

Research Article



Comparison of LSTM and GRU algorithms in predicting precipitation using historical meteorological data

Iman Ahmadi

Department of Genetics and Plant Production Engineering, Institute of Agriculture, Water, Food and Nutraceuticals, Isf. C., Islamic Azad University, Isfahan, Iran

Corresponding Author email: imanahmadi1358@iau.ac.ir

© The Author (s) 2025

Received: 05 Jun 2025

Revised: 16 Jul 2025

Accepted: 25 Aug 2025

Published: 27 Sep 2025

Extended Abstract

Introduction

Accurate precipitation forecasting is essential across a wide range of applications, including but not limited to agriculture, transportation, urban planning, and disaster preparedness. The ability to anticipate rainfall events with precision allows stakeholders to make informed decisions that can significantly reduce risks and optimize resource allocation. For instance, farmers can adjust irrigation schedules to conserve water and improve crop yields, while transportation authorities can plan routes to avoid delays or accidents caused by adverse weather conditions. This study investigates the comparative performance of two advanced deep learning architectures Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) in predicting daily precipitation events. Both models are designed to handle sequential data and are widely used in time series analysis. By leveraging historical meteorological data from diverse European cities, this research aims to evaluate the strengths and limitations of each architecture in real-world forecasting scenarios.

Materials and Methods

Data Source and Selection

Due to a lack of comprehensive domestic meteorological data, this study used public data from various European cities. The datasets included daily weather variables like temperature, humidity, wind speed, and atmospheric pressure.

Climate Diversity and Station Selection

To ensure model robustness across climates, five meteorologically diverse stations were selected:

- Oslo, Norway – Cold polar climate
- Basel, Switzerland – Central European climate
- Heathrow, England – Temperate oceanic climate
- Budapest, Hungary – Continental climate
- Perpignan, France – Mediterranean climate

Data Preprocessing

For each station, two cleaned CSV files were used:

1. A file of daily meteorological variables.
2. A file indicating daily precipitation occurrence (True/False).

Missing values were handled through interpolation, and features were scaled for model convergence.

Model Implementation

Recurrent Neural Networks (RNNs), specifically LSTM and GRU architectures, were implemented using Python and key libraries (PyTorch, Scikit-learn, Pandas, NumPy). Models were developed in a Jupyter Notebook environment, and hyperparameters were tuned via grid search.

Evaluation Metrics

Model performance was assessed using:

- Confusion Matrix (to calculate Recall, Specificity, Precision, Accuracy)



- ROC Curve
- Precision-Recall Curve

These metrics provided a comprehensive evaluation of the models' predictive power.

Results and Discussion

The models were trained using 80% of each dataset, with the remaining 20% reserved for validation. Training curves indicated consistent convergence across epochs, with a steady decrease in loss and an increase in accuracy.

During training, the LSTM model consistently outperformed the GRU model, demonstrating lower loss values and higher accuracy scores. However, when evaluated using the confusion matrix, both models exhibited comparable predictive performance:

- LSTM: Recall = 0.67, Specificity = 0.84, Precision = 0.75, Accuracy = 0.79
- GRU: Recall = 0.65, Specificity = 0.84, Precision = 0.74, Accuracy = 0.78

Further analysis using ROC and precision-recall curves reinforced LSTM's superior classification capabilities. Notably, the LSTM model trained on Oslo's dataset achieved the highest area under the curve (AUC) values:

- Precision-Recall AUC: 0.89
- ROC AUC: 0.87

These results suggest that LSTM is slightly more effective in capturing complex temporal patterns associated with precipitation events. Additionally, model performance improved significantly with the inclusion of supplementary meteorological features, highlighting the importance of comprehensive and high-quality data inputs.

The findings also reveal that while GRU offers computational efficiency and faster training times, LSTM's ability to retain long-term dependencies gives it a slight edge in accuracy. This trade-off between speed and precision is an important consideration for real-time forecasting systems.

Conclusion

This study underscores the potential of deep learning architectures—specifically LSTM and GRU—in forecasting daily precipitation using historical meteorological data. While both models demonstrated strong predictive capabilities, LSTM consistently delivered marginally better results across multiple evaluation metrics. These findings are consistent with existing literature and affirm the suitability of LSTM for time series forecasting tasks in meteorology.

Keywords: Time series analysis, Confusion matrix, Deep learning, Precipitation prediction

Acknowledgments

The author extends sincere appreciation to the scientific advisors who provided valuable insights throughout the development of this study.

Conflicts of interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Data availability statement

The datasets are available upon a reasonable request to the corresponding author.

Author Contribution

This manuscript was prepared solely by the author.

Citation: Ahmadi, I. (2025). Comparison of LSTM and GRU algorithms in predicting precipitation using historical meteorological data. *Technical Strategies in Water Systems*, 3(2), 101-114.

Publisher: Islamic Azad University, Isfahan Branch



مقایسه الگوریتم‌های LSTM و GRU در پیش‌بینی وقوع بارش با استفاده از داده‌های تاریخی هواشناسی

ایمان احمدی

گروه مهندسی تولید و ژنتیک گیاهی، دانشکده کشاورزی، آب، غذا و فراسودمندا، واحد اصفهان (خوراسگان)، دانشگاه آزاد اسلامی، اصفهان، ایران

ایمیل نویسنده مسئول: imanahmadi1358@iau.ac.ir

© The Author(s) 2025

چاپ: ۱۴۰۴/۰۷/۰۵

پذیرش: ۱۴۰۴/۰۶/۰۳

بازنگری: ۱۴۰۴/۰۴/۲۵

دریافت: ۱۴۰۴/۰۳/۱۵

چکیده

در این مطالعه، مقایسه الگوریتم‌های LSTM و GRU در پیش‌بینی وقوع بارش با استفاده از داده‌های هواشناسی تاریخی مد نظر است. با توجه به عدم دسترسی به داده‌های کامل هواشناسی داخلی چندساله، در این مطالعه از یک پایگاه داده از داده‌های هواشناسی برخی از شهرهای اروپا استفاده شد. پنج ایستگاه هواشناسی که هر کدام متعلق به اقلیم متفاوتی بودند، انتخاب شدند و دقت مدل بر روی داده‌های به‌دست آمده از این ایستگاه‌ها محاسبه شد. در این تحقیق از دو الگوریتم حافظه کوتاه‌مدت بلند (LSTM) و واحد بازگشتی دروازه‌ای (GRU) استفاده شد. برای ارزیابی کارایی مدل‌های توسعه‌یافته در این مطالعه، از معیارهای ماتریس درهم‌ریختگی و نمودارهای مشخصه عملکرد گیرنده (ROC) و دقت-فراخوانی استفاده شد. نتایج به‌دست آمده از تجزیه و تحلیل ماتریس‌های درهم‌ریختگی نشان داد که کارایی دو الگوریتم در پیش‌بینی وقوع بارش تقریباً مشابه است. از نظر عددی، میانگین مقادیر فراخوانی، ویژگی، دقت و صحت الگوریتم LSTM به ترتیب ۰/۶۷، ۰/۸۴، ۰/۷۵ و ۰/۷۹ و مقادیر مربوطه برای الگوریتم GRU به ترتیب ۰/۶۵، ۰/۸۴، ۰/۷۴ و ۰/۷۸ بود. از نظر مقایسه عملکرد این دو الگوریتم، اگرچه با توجه به بالاتر بودن مقادیر بیشتر شاخص‌های ارزیابی کننده مربوط به الگوریتم LSTM نسبت به GRU، به ظاهر الگوریتم LSTM عملکرد بهتری داشته است؛ اما عملکرد کلی آن‌ها از نظر آماری با توجه به عدم وجود اختلاف معنی‌دار بین شاخص‌های ارزیابی کننده مشابه بوده است.

واژه‌های کلیدی: داده‌های سری زمانی، ماتریس درهم‌ریختگی، یادگیری عمیق، پیش‌بینی هواشناسی

استناد: احمدی، ا. (۱۴۰۴). مقایسه الگوریتم‌های LSTM و GRU در پیش‌بینی وقوع بارش با استفاده از داده‌های تاریخی هواشناسی. راهبردهای

فنی در سامانه‌های آبی، ۳(۲): ۱۱۴-۱۰۱

ناشر: دانشگاه آزاد اسلامی واحد اصفهان (خوراسگان)

۱- مقدمه

پیش‌بینی دقیق بارش از مؤلفه‌های بنیادین در مدیریت پایدار منابع آب و کاهش مخاطرات هیدرولوژیکی به‌شمار می‌رود، زیرا نوسانات مکانی و زمانی بارش تأثیر مستقیمی بر تأمین آب شرب، برنامه‌ریزی کشاورزی و تحقق امنیت غذایی جوامع دارد. بارش‌های شدید و غیرمنتظره می‌توانند به وقوع سیلاب، فرسایش خاک و بروز خسارت‌های گسترده اقتصادی و اجتماعی منجر شوند و در این میان، پیش‌بینی به‌موقع و مبتنی بر شواهد علمی نقشی کلیدی در کاهش آسیب‌پذیری و ارتقای تاب‌آوری جوامع ایفا می‌کند. علاوه‌براین، در اقلیم‌های خشک و نیمه‌خشک، اطلاع از زمان‌بندی و شدت بارش برای مدیریت تقاضای آب و بهره‌برداری بهینه از منابع محدود آبی ضرورتی انکارناپذیر محسوب می‌شود. بنابراین پیش‌بینی وقوع و مقدار بارش اهمیت زیادی دارد. طیف متنوعی از پژوهش‌ها در زمینه پیش‌بینی وقوع و مقدار بارش انجام شده است که شامل استفاده از روش‌های عددی (Golding, 2000)، روش‌های بر مبنای برون‌یابی تصاویر راداری (Kim et al., 2009) و روش‌های بر مبنای الگوریتم‌های یادگیری ماشین (Shi et al., 2015) می‌شود.

روش‌های یادگیری ماشین می‌توانند الگوهای پنهان در داده‌های بارندگی تاریخی را آشکار کنند و به‌عنوان یک رویکرد مدلسازی جایگزین برای سامانه‌های غیرخطی و پویا پیشنهاد شده‌اند (Abobakr Yahya et al., 2019). به‌همین دلیل در سال‌های اخیر رویکردهای یادگیری ماشین به‌عنوان جانشینان قدرتمندی برای روش‌های داده‌کاوی سنتی در زمینه پیش‌بینی بارندگی مطرح شده‌اند که نشان‌دهنده شناخت روزافزون قابلیت‌های یادگیری ماشین در مقابله با چالش‌های پیچیده پیش‌بینی الگوهای بارندگی است (Khambra & Shukla, 2023; Patil & Vidyavathi, 2022). روش‌های یادگیری عمیق به‌عنوان زیر مجموعه‌ای از یادگیری ماشین، با استفاده از شبکه‌های عصبی پیچیده الهام گرفته از نورون‌های به‌هم پیوسته مغز انسان، پتانسیل قابل توجهی در افزایش قابلیت‌های پیش‌بینی از خود نشان داده‌اند (Calderaro et al., 2022). این شبکه‌ها قادر هستند الگوها و رابطه‌های پیچیده را در مجموعه داده‌های گسترده تشخیص دهند. این قابلیت به‌ویژه در زمینه‌هایی که داده‌ها دارای ابعاد بالا بوده و رابطه‌های بین ویژگی‌ها غیرخطی هستند، مانند علم آب و هواشناسی ارزشمند است (Indrakumari et al., 2021). ویژگی متمایز کننده روش‌های یادگیری عمیق در مقایسه با روش‌های یادگیری ماشین این است که مدل‌های یادگیری عمیق می‌توانند به‌صورت خودکار ویژگی‌های پیچیده را در داده‌های خام، بدون مهندسی صریح ویژگی‌ها، کشف کنند که در صورت عدم استفاده از روش‌های یادگیری عمیق نیاز به مراجعه به فرد متخصص در حوزه داشته که می‌تواند زمان‌بر باشد (Janiesch et al., 2021). کاربرد یادگیری عمیق در پیش‌بینی بارندگی شامل آموزش شبکه‌های عصبی بر اساس داده‌های اقلیمی تاریخی است. این شبکه‌ها برای شناسایی همبستگی‌های پنهان، روابط غیرخطی و وابستگی‌های زمانی بین متغیرهای حیاتی برای پیش‌بینی بارش طراحی شده‌اند (Ozcanli et al., 2020). در همان زمانی که شبکه عصبی این مجموعه داده‌ها را پردازش می‌کند و از آن‌ها یاد می‌گیرد، شبکه عصبی نمایش داخلی خود را اصلاح کرده و بتدریج آن‌را قادر می‌سازد تا پیش‌بینی‌های دقیق‌تری انجام دهد. روش‌های یادگیری عمیق به‌طور مؤثر از ارتباط متقابل عوامل اقلیمی در پیش‌بینی بارندگی استفاده می‌کنند و متغیرهای متنوعی مانند دما، رطوبت، سرعت باد و فشار اتمسفر را در نظر می‌گیرند و تأثیر ترکیبی آن‌ها را بر الگوهای بارش تشخیص می‌دهند (Kang et al., 2020). در بخش بعد به تعدادی از پژوهش‌های انجام شده در این حوزه اشاره می‌شود. Kim et al. (2020) یک مدل پیش‌بینی وقوع بارندگی با استفاده از شبکه عصبی پیچشی (CNN¹) توسعه دادند. داده‌های ورودی به مدل، داده‌های زمانی- مکانی آب و هوایی بودند و خروجی مدل، پیش‌بینی وقوع بارندگی بود.

¹ Convolutional Neural Network

نتایج حاصل از مدل برای داده‌های به‌دست آمده از سه شهر در کشور ژاپن امیدوار کننده بود و نسبت تشخیص ۷۴-۷۶ درصد به‌دست آمد.

Wang et al. (2021) با استفاده از دو روش یادگیری ماشین و یادگیری عمیق (جنگل تصادفی و شبکه عصبی) به تقسیم‌بندی بارندگی به سه شکل همرفتی عمیق، لایه‌ای و همرفتی کم عمق پرداختند. نتیجه به‌دست آمده حاکی از این بود که ابزارهای یادگیری ماشین برای کاربرد در این زمینه باید به‌دقت ارزیابی شوند و این ابزارها قادر به ارائه راه حل برای همه مسائل مرتبط با داده‌های بزرگ نیستند.

George et al. (2016) با استفاده از یک مدل دوبعدی خطی، مقدار بارش روزانه را بر اساس داده‌های هواشناسی همان روز پیش‌بینی کردند. نتایج نشان داد که مدل قادر است با دقت ۸۷ درصد، مقادیر بارش را پیش‌بینی نماید.

Ghamghami & Bazrafshan (2014) از الگوریتم ویتربی در پیش‌بینی وقوع بارش استفاده کردند. داده‌های ورودی مدل آمارهای به‌دست آمده از ایستگاه سینوپتیک خرم آباد در سال‌های ۱۳۸۳-۱۳۳۹ بود. ویژگی‌های هواشناسی مورد استفاده عبارت بودند از: فشار هوا، فشار بخار آب، دامنه شبانه‌روزی دمای هوا، رطوبت نسبی و نقطه شبنم. هدف پژوهش پیدا کردن بهترین ویژگی هواشناسی در پیش‌بینی وقوع بارش با توجه به معیار دقت پیش‌بینی بود. نتایج نشان داد که ویژگی دامنه شبانه‌روزی دمای هوا به‌عنوان مناسب‌ترین ویژگی در پیش‌بینی وقوع بارش مطرح می‌باشد.

Ramkumar & Thomas (2024) به پیش‌بینی بارش به‌کمک روش‌های یادگیری ماشین پرداختند. آن‌ها برای آموزش مدل‌های یادگیری ماشین از داده‌های هواشناسی دانشگاه کالیفرنیا استفاده کردند. ویژگی‌های استفاده شده در توسعه مدل عبارت بودند از: روز، مکان، دامنه تغییرات دما، رطوبت، سرعت و جهت باد و مقدار تبخیر و تعرق. از بین الگوریتم‌های مورد بررسی، الگوریتم‌های جنگل تصادفی و K نزدیکترین همسایه، ۸۸ درصد در پیش‌بینی وقوع بارش دقت داشتند. Wani et al. (2024) به پیش‌بینی مقدار بارش با به‌کارگیری طیف وسیعی از روش‌های یادگیری ماشین (KNN^1 , ANN^2 , SVR^3 , RF^4) و یادگیری عمیق (RNN^5 , GRU^6 , $LSTM^7$) پرداختند. اثربخشی و دقت الگوریتم‌های پیشنهادی با استفاده از داده‌های هواشناسی از سال ۱۹۸۰ تا سال ۲۰۲۱ ارزیابی شد. نتایج نشان داد که کمترین میانگین مربعات خطا و میانگین خطی مطلق از روش‌های مبتنی بر یادگیری عمیق حاصل شد. در بین روش‌های یادگیری عمیق، روش LSTM بهترین کارایی را در پیش‌بینی مقدار بارش داشت.

Poornima & Pushpalatha (2019) یک شبکه عصبی بازگشتی (RNN) مبتنی بر حافظه بلندمدت تقویت‌شده (LSTM) برای پیش‌بینی بارش معرفی کردند که با استفاده از یک مجموعه داده استاندارد بارش آموزش داده شده و مورد آزمایش قرار گرفت. عملکرد این مدل با استفاده از معیارهایی مانند RMSE، دقت، تعداد دوره‌ها (epochs)، میزان خطا (loss) و نرخ یادگیری ارزیابی شد. برای نشان‌دادن اثربخشی مدل، پژوهشگران نتایج آن را با روش‌های شناخته‌شده‌ای مانند هولت-ویتنرز، ARIMA، ELM، LSTM و RNN مقایسه کردند.

Kagabo et al. (2024) مطالعه‌ای را در زمینه پیش‌بینی رخداد‌های بارش شدید در رواندا با استفاده از الگوریتم‌های یادگیری ماشین انجام دادند. پژوهشگران بیش از ۸۵۰۰۰ داده روزانه بارش از چهار ایستگاه سینوپتیک در سراسر رواندا را که بازه زمانی

¹ k-Nearest Neighbor

² Artificial Neural Network

³ Support Vector Machine

⁴ Random Forest

⁵ Recurrent Neural Network

⁶ Gated Recurrent Unit

⁷ Long Short-Term Memory

۱۹۸۳ تا ۲۰۲۱ را پوشش می‌داد، تحلیل کردند. آن‌ها از تکنیک‌های پیشرفته یادگیری ماشین از جمله شبکه‌های عصبی پیچشی (CNN)، واحدهای بازگشتی دروازه‌دار (GRU) و مدل‌های حافظه بلندمدت (LSTM) بهره گرفتند. نتایج مطالعه نشان داد که مدل LSTM عملکرد بهتری نسبت به سایر الگوریتم‌ها داشته است. آن‌ها بر پتانسیل مدل‌های مبتنی بر LSTM برای تقویت تاب‌آوری در برابر خطرات طبیعی و بهبود راهبردهای آمادگی در رواندا تأکید کردند؛ کشوری که با چالش‌های جدی ناشی از بلایای طبیعی مکرر مانند سیل مواجه است.

به‌طور کلی در مسئله پیش‌بینی بارش دو رویکرد پیش‌بینی وقوع بارش و پیش‌بینی مقدار بارش وجود دارد که اولی یک مسئله دسته‌بندی و دومی یک مسئله رگرسیونی است. هدف از پژوهش حاضر پیش‌بینی وقوع بارش به‌صورت روزانه با استفاده از داده‌های چندین ساله دارای چندین ویژگی هواشناسی است، بنابراین در این پژوهش با یک مسئله دسته‌بندی دو کلاسه مواجه هستیم. از آنجا که تاکنون در مقاله‌های داخلی از مدل‌های یادگیری عمیق بر مبنای الگوریتم‌های GRU و LSTM در پیش‌بینی وقوع بارش استفاده نشده است، بنابراین نو بودن این مقاله به استفاده از این دو الگوریتم یادگیری عمیق در پیش‌بینی وقوع بارش برمی‌گردد.

۲- مواد و روش‌ها

- به‌علت عدم دسترسی به داده‌های هواشناسی کامل چندین ساله داخلی، در این پژوهش از پایگاه داده‌ای داده‌های هواشناسی برخی از شهرهای قاره اروپا استفاده شد (Klein Tank et al., 2002). داده‌های مورد استفاده به‌صورت فایل CSV تنظیم شده بودند که در برگیرنده تعدادی از ویژگی‌های هواشناسی روزانه در دوره زمانی سال ۲۰۰۰ تا ۲۰۰۹ میلادی بود. ویژگی‌های هواشناسی مورد استفاده عبارت بودند از: تاریخ، ماه میلادی، پوشش ابر، سرعت باد، شدت باد، فشار، تابش جهانی، دوره تابش مستقیم آفتاب، میانگین دما، حداقل دما، حداکثر دما و مقدار بارش. پس از بررسی داده‌ها از نظر عدم وجود داده از دست رفته و عدم تغییر نوع داده‌های موجود در هر ستون فایل CSV، ویژگی مقدار بارش به متغیر هدف وقوع/عدم وقوع بارش تبدیل شد به‌طوری‌که در صورت غیر صفر بودن مقدار بارش، ویژگی وقوع بارش True و در غیر این‌صورت False در نظر گرفته شد.

- به‌منظور پژوهش راجع به میزان تأثیر اقلیم‌های متفاوت روی دقت مدل‌های پیش‌بینی وقوع بارش، پنج ایستگاه هواشناسی که هر یک متعلق به یک اقلیم بود انتخاب شده و دقت مدل روی داده‌های حاصل از این ایستگاه‌ها محاسبه شد. پنج ایستگاه هواشناسی شامل ایستگاه اسلو کشور نروژ به‌عنوان ایستگاه دارای آب و هوای سرد قطبی، ایستگاه باسل کشور سوئیس به‌عنوان ایستگاه دارای آب و هوای اروپای مرکزی، ایستگاه هدرو کشور انگلستان به‌عنوان ایستگاه دارای آب و هوای معتدل اقیانوسی، ایستگاه بوداپست کشور مجارستان به‌عنوان ایستگاه دارای آب و هوای اروپای شرقی و ایستگاه پریگنان کشور فرانسه به‌عنوان ایستگاه دارای آب و هوای معتدل مدیترانه‌ای بودند.

- داده‌های هر یک از ایستگاه‌های هواشناسی به دو فایل CSV تقسیم شد که یکی شامل ویژگی‌های روزانه آب و هواشناسی و دیگری شامل تابع هدف وقوع / عدم وقوع بارش در روز متناظر به‌صورت True / False بود. این فایل‌ها در مسیر کاری نرم‌افزار ایجاد کننده مدل قرار داده شد.

- از آنجا که در این پژوهش توسعه مدل‌های بر مبنای یادگیری عمیق مورد نظر است و از سوی دیگر داده‌های ورودی به مدل از جنس سری زمانی هستند، بنابراین مدل‌های بر مبنای الگوریتم شبکه عصبی بازگشتی (RNN) مناسب به‌نظر می‌رسند. در نتیجه در این پژوهش از دو الگوریتم حافظه کوتاه مدت بلند (LSTM) و واحد بازگشتی دروازه‌ای (GRU) استفاده شد. در ادامه توضیحاتی راجع به این الگوریتم‌ها داده شده است. شبکه‌های عصبی بازگشتی (RNN) برای پردازش داده‌های ترتیبی استفاده می‌شوند که در آن‌ها ترتیب عناصر برای توسعه مدل بسیار مهم است. آن‌ها در کارهایی مانند پردازش زبان طبیعی، تشخیص گفتار و تحلیل سری‌های

زمانی عالی هستند زیرا از طریق حلقه‌های بازخورد، «حافظه‌ای» از ورودی‌های گذشته را حفظ می‌کنند و به آن‌ها اجازه می‌دهند روابط بین عناصر را در یک توالی درک کنند.

LSTM و GRU انواع تخصصی شبکه‌های عصبی بازگشتی (RNN) هستند که برای حل مشکل محو شدن گرادیان در RNN‌های سنتی طراحی شده‌اند و آن‌ها را قادر می‌سازند تا وابستگی‌های دوربرد را در داده‌های متوالی به‌طور مؤثرتری مدیریت کنند. هر دو معماری از مکانیسم‌های دروازه‌ای برای کنترل جریان اطلاعات استفاده می‌کنند، اما GRU ساختار LSTM را ساده‌تر می‌کند و آن‌را از نظر محاسباتی کارآمدتر می‌سازد. LSTM‌ها برای مدیریت داده‌های ترتیبی با وابستگی‌های بلندمدت طراحی شده‌اند، به این معنی که می‌توانند اطلاعات مربوط به مراحل قبلی یک توالی را به‌خاطر بسپارند و از آن برای تأثیرگذاری بر بخش‌های بعدی توالی استفاده کنند. هر دو معماری می‌توانند عملکرد خوبی داشته باشند، اما LSTM ممکن است برای کارهایی که نیاز به ثبت وابستگی‌های بسیار دوربرد دارند، مناسب‌تر باشد، در حالی که GRU می‌تواند جایگزین خوبی برای زمانی باشد که منابع محاسباتی محدود هستند.

- برای استقرار مدل‌ها از دستورات کتابخانه‌های Torch, Torchvision, Torchaudio, Pandas, Numpy, Scikit-Learn, Matplotlib, Seaborn زبان برنامه‌نویسی python استفاده شد و کدنویسی در محیط Jupyter Notebook انجام شد.

- برای ارزیابی کارایی مدل‌های توسعه یافته در این پژوهش از معیارهای ماتریس درهم ریختگی^۱ و نمودارهای ویژگی عملکرد گیرنده^۲ و دقت-فراخوانی^۳ استفاده شد. منحنی ویژگی عملکرد گیرنده (ROC) یک نمایش گرافیکی از عملکرد یک طبقه‌بندی‌کننده دودویی در آستانه‌های مختلف طبقه‌بندی است. این منحنی، نرخ مثبت واقعی (TPR) را در مقابل نرخ مثبت کاذب (FPR) در آستانه‌های مختلف رسم می‌کند. این ابزار بصری به ارزیابی میزان تمایز یک مدل بین دو کلاس (مثلاً مثبت/منفی، درست/غلط) کمک می‌کند. یک طبقه‌بندی‌کننده خوب، منحنی‌ای خواهد داشت که به سمت گوشه بالا سمت چپ نمودار خم می‌شود و نشان‌دهنده TPR بالا و FPR پایین است. هرچه منحنی به گوشه بالا سمت چپ نزدیک‌تر باشد، توانایی مدل در تمایز بین دو کلاس بهتر است.

منحنی دقت-فراخوانی (منحنی PR) یک نمایش گرافیکی از عملکرد یک طبقه‌بندی‌کننده دودویی است که بده‌بستان بین دقت و فراخوانی را در تنظیمات آستانه مختلف نشان می‌دهد. این منحنی به‌ویژه هنگام مواجهه با مجموعه داده‌های نامتوازن، که در آن یک کلاس نمونه‌های خیلی کمتری نسبت به کلاس دیگر دارد، مفید است. مساحت زیر منحنی PR یک عدد است که عملکرد طبقه‌بندی‌کننده را خلاصه می‌کند. مساحت بیشتر نشان‌دهنده عملکرد بهتر است. یک منحنی PR خوب، دقت و فراخوانی بالایی خواهد داشت (در حالت ایده‌آل منحنی به نقطه (۱،۱) یعنی گوشه بالای سمت راست نمودار تمایل دارد).

۳- نتایج و بحث

۳-۱- آمار توصیفی به‌دست آمده از ویژگی‌های هواشناسی ایستگاه‌های مورد مطالعه

جدول (۱) آمار توصیفی مربوط به ویژگی‌های هواشناسی پنج ایستگاهی که از داده‌های آن‌ها برای توسعه مدل استفاده شده است را نشان می‌دهد:

^۱ Confusion Matrix

^۲ Receiver-Operating Characteristic

^۳ Precision-Recall

جدول ۱- تعدادی از شاخص‌های آماری مربوط به ویژگی‌های هواشناسی ایستگاه‌های مورد نظر در این پژوهش

Table 1. A number of statistical indicators related to the meteorological characteristics of the weather stations considered in this study

شاخص آماري مرکزي	ایستگاه	سرعت باد (متر بر ثانيه)	شدت باد (متر بر مجدور ثانيه)	رطوبت هوا (درصد اعشاري)	فشار هوا (آتمسفر) (وات بر متر مربع)	تابش جهاني (وات بر متر مربع)	تابش خورشيد (ساعت)	پوشش ابر (اکتاز)	میانگین دما (درجه سانتيگراد)	دماي کمينه (درجه سانتيگراد)	دماي بيشينه (درجه سانتيگراد)
میانگین	Basel	-	-	۰/۷۴	۱/۰۲	۱/۳۵	۴/۷۱	۵/۴	۱۱/۱۱	۷/۰۶	۱۵/۶۵
	Budapest	-	-	۰/۶۵	۱/۰۲	۱/۴۸	۵/۸۱	۴/۷۸	۱۲/۲۹	-	۱۶/۷۶
	Heathrow	-	-	۰/۷۶	۱/۰۲	۱/۳۱	۴/۴۷	۵/۲۷	۱۱/۹	۸/۰۶	۱۵/۷۳
	Oslo	۲/۶۶	۹/۱	۰/۷۲	۱/۰۱	۱/۰۶	۴/۹	۵/۶	۷/۳۲	۳/۹۴	۱۱/۱۸
	Perpignan	۴/۶۸	-	۰/۶۵	۱/۰۲	۱/۷۳	-	-	۱۶/۱۲	۱۱/۶۹	۲۰/۵۴
انحراف معیار	Basel	-	-	۰/۱۱	۰/۰۱	۰/۹۳	۴/۳۴	۲/۳۳	۷/۴۱	۴/۶۴	۸/۷۱
	Budapest	-	-	۰/۱۵	۰/۰۱	۰/۹۸	۴/۴۷	۲/۳۹	۸/۷۴	-	۹/۹۸
	Heathrow	-	-	۰/۱	۰/۰۱	۰/۸۸	۳/۹۹	۲/۰۱	۵/۵۹	۵/۲۱	۶/۳۶
	Oslo	۱/۳۶	۳/۴۷	۰/۱۵	۰/۰۱	۰/۹۸	۴/۸۹	۲/۱۶	۷/۹۶	۷/۴۷	۸/۹۶
	Perpignan	۲/۶۵	-	۰/۱۵	۰/۰۱	۰/۹۴	-	-	۶/۴۷	۶/۳۷	۶/۹۷
میان	Basel	-	-	۰/۷۶	۱/۰۲	۱/۱۴	۳/۶	۶	۱۱/۶	۷/۴	۱۶
	Budapest	-	-	۰/۶۵	۱/۰۲	۱/۳۶	۶	۵	۱۳/۱	-	۱۷/۷
	Heathrow	-	-	۰/۷۶	۱/۰۲	۰/۹۸	۳/۷	۶	۱۱/۸	۸/۳	۱۵/۵
	Oslo	۲/۴	۸/۷	۰/۷۵	۱/۰۱	۰/۷۲	۴	۶	۷/۲	۳/۹	۱۱/۱
	Perpignan	۳/۹	-	۰/۶۵	۱/۰۲	۱/۵۹	-	-	۱۶	۱۱/۶	۲۰/۴
نما	Basel	-	-	۰/۸	۱/۰۲	۰/۳۳	۰	۷	۱۷/۲	۶/۴	۲۰/۱
	Budapest	-	-	۰/۵۹	۱/۰۲	۰/۱۸	۰	۸	۲۰/۴	-	۲۲/۴
	Heathrow	-	-	۰/۷۸	۱/۰۲	۰/۱۲	۰	۶	۱۷/۴	۹/۳	۱۲/۹
	Oslo	۱/۹	۸/۷	۰/۸۸	۱/۰۱	۰/۰۴	۰	۸	۲/۴	-۱	۶/۶
	Perpignan	۲/۶	-	۰/۵۸	۱/۰۲	۰/۹۵	-	-	۱۶/۲	۸/۹	۱۴/۳
کشیدگی	Basel	-	-	۰/۳۲	۰/۵۱	۰/۹۳	۰/۹۵	۰/۵۹	۰/۷۷	۰/۷	۰/۸۲
	Budapest	-	-	۰/۶۵	۰/۴۹	۰/۲۴	۰/۱۳	۰/۱۰۱	۰/۹۳	-	۰/۱۰۱
	Heathrow	-	-	۰/۴۷	۰/۴۵	۰/۶۹	۰/۵۷	۰/۱	۰/۷۳	۰/۷۳	۰/۵۸
	Oslo	۲/۴۶	۰/۵۴	۰/۵۶	۰/۲۲	۰/۶۸	۰/۲۳	۰/۶۴	۰/۷۴	۰/۵۸	۰/۸۷
	Perpignan	۰/۴۹	-	۰/۷۹	۱/۱	۰/۰۹	-	-	۰/۸۹	۰/۷۸	۰/۷۹
چولگی	Basel	-	-	۰/۳۹	۰/۱۱	۰/۵۲	۰/۵۶	۰/۷۳	۰/۱۴	۰/۲۲	۰/۰۶
	Budapest	-	-	۰/۰۹	۰/۱۹	۰/۲۷	۰/۱۱	۰/۳۵	۰/۱۷	-	۰/۱۶
	Heathrow	-	-	۰/۲۹	۰/۴	۰/۶۳	۰/۶۴	۰/۷۳	۰	۰/۱۹	۰/۱۴
	Oslo	۱/۱۸	۰/۶۲	۰/۵۶	۰/۱۲	۰/۷۵	۰/۸۶	۰/۶۴	۰/۱۳	۰/۲۴	۰/۰۳
	Perpignan	۱/۰۴	-	۰/۰۷	۰/۳۵	۰/۲۵	-	-	۰	۰/۱۴	۰/۰۵
دامنه تغییرات	Basel	-	-	۰/۶	۰/۰۶	۳/۵	۱۵/۳	۸	۳۷	۳۵/۵	۴۴/۳
	Budapest	-	-	۰/۷۴	۰/۰۵	۳/۴۵	۱۴/۹	۸	۴۲	-	۴۶/۷
	Heathrow	-	-	۰/۵۸	۰/۰۷	۳/۳۷	۱۵/۵	۸	۳۱/۲	۲۷/۴	۳۷/۷
	Oslo	۱۱	۲۵/۸	۰/۷۶	۰/۰۹	۳/۵۲	۲۴	۸	۴۳/۵	۴۱/۴	۴۸/۶
	Perpignan	۱۵/۵	-	۰/۷۵	۰/۰۵	۳/۶۳	-	-	۳۲/۴	۳۲/۲	۳۶/۹
بیشینه	Basel	-	-	۰/۹۸	۱/۰۴	۳/۵۵	۱۵/۳	۸	۲۹	۲۰/۸	۳۸/۶
	Budapest	-	-	۱	۱/۰۴	۳/۴۹	۱۴/۹	۸	۳۳/۱	-	۴۰/۱
	Heathrow	-	-	۱	۱/۰۴	۳/۴۹	۱۵/۵	۸	۲۹	۲۰/۶	۳۷/۶
	Oslo	۱۱	۲۷/۳	۱	۱/۰۵	۳/۵۳	۲۴	۸	۲۵/۴	۲۰/۷	۳۳
	Perpignan	۱۶/۳	-	۰/۹۷	۱/۰۴	۳/۶۶	-	-	۳۱/۸	۲۶/۳	۳۸/۲
کمینه	Basel	-	-	۰/۳۸	۰/۹۹	۰/۰۵	۰	۰	-۸	-۱۴/۷	-۵/۷
	Budapest	-	-	۰/۲۶	۰/۹۹	۰/۰۴	۰	۰	-۸/۹	-	-۶/۶
	Heathrow	-	-	۰/۴۲	۰/۹۷	۰/۱۲	۰	۰	-۲/۲	-۶/۸	-۰/۲
	Oslo	۰	۱/۵	۰/۲۴	۰/۹۶	۰/۰۱	۰	۰	-۱۸/۱	-۲۰/۷	-۱۵/۶
	Perpignan	۰/۸	-	۰/۲۲	۰/۹۸	۰/۰۳	-	-	-۰/۶	-۵/۹	۱/۳

۳-۲- نتایج مربوط به کارکرد الگوریتم‌های LSTM و GRU در پیش‌بینی وقوع بارش در ایستگاه‌های پنج‌گانه

کارکرد الگوریتم‌ها به این شکل است که ابتدا مدل روی داده‌های قرار گرفته در ۸۰ درصد اول داده‌های تاریخی آموزش می‌بیند و پس از توسعه مدل، کارایی آن روی ۲۰ درصد داده‌های قرار گرفته در انتهای سری زمانی آزمون می‌شود. شکل (۱) نمودارهای تابع هزینه و صحت پیش‌بینی را در جریان آموزش مدل در طول ۱۰۰ دوره آموزشی نشان می‌دهد. همان‌طور که مشخص است در تمام مدل‌ها فرآیند آموزش به‌خوبی پیش‌رفته است چون نمودارهای تابع هزینه با افزایش شماره دوره آموزشی روند کاهشی و نمودارهای صحت پیش‌بینی با افزایش شماره دوره آموزشی روند افزایشی دارد. از سوی دیگر در تمام حالت‌ها نمودارهای مربوط به الگوریتم LSTM نسبت به GRU کارکرد بهتری در مرحله آموزش داشته است، چون نمودارهای LSTM مربوط به تابع هزینه پایین‌تر از نمودار GRU قرار گرفته‌اند و نمودارهای LSTM مربوط به صحت پیش‌بینی در مرحله آموزش بالاتر از نمودارهای GRU قرار گرفته‌اند. شکل (۲) ماتریس‌های درهم‌ریختگی مربوط به الگوریتم‌های LSTM و GRU را در هر یک از ایستگاه‌های پنج‌گانه نشان می‌دهد. با استفاده از ماتریس‌های درهم‌ریختگی امکان قرائت مقادیر TP، FN، FP، TN و سپس محاسبه معیارهای فراخوانی، اختصاصیت، دقت و صحت با استفاده از روابط $\text{recall} = \text{TP}/(\text{TP} + \text{FN})$ ، $\text{specificity} = (\text{TN})/(\text{TN} + \text{FP})$ ، $\text{precision} = \text{TP}/(\text{TP} + \text{FP})$ و $\text{accuracy} = (\text{TP} + \text{TN})/(\text{TP} + \text{TN} + \text{FP} + \text{FN})$ فراهم می‌شود که نتایج حاصل در جدول (۲) آورده شده است:

جدول ۲- مقادیر TP، FN، TN، FP و معیارهای فراخوانی، اختصاصیت، دقت و صحت مربوط به الگوریتم‌های LSTM و GRU در هر یک از ایستگاه‌های پنج‌گانه

Table 2. True Positive (TP), False Positive (FP), True Negative (TN), and False Negative (FN) values, as well as recall, specificity, precision, and accuracy metrics for the LSTM and GRU algorithms across the five meteorological stations

ایستگاه	الگوریتم GRU								الگوریتم LSTM			
	FN	FP	TN	TP	صحت	دقت	اختصاصیت	حساسیت	FN	FP	TN	TP
Basel	۹۲	۹۸	۲۹۰	۲۴۰	۰/۷۴	۰/۷۱	۰/۷۵	۰/۷۲	۸۱	۹۲	۲۹۶	۲۵۱
Budapest	۱۰۳	۵۰	۴۴۶	۱۲۱	۰/۷۹	۰/۷۱	۰/۹	۰/۵۴	۹۲	۶۱	۴۳۵	۱۳۲
Heathrow	۸۵	۷۷	۲۶۹	۲۸۹	۰/۷۸	۰/۷۹	۰/۷۸	۰/۷۷	۹۵	۶۴	۲۸۲	۲۷۹
Oslo	۸۰	۵۸	۲۹۹	۲۸۳	۰/۸۱	۰/۸۳	۰/۸۴	۰/۷۸	۷۱	۶۷	۲۹۰	۲۹۲
Perpignan	۱۰۵	۴۱	۴۸۹	۸۵	۰/۸	۰/۶۷	۰/۹۲	۰/۴۵	۱۰۰	۳۵	۴۹۵	۹۰

با توجه به نتایج جدول (۲)، کارایی دو الگوریتم LSTM و GRU در پیش‌بینی بارش تقریباً مشابه است و آزمون t جفت شده اختلاف معناداری را بین آن‌ها از نظر چهار شاخص ارزیابی نشان نداد. مقادیر به‌دست‌آمده با نتایج پژوهش‌های مشابه همخوانی دارد. به‌عنوان مثال، در پژوهش‌های Ramkumar & Thomas (2024) و Kim et al. (2020) به‌ترتیب صحت‌های حدود ۸۸٪ و ۷۳٪ و نسبت تشخیص ۶۴-۷۴٪ گزارش شده است. برای انتخاب بهتر مدل دسته‌بند دوکلاسه، استفاده از نمودارهای ROC و Precision-Recall توصیه می‌شود.

شکل (۳) نمودارهای ROC و Precision-Recall دو الگوریتم LSTM و GRU را برای هر پنج ایستگاه مورد مطالعه نمایش می‌دهد.

شکل ۱- نمودارهای تابع هزینه و صحت پیش‌بینی در جریان آموزش مدل‌ها




Fig 1. Graphs of the cost function and prediction accuracy during the training process of the models

شکل ۲- ماتریس‌های درهم‌ریختگی به‌دست آمده در این پژوهش




Fig 2. The confusion matrices derived from this research

شکل ۳- نمودارهای ROC و Precision-Recall به‌دست آمده در این پژوهش




Fig 3. Receiver Operating Characteristic (ROC) and precision-recall curves derived from this research

هر چه عدد مشخصه (سطح زیر منحنی) مربوط به نمودارهای ROC و Precision-Recall به ۱ نزدیکتر باشد، به معنای کارایی بهتر دسته‌بند در جداسازی دو کلاس است، بنابراین می‌توان این نتیجه را به دست آورد که اولاً الگوریتم LSTM کارایی نسبی بهتری نسبت به GRU داشته است (لازم به ذکر است که از نظر آماری و با انجام آزمون t جفت شده، اختلاف معنی‌داری بین این دو الگوریتم از نظر سطح زیر منحنی هر کدام از نمودارهای مورد مطالعه وجود نداشت) و ثانیاً با افزایش تعداد ویژگی‌های مورد استفاده در توسعه مدل کارایی آن بهبود یافته است، به دلیل اینکه نمودارهای مربوط به ایستگاه Oslo که از ۱۲ ویژگی بهره می‌برد کارایی بهتری نسبت به نمودارهای حاصل از ایستگاه‌های Heathrow و Basel که از ۱۰ ویژگی استفاده کرده‌اند، داشته است و عملکرد مدل‌های مربوط به این دو ایستگاه از عملکرد مدل‌های به دست آمده از ایستگاه‌های Budapest و Perpignan که در توسعه آن‌ها از ۹ ویژگی استفاده شده است، بهتر بوده است. نتایج به دست آمده از پژوهش (Poornima and Pushpalatha (2019) حاکی از برتری الگوریتم LSTM بر دیگر مدل‌های مورد تحقیق در آن پژوهش بود. از نظر عددی صحت الگوریتم LSTM در پیش‌بینی مقدار بارش بالاتر از ۸۷٪ بود در حالیکه مدل‌های دیگر صحت پایین‌تر از ۸۰٪ را نتیجه دادند. در پژوهش (Kagabo et al. (2024 که راجع به پیش‌بینی وقوع بارش‌های شدید در کشور رواندا بود، صحت به دست آمده از الگوریتم‌های LSTM و GRU مشابه بودند، هرچند از نظر عددی صحت‌های به دست آمده بالاتر از پژوهش حاضر و معادل ۹۹/۷٪ بود.

به منظور توجیه کردن مشابهت نتایج حاصل از این دو الگوریتم ذکر این مطلب لازم است که LSTM و GRU دو نوع شبکه عصبی بازگشتی (RNN) هستند که برای حل مشکل محو شدن گرادیان در RNN‌های سنتی طراحی شده‌اند. آن‌ها قادرند تا وابستگی‌های دوربرد را در داده‌های متوالی به طور مؤثرتری مدیریت کنند. هر دو معماری از مکانیسم‌های دروازه‌ای برای کنترل جریان اطلاعات استفاده می‌کنند، اما GRU ساختار LSTM را ساده‌تر می‌کند و آن‌را از نظر محاسباتی کارآمدتر می‌سازد. بنابراین می‌توان انتظار داشت به علت مشابهت ساختار، کارایی این دو الگوریتم در انجام پیش‌بینی‌ها نیز مشابه باشد.

۴- نتیجه‌گیری

در این پژوهش با استفاده از دو الگوریتم پردازش داده‌های تاریخی هواشناسی یعنی LSTM و GRU، وقوع بارش به صورت روزانه پیش‌بینی شد. از نظر مقایسه کارایی این دو الگوریتم این نتیجه به دست آمد که هر چند الگوریتم LSTM در زمینه‌هایی به صورت نسبی برتر از الگوریتم GRU عمل کرد، که این نتیجه‌گیری به بالاتر بودن مقادیر عددی شاخص‌های ارزیابی‌کننده الگوریتم LSTM در مقایسه با الگوریتم GRU برمی‌گردد، اما به طور کلی و با توجه به عدم وجود اختلاف معنی‌دار بین دو الگوریتم از نظر تمام شاخص‌های ارزیابی‌کننده، کارایی آن‌ها شبیه هم بود.

سپاسگزاری

با سپاسگزاری صمیمانه از مشاوران علمی که در طول انجام این مطالعه، بینش‌های ارزشمندی ارائه نمودند.

تضاد منافع نویسندگان

نویسنده این مقاله اعلام می‌دارد که هیچ تضاد منافعی در رابطه با نویسندگی و یا انتشار این مقاله ندارد.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

این نسخه خطی منحصراً توسط نویسنده تهیه شده است.

منابع

Abobakr Yahya, A. S., Ahmed, A. N., Binti Othman, F., Ibrahim, R. K., Afan, H. A., El-Shafie, A., ... & Elshafie, A. (2019). Water quality prediction model-based support vector machine model for ungauged river catchment under dual scenarios. *Water*, 11(6), 1231. <http://doi.org/10.3390/w11061231>

- Calderaro, J., Seraphin, T. P., Luedde, T., & Simon, T. G. (2022). Artificial intelligence for the prevention and clinical management of hepatocellular carcinoma. *Journal of Hepatology*, 76, 1348–1361. <http://doi.org/10.1016/j.jhep.2022.01.014>
- George, J., Letha, J., & Jairaj, P. G. (2016). Daily rainfall prediction using generalized linear bivariate model – A case study. *Procedia Technology*, 24, 31–38. <http://doi.org/10.1016/j.protcy.2016.05.006>
- Ghamghami, M., & Bazrafshan, J. (2014). Application of Viterbi's algorithm for predicting rainfall occurrence and simulating wet/dry spells – Comparison with common methods. *Journal of Water and Soil*, 28(5), 1048–1060. <http://doi.org/10.22067/jsw.v0i0.25613>. (In Persian)
- Golding, B. W. (2000). Quantitative precipitation forecasting in the UK. *Journal of Hydrology*, 239, 286–305. [http://doi.org/10.1016/S0022-1694\(00\)00354-1](http://doi.org/10.1016/S0022-1694(00)00354-1)
- Indrakumari, R., Poongodi, T., & Singh, K. (2021). Introduction to deep learning. In *Advanced Deep Learning for Engineers and Scientists: A Practical Approach* (pp. 1–22). http://doi.org/10.1007/978-3-030-66519-7_1
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31, 685–695. <http://doi.org/10.1007/s12525-021-00475-2>
- Kagabo, J., Kattel, G. R., Kazora, J., Shangwe, C. N., & Habiakare, F. (2024). Application of machine learning algorithms in predicting extreme rainfall events in Rwanda. *Atmosphere*, 15(6), 691. <http://doi.org/10.3390/atmos15060691>
- Kang, J., Wang, H., Yuan, F., Wang, Z., Huang, J., & Qiu, T. (2020). Prediction of precipitation based on recurrent neural networks in Jingdezhen, Jiangxi Province, China. *Atmosphere*, 11, 246. <http://doi.org/10.3390/atmos11030246>
- Khambra, G., & Shukla, P. (2023). Novel machine learning applications on fly ash-based concrete: An overview. *Materials Today: Proceedings*, 80, 3411–3417. <http://doi.org/10.1016/j.matpr.2021.07.262>
- Kim, S., Suzuki, T., & Tachikawa, Y. (2020). Rainfall occurrence prediction with convolutional neural network. *Journal of Japan Society of Civil Engineering, Ser. B1 (Hydraulic Engineering)*, 76(2), 379–384. http://doi.org/10.2208/jscejhe.76.2_I_379
- Kim, S., Tachikawa, Y., Sayama, T., & Takara, K. (2009). Ensemble flood forecasting with stochastic radar image extrapolation and a distributed hydrologic model. *Hydrological Processes*, 23(4), 597–611. <http://doi.org/10.1002/hyp.7188>
- Klein Tank, A. M., Wijngaard, J. B., Können, G. P., Böhm, R., Demarée, G., Gocheva, A., ... & Petrovic, P. (2002). Daily dataset of 20th-century surface air temperature and precipitation series for the European Climate Assessment. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 22(12), 1441–1453. <http://doi.org/10.1002/joc.773>
- Ozcanli, A. K., Yaprakdal, F., & Baysal, M. (2020). Deep learning methods and applications for electrical power systems: A comprehensive review. *International Journal of Energy Research*, 44, 7136–7157. <http://doi.org/10.1002/er.5331>
- Patil, S. S., & Vidyavathi, B. (2022). A machine learning approach to weather prediction in wireless sensor networks. *International Journal of Advanced Computer Science and Applications*, 13(1). <http://doi.org/10.14569/IJACSA.2022.0130131>
- Poornima, S., & Pushpalatha, M. (2019). Prediction of rainfall using intensified LSTM-based recurrent neural network with weighted linear units. *Atmosphere*, 10(11), 668. <http://doi.org/10.3390/atmos10110668>
- Ramkumar, P., & Thomas, R. (2024). Prediction of rainfall using machine learning algorithms. *International Journal of Advance Research and Innovative Ideas in Education*, 10(5), 874–878. <http://doi.org/10.16415/IJARIIE-25040>
- Shi, X., Chen, Z., Wang, H., Yeung, D., Wong, W., & Woo, W. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Proceedings of the 28th NIPS*. <http://doi.org/10.48550/arXiv.1506.04214>
- Wang, J., Wong, R. K. W., Jun, M., Schumacher, C., Saravanan, R., & Sun, C. (2021). Statistical and machine learning methods applied to the prediction of different tropical rainfall types. *Environmental Research Communications*, 3, 111001. <http://doi.org/10.1088/2515-7620/ac371f>
- Wani, O. A., Mahdi, S. S., Yeasin, M., Kumar, S. S., Gagnon, A. S., Danish, F., Al-Ansari, N., El Hendawy, S., & Mattar, M. A. (2024). Predicting rainfall using machine learning, deep learning, and time series models across an altitudinal gradient in the North-Western Himalayas. *Scientific Reports*, 14, 27876. <http://doi.org/10.1038/s41598-024-27876-4>