجنده ECOSTRESS در حوزه آبخیز لثیان

بنابراین می‌توان نتیجه گرفت مدل‌های با لایه‌های عمیق زیاد در بررسی و مدل‌سازی ویژگی‌های سری زمانی کارآمدتر و با داشتن یک حافظه بلند مدت‌تر عملکرد بهتری را رقم خواهد زد. حتی در صورت درک نادرست شبکه از تاریخچه اخیر خود، شبکه باز قادر خواهد بود با نگاه در 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 می‌گردد؛ مدل LSTM توانست در اغلب تاریخ‌های مذکور و برای هر دو منطقه نتایج مناسب‌تری در مقایسه با روش SVR نشان دهد. مدل LSTM برای منطقه بار-اریه در ۱۷ ژوئن ۲۰۲۰ و در تاریخ ۲۸ ژوئن ۲۰۱۹ برای منطقه لثیان بهترین نتیجه را ارائه نمود. نتایج نشان می‌دهد استفاده از مدل LSTM نسبت به مدل SVR به افزایش کیفیت پیش‌بینی منجر شده است. چرا که در مدل SVR با هدف مدل‌سازی روابط پیچیده و پدیده‌های غیرخطی از توابع کرنل استفاده می‌گردد؛ به عبارتی با تغییر غیرخطی از محیط ورودی به محیطی با ابعاد بیشتر می‌توان با استفاده از تبدیل غیرخطی ویژگی‌های ورودی موردنظر را ابتدا تفکیک و سپس مدل‌سازی نمود. اما با توجه به پراکنش بالای داده‌ها در مبحث رگرسیون و تعداد زیاد داده‌ها، در صورتی که ابرصفحه از تمام داده‌ها در طبقه بندی و مدل‌سازی استفاده نماید؛ مجموعه کلاس‌های هدف دارای همپوشانی خواهند بود. همین امر ممکن است سبب افزایش خطای مدل شود که نتایج حاصله از پژوهش حاضر نیز تاییدکننده این امر بود. درواقع به منظور مدل‌سازی داده‌های سری زمانی به‌ویژه داده‌هایی که با فواصل طولانی نسبت به یکدیگر تهیه و پردازش خواهند شد مدل LSTM بهتر توانست ویژگی و یا شاخص‌های مهم در دنباله ورودی در گام‌های ابتدایی را تشخیص و بسادگی این اطلاعات را طی مسیر طولانی منتقل نماید. همچنین به منظور مدل‌سازی، وابستگی‌های بلندمدت احتمالی را به خوبی دریافت و حفظ می‌نماید و در نهایت یک عملکرد قابل قبول نسبت به مدل SVR از خود نشان داد. با توجه به این امر در تجزیه و تحلیل سری‌های زمانی باید به درک و مدل‌سازی پارامترهای غیرخطی و موثر در رخداد پدیده‌ها پرداخت تا بتوان برای پیش‌بینی مقادیر آینده سری که بر مبنای گذشته صورت می‌گیرند؛ اقدامات مدیریتی مناسب را انجام داد. در مطالعه‌ای حاجی‌زاده طحان و همکاران (۲۰۲۰) قابلیت الگوریتم LSTM را در پیش‌بینی سری‌های زمانی طولانی بررسی کردند که نتایج، حاکی از تایید پژوهش حاضر می‌باشد. همچنین ژانگ و همکاران (۲۰۱۷) و خلیل و همکاران (۲۰۲۲) عملکرد الگوریتم LSTM را به منظور

مدل‌سازی دمای سطح دریا و دمای سطح زمین بررسی کردند که نتایج ایشان نیز در راستای نتایج این پژوهش می‌باشد. با توجه به مطالعه‌ی انجام شده و بررسی عملکرد مدل LSTM در برآورد و بازسازی دمای سطح زمین می‌توان به این نتیجه رسید که مدل LSTM در برآورد دمای سطح زمین سنجنده‌ی ECOSTRESS با آموزش داده‌های MODIS، VIIRS و ECOSTRESS در زمان  $t+2$ ، عملکردی خوب و مناسب داشته که این نشان از دقت مدل در مدل‌سازی دمای سطح زمین می‌باشد. این پژوهش چنین عنوان می‌کند که استفاده از داده‌های ماهواره‌ای می‌تواند باعث صرفه‌جویی در وقت، هزینه و افزایش دقت در تصمیم‌گیری‌های مدیریتی شود. البته نباید فراموش کرد که طبق مطالب گفته‌شده و پژوهش‌های انجام گرفته (Khalil et al., ۲۰۲۲؛ Zhang et al., ۲۰۱۹) مدل دارای پارامترهای فیزیکی می‌باشد که واسنجی پارامترها برای هر حوزه و باتوجه به ماهیت داده‌ها، مورد نیاز می‌باشد. پایش به هنگام دمای سطح زمین در حوزه‌های آبخیز کوهستانی، شهری و دیگر مناطق، ویژگی‌ها و پارامترهای عدیده‌ی متغیرهای موجود در مناطق را نشان می‌دهد. لذا با بهره‌گیری از نقشه‌های دمای سطح زمین به عنوان یکی از پتانسیل‌های موجود حوزه در ارتباط با بهره‌برداری از منابع آب و خاک آن، می‌توان مدیریت مناسب‌تری را اعمال نمود. تصاویر ماهواره‌ای علیرغم مزایا و ویژگی‌های فراوان مانند سهل الوصول بودن، ارائه‌ی محصولات به‌صورت روزانه و ایجاد راهکارهایی مفید برای بررسی متغیرهای اقلیمی، در کاربرد دچار محدودیت‌هایی هستند. اغلب سنجنده‌ها نظیر MODIS، LANDSAT و دیگر سنجنده‌های اپتیکالی با مشکل پوشش ابری گسترده در تصاویر مواجه هستند به‌طوری که گاهی استفاده از این دسته از داده‌ها غیر ممکن می‌شود. بنابراین باتوجه به پیچیدگی‌های مدیریتی خاص هر حوزه و متاثر بودن از متغیرهای فراوان همچنین محدودیت‌هایی که در استفاده از تصاویر سنجنش از دور وجود دارد؛ برای پژوهش‌های مرتبط با برآورد متغیرهایی که اطلاع دقیق از میزان تغییرات آن‌ها در مقیاس روزانه و یا ساعتی مانند دمای هوا، رطوبت خاک، درجه حرارت و غیره استفاده از علم سنجنش از دور و تلفیق تصاویر آن توصیه می‌گردد.

#### ۴- نتیجه‌گیری و پیشنهادات

دمای سطح زمین به عنوان یک مولفه در بسیاری از مطالعات مانند مطالعات بیلان انرژی، تبخیر و تعرق و بسیاری از مطالعات هیدرولوژی مورد استفاده قرار می‌گیرد. در پژوهش حاضر عملکرد مدل LSTM و SVR در بازسازی داده‌های دمای سطح زمین سنجنده ECOSTRESS با استفاده از داده‌های سنجنده‌های MODIS، VIIRS و ECOSTRESS در آبخیز بار- اریه و آبخیز لتیان مورد ارزیابی و بررسی قرار گرفت. نتایج پژوهش نشان داد عملکرد مدل‌ها بجز در یک تاریخ با یکدیگر متفاوت و مدل LSTM در مجموع در هر دو حوضه دارای عملکرد بهتری در بازسازی دمای سطح زمین داشته است که نشان از توانایی بالای LSTM دارد. مدل‌های مورد استفاده از جمله مدل‌های بسیار قوی و پرکاربرد در مدل‌سازی‌های محیطی می‌باشند. مدل SVR یک مدل قوی یادگیری ماشین و مدل LSTM جزو قوی‌ترین مدل‌های یادگیری عمیق است. باید توجه داشت که با توجه به پیچیدگی فرآیند و تعدد عوامل موثر بر دمای سطح زمین نتایج حاصله از دقت و صحت قابل قبولی برخوردارند. تاکید بر این نکته که مدل‌سازی و پیش‌بینی دمای سطح زمین برای ۳ یا ۴ روز بعد انجام شده است (با توجه به فاصله زمانی بین دو تصویر متوالی ECOSTRESS) و اتفاقات پیچیده‌ای که در این مدت می‌تواند به وقوع بپیوندد می‌تواند بر مناسب بودن نتایج و کارایی مدل‌های مورد استفاده صحت بگذارد. توجه به مقادیر  $R^2$  به عنوان معیار استاندارد برای ارزیابی تحلیل‌های رگرسیون، و نیز مقادیر RMSE و NRMSE نشان دهنده توانایی مناسب مدل LSTM در بازسازی مقادیر دمای سطح زمین ECOSTRESS می‌باشد. با توجه به دامنه تغییرات دمای سطح زمین در تاریخ- های مورد مدل‌سازی که بین صفر تا بعضاً نزدیک به ۳۵ درجه سانتیگراد تغییر کرده، مقدار RMSE (که نشان دهنده متوسط خطای مدل است) برای مدل LSTM بین حدود ۱.۵ تا ۳ درجه سانتیگراد بوده که قابل قبول و مناسب به نظر می‌رسد. مقادیر نرمال شده RMSE یا همان NRMSE نیز در اغلب تاریخ‌ها بین ۸ تا ۱۷ درصد

بوده که در مدل سازی های محیطی با توجه به پیچیدگی های بالای فرآیندها مقادیر قابل قبولی می باشند. اما قطعاً به منظور بررسی و پیش بینی سری زمانی قطعاً به الگوریتم های پیش بینی دقیق تر و پیشرفته تری نیاز است. بنابراین تصور می شود استفاده از برخی از پیش پردازش ها مانند موجک و کرولت با توجه به ماهیت کشف ویژگی پیش پردازش های مدنظر از داده های سری زمانی ممکن است مناسب بوده و برای پژوهش های مشابه پیشنهاد می گردد. در واقع پیش پردازش های مذکور، مولفه های مختلف مانند مولفه های فرکانس بالا و فرکانس پایین را از سیگنال اصلی استخراج و به عنوان ورودی در اختیار مدل قرار می دهند که می تواند سبب افزایش عملکرد مدل های داده محور شود.

## منابع

- Anderson, M.C., Yang, Y., Xue, J., Knipper, K. R., Yang, Y., Gao, F. & Rey-Sanchez, C., ۲۰۲۱, Interoperability of ECOSTRESS and Landsat for mapping evapotranspiration time series at sub-field scales. Remote Sensing of Environment, ۲۵۲: ۱۱۲-۱۸۹. <https://doi.org/10.1016/j.rse.2020.112189>
- Dastjerdi, F., Azarakhshi, M., Bashiri, M., ۲۰۱۹, Comparison of Efficiency for Hydrological Models (AWBM & SimHyd) and Neural Network (MLP & RBF) in Rainfall-Runoff Simulation (Case study: Bar Aryeh Watershed -Neyshabur). Jwmseir, ۱۲ (۴۵): ۱۰۷-۱۱۷. [doi: 10.1001/1.20089554.1398.13.45.13.7](https://doi.org/10.1001/1.20089554.1398.13.45.13.7). (in persian).
- Bakhshi, E. & Khalookakaei, R., ۲۰۱۰, Application of Artificial Neural Networks in Remote Sensing, Geomatics Conference, Tehran. <https://civilica.com/doc/102419>
- Dehid Havei, H., ۲۰۲۰, Forecasting Crude Oil Prices Using Improved DeepBelief Network (IDBN) And Long-Term Short-Term Memory Network (LSTM), Imam Reza International University, ۶۳ pages.
- Ebahrami, S., Amir-Ahmadi, A., Habibolahian, M. & ebrahimi M., ۲۰۱۵, 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, ۲۵(۴): ۱۲۵ ۱۴۴. [doi: 10.1001.1.20088362.1393.25.4.8.6](https://doi.org/10.1001.1.20088362.1393.25.4.8.6). (□□ □□□□□□)
- Gerami, Z., Peyrowan, H.R. & Partovi, A., ۲۰۲۲, Introducing suitable places for establishing rainwater catchment systems in Latyan Watershed, Journal of Rainwater Catchment Systems, ۹ (۴): ۳۳-۴۲. [doi: 10.1001.1.24235970.1400.9.4.1.9](https://doi.org/10.1001.1.24235970.1400.9.4.1.9). (□□ □□□□□□)
- Hadadian Sanu, H., Karimi, A., Esfandiapour Borujeni, I., Haqnia Comparing, G., ۲۰۱۵, the efficiency of RMSE and NRMSE to calculate the effective error value of models with different training data sets, The ۱۴th Congress of Soil Sciences of Iran.
- Hajizadeh Tahan, M., Ghasemzadeh, M. & Rezaeian, M., ۲۰۲۰, An evolutionary attention-based deep long short-term memory for time series prediction, Computational Intelligence in Electrical Engineering, ۱۱(۴): ۱۵-۲۸. [Doi: 10.22108/isee.2020.121097.1334](https://doi.org/10.22108/isee.2020.121097.1334). (in persian)
- Hasanlou, M., Jamshidi, M. & Sattari, M., ۲۰۱۸, Urmia Lake Salinity Mapping Using Support Vector Regression and Landsat imagery, Hydrogeomorphology, ۵(۱۴): ۴۳-۶۵. [doi: 10.1001.1.23833254.1397.5.14.3.7](https://doi.org/10.1001.1.23833254.1397.5.14.3.7). (in persian)
- Hejazizadeh, Z. Ziaian, P. & Shirkhani, A., ۲۰۱۳, Estimation of surface temperature using thermal-band data in the west of tehran province and qazvin, geography, ۱۱(۳۸): ۳۳-۴۹. ISSN: ۲۷۸۳-۳۷۳۹. (in persian)
- Jaafar, H., Mourad, R., & Schull, M., ۲۰۲۲, A global ۳۰-m ET model (HSEB) using harmonized Landsat and Sentinel-۲, MODIS and VIIRS: Comparison to ECOSTRESS ET and LST, Remote sensing of environment, ۲۷۴, ۱۱۲۹۹۵. <https://doi.org/10.1016/j.rse.2022.112995>
- Kaffash, M. & Sanaei-Nejad, S.H., ۲۰۲۰, Fusion of MODIS and Landsat-۸ Land Surface Temperature Images Using Spatio-Temporal Image Fusion Model. Iranian Journal of Soil and Water Research, ۵۱(۳): ۷۶۳-۷۷۳, [doi: 10.22059/ijswr.2019.291016.668360](https://doi.org/10.22059/ijswr.2019.291016.668360). (in persian)

Khalil, U., Azam, U., Aslam, B., Ullah, I., Tariq, A., Li, Q. & Lu, L., ۲۰۲۲, Developing a Spatiotemporal Model to Forecast Land Surface Temperature: A Way Forward for Better Town Planning. Sustainability, ۱۴(۱۹): ۱۱۸۷۳. <https://doi.org/10.3390/su141911873>

Kim, H., ۲۰۲۲, Tracing the Origins of Artificial Intelligence: A Kantian Response to McCarthy's Call for Philosophical Help. Kant and Artificial Intelligence, ۱۲۹. [doi: 10.1016/j.yfs.2022.100000](https://doi.org/10.1016/j.yfs.2022.100000). (In book: Kant and Artificial Intelligence)

Li, H., Wu, G., Xu, F. & Li, S., ۲۰۲۱, Landsat-۸ and Gaofen-۱ image-based inversion method for the downscaled land surface temperature of rare earth mining areas, Infrared Physics & Technology, ۱۱۳: ۱۰۳۶۵۸. <https://doi.org/10.1016/j.infrared.2021.103658>

Malik, A., Tikhamarine, Y., Souag-Gamane, D., Kisi, O., & Pham, Q. B. (۲۰۲۰). Support vector regression optimized by meta-heuristic algorithms for daily streamflow prediction. Stochastic Environmental Research and Risk Assessment, ۳۴, ۱۷۵۵-۱۷۷۳. [doi: 10.1007/s00487-020-01874-1](https://doi.org/10.1007/s00487-020-01874-1)

Rawat, K.S., Sehgal, V.K. & Ray, S.S., ۲۰۱۹, Downscaling of MODIS thermal imagery, The Egyptian Journal of Remote Sensing and Space Science, ۲۲(۱): ۴۹-۵۸. <https://doi.org/10.1016/j.ejrs.2018.01.001>

Salehi, H. & Shamsoddini, A., ۲۰۲۱, MODIS and Sentinel-۲ Data Fusion For ۱۰-m Daily Evapotranspiration mapping, Iranian Journal of Irrigation & Drainage, ۱۴(۶): ۱۸۸۱-۱۸۹۲. <https://doi.org/10.22084/ijid.2021.14.6.1881-1892>

Sedighi, F., Vafakhah M. Javadi M R., ۲۰۱۶, Application of Artificial Neural Network for Snowmelt-Runoff (Case Study: Layan Dam Watershed), ۶ (۱۲): ۴۳-۵۴. (in persian)

Shao, Z., Cai, J., Fu, P., Hu, & L. Liu, T., ۲۰۱۹, Deep learning-based fusion of Landsat-۸ and Sentinel-۲ images for a harmonized surface reflectance product, Remote Sensing of Environment, ۲۳۵: ۱۱۱-۴۲۵. <https://doi.org/10.1016/j.rse.2019.111425>

Taei Semiromi, S., Moradi, H. & Khodaghali, M., ۲۰۱۴, Simulation and prediction some of climate variable by using multi line SDSM and Global Circulation Models (Case study: Bar Watershed Nayshabour), Human & Environment, ۱۲(No. ۲۸ Spring ۲۰۱۴), ۱-۱۵. (in persian)

Wang, j., Schmitz, O. Lu, M. & Karssenberg, D., ۲۰۲۰, Thermal unmixing based downscaling for fine resolution diurnal land surface temperature analysis, ISPRS Journal of Photogrammetry and Remote Sensing, ۱۶۱: ۷۶-۸۹. <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., ۲۰۲۰, Sharpening ECOSTRESS and VIIRS land surface temperature using harmonized Landsat-Sentinel surface reflectances, Remote Sensing of Environment, ۲۵۱: ۱۱۲-۵۵. <https://doi.org/10.1016/j.rse.2020.112055>

Yan, S. Understanding LSTM and Its Diagrams. Available online: <https://medium.com/mlreview/understanding-lstm-and-its-diagrams-۳۷e۲f۴۶f۷۱۴> (accessed on ۲۶ June ۲۰۱۸).

Yasrab, R., Pound, M. P., French, A. P., & Pridmore, T. P., ۲۰۲۰, PhenomNet: bridging phenotype-genotype gap: a CNN-LSTM based automatic plant root anatomization system. bioRxiv, ۲۰۲۰-۰۵. <https://doi.org/10.1101/2020.05.03.270184>

Zhang, Q., Wang, H., Dong, J., Zhong, G., & Sun, X., ۲۰۱۷, Prediction of sea surface temperature using long short-term memory, IEEE geoscience and remote sensing letters, ۱۴(۱۰): ۱۷۴۵-۱۷۴۹. DOI: 10.1109/LGRS.2017.2733048