

## تخمین بارش با استفاده از داده ماهواره‌ای و مدل یادگیری عمیق برای نواحی مرکزی ایران

سیدعباس میرحسینی<sup>۱</sup>، ابوالحسن غیبی<sup>۲\*</sup>، محمدحسین معماریان<sup>۳</sup>، الهام عباسی<sup>۴</sup>

<sup>۱</sup> دانشجوی دکتری هواشناسی، گروه علوم غیرزیستی جوی و اقیانوسی، دانشگاه هرمزگان، بندرعباس، ایران

<sup>۲</sup> ابوالحسن غیبی، دانشیار گروه فیزیک، دانشکده علوم پایه، دانشگاه هرمزگان، بندرعباس، ایران

<sup>۳</sup> محمدحسین معماریان، دانشیار، بخش اتمی و مولکولی، دانشکده فیزیک، دانشگاه یزد، یزد، ایران

<sup>۴</sup> الهام عباسی، استادیار، بخش علوم کامپیوتر، دانشکده ریاضی، دانشگاه یزد، یزد، ایران

تاریخ دریافت: ۱۴۰۴/۱۰/۱۷، تاریخ پذیرش: ۱۴۰۴/۱۱/۲۶

### چکیده

برآورد بارش با روش‌های سنتی به‌ویژه در رخدادهای همرفتی و رگباری معمولاً با خطای قابل توجه همراه است. به منظور افزایش دقت برآورد بارش، ترکیب داده‌های ماهواره‌ای و داده‌های بازتحلیل با روش یادگیری عمیق مورد استفاده قرار گرفت. در این پژوهش مدل U شکل مبتنی بر توجه توسعه یافت که ورودی آن دمای روشنایی ساعتی چند کاناله ماهواره‌های نسل دوم متئوست و خروجی آن داده‌های بازتحلیل نسل پنجم مربوط به سطح خشکی (ERA5-Land) در بازه‌ی زمانی ۲۰۱۹ تا ۲۰۲۲ با وضوح زمانی یک‌ساعته و وضوح مکانی ۰/۱ درجه بود. برای بهبود عملکرد مدل، از نسخه‌ای بهبود یافته و وزن‌دهی شده‌ی تطبیقی تابع زیان هوبر استفاده شد که با ترکیب مزایای توابع میانگین مربعات خطا و میانگین قدرمطلق خطا، پایداری بیشتری در برابر داده‌های بارشی حدی ایجاد می‌کند. همچنین به منظور انتقال اطلاعات بین مسیرهای رمزگذار و رمزگشا و حذف ویژگی‌های غیرضروری، از سازوکار دروازه توجه استفاده شد که همانند یک فیلتر هوشمند تنها ویژگی‌های مرتبط با پیش‌بینی بارش را عبور می‌دهد. بعد از آموزش، مدل توانست میانگین خطای مطلق را برابر با ۰/۳۹ میلی‌متر، ریشه میانگین مربعات خطا را ۰/۸۶۲ میلی‌متر و ضریب همبستگی را ۰/۸۰ به دست آورد و همبستگی مکانی مطلوبی با داده‌های ERA5-Land نشان دهد. این پژوهش در محدوده جغرافیایی ۲۸/۵ تا ۳۵/۵ درجه شمالی و ۵۲ تا ۵۹ درجه شرقی انجام شده است. نتایج کلی نشان می‌دهد رویکرد ترکیبی داده‌های چندمنبع و معماری توسعه یافته مدل U شکل مبتنی بر توجه، به‌عنوان ابزاری مؤثر برای پیش‌بینی بارش، به‌ویژه در مناطق فاقد شبکه ایستگاهی، می‌تواند مورد استفاده قرار گیرد.

کلمات کلیدی: تخمین بارش، داده‌های بازتحلیل، دمای روشنایی، شبکه عصبی پیچشی، رویکرد نوین یادگیری عمیق

## مقدمه

تخمین دقیق و به موقع بارش، یکی از ارکان حیاتی در مدیریت منابع آب، پیش‌بینی سیلاب‌ها و مطالعات تغییرات اقلیمی به شمار می‌رود. روش‌های سنتی متکی بر مجموعه داده ایستگاهی، به‌رغم دقت نسبی، با چالش‌های بنیادینی مواجه هستند. از جمله این چالش‌ها و محدودیت‌ها پراکندگی ناهمگون ایستگاه‌ها در مناطق کوهستانی یا صحرائی، تأخیر زمانی در جمع‌آوری داده‌ها و ناتوانی در پایش پیوسته پهنه‌های وسیع به‌ویژه در نواحی فاقد زیرساخت می‌باشد. این محدودیت‌ها، محققان را به سمت بهره‌گیری از داده‌های سنجش از دور سوق داده است که با پوشش فضایی-زمانی گسترده و تکرارپذیری بالا، امکان رصد دینامیک ابرها را در مقیاس‌های مختلف فراهم می‌کنند. با این حال، ماهیت پیچیده و غیرخطی فرایندهای بارش‌زایی، از تشکیل ابر تا ریزش باران و تأثیرپذیری آن از عوامل جوی چندلایه مانند رطوبت، دمای جو و زمین و میزان ناپایداری جو، مدل‌سازی ارتباط بین سیگنال‌های ماهواره‌ای و بارش سطحی را به مسئله‌ای چالش‌برانگیز تبدیل کرده است.

پیشینه تحقیق با روش‌های آماری و فیزیکی در تخمین بارش

تخمین دقیق بارش همواره به عنوان یکی از چالش‌های اصلی در علوم جوی و آب‌شناسی مطرح بوده است. در دهه‌های گذشته، روش‌های آماری و فیزیکی متعددی برای برآورد بارش از داده‌های ماهواره‌ای توسعه یافته‌اند. لویزانی و همکاران (۲۰۰۲) در یک مطالعه مروری جامع، روش‌های تخمین بارش مبتنی بر ماهواره را بررسی کردند و نشان دادند که مجموعه داده ماهواره‌ای مرئی (VIS)، فروسرخ (IR) و مایکروویو (MW) هر کدام مزایا و محدودیت‌های خاص

خود را دارند. به عنوان مثال، داده‌های فروسرخ به دلیل پوشش وسیع و پیوسته، برای پایش بارش در مقیاس جهانی مناسب هستند، اما در تشخیص بارش‌های سبک و تفکیک ابرهای بارشی از غیربارشی دقت کمتری دارند. در مقابل، داده‌های مایکروویو اگرچه دقت بالاتری در تخمین بارش ارائه می‌دهند، اما به دلیل وابستگی به ماهواره‌های مدار پایین، از نظر پوشش زمانی محدودیت دارند.

جنیفر و همکاران<sup>۱</sup> (۲۰۱۰) در مطالعه‌ای در حوضه آبریز ماکانا در تانزانیا، از ترکیب مجموعه داده نسل دوم ماهواره متئوست (MSG<sup>۲</sup>) و ماهواره TRMM<sup>۳</sup> برای تخمین بارش استفاده کردند. نتایج آن‌ها نشان داد که این روش ترکیبی می‌تواند با ضریب همبستگی ۰/۸۰، جایگزین مناسبی برای بارش زمینی در مناطق با شبکه مشاهداتی پراکنده باشد. این مطالعه همچنین تأکید کرد که دقت تخمین بارش در مقیاس‌های ماهانه و فصلی به طور قابل توجهی بیشتر از مقیاس روزانه است.

در ایران، طارمی و همکاران (۲۰۲۰) عملکرد الگوریتم تخمین بارش بر حسب رطوبت خاک (SM2Rain) را برای تخمین بارش از مجموعه داده رطوبت خاک سنجنده ASCAT<sup>۴</sup> در دو منطقه نیمه‌خشک (خراسان رضوی) و مرطوب (مازندران) ارزیابی کردند. یافته‌های آن‌ها نشان داد که این الگوریتم در مناطق نیمه‌خشک با ضریب همبستگی ۰/۷۰ عملکرد بهتری دارد در حالی که در مناطق مرطوب، افزودن تبخیر-تعرق به مدل باعث بهبود ۱۰ تا ۱۸ درصدی دقت می‌شود. این مطالعه بر اهمیت تطبیق روش‌های فیزیکی با شرایط اقلیمی محلی تأکید کرد.

<sup>۳</sup> Tropical Rainfall Measuring Mission

<sup>۴</sup> Advanced Scatterometer

<sup>۱</sup> Jeniffer et al.

<sup>۲</sup> Meteosat Second Generation

دارند و می‌توانند برای تفکیک ابرهای بارشی از غیربارشی با دقت ۸۳/۸ درصد استفاده شوند.

جمع‌بندی این مطالعات نشان می‌دهد که اگرچه روش‌های آماری و فیزیکی در تخمین بارش، پیشرفت‌های قابل توجهی داشته‌اند، اما همچنان چالش‌هایی مانند کم‌برآوردی بارش‌های شدید، وابستگی به کالیبراسیون زمینی و محدودیت در تفکیک مکانی وجود دارد. این محدودیت‌ها انگیزه‌ای برای توسعه روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق در سال‌های اخیر بوده است.

پیشینه تحقیق با روش‌های مبتنی بر شبکه‌های عصبی مصنوعی در تخمین بارش

شبکه‌های عصبی مصنوعی به عنوان یکی از ابزارهای قدرتمند در مدل‌سازی غیرخطی سیستم‌های پیچیده جوی، تحول چشمگیری در تخمین و پیش‌بینی بارش ایجاد کرده‌اند. ابهیشک و همکاران<sup>۸</sup> (۲۰۱۲) در مطالعه‌ای نشان دادند که معماری‌های مبتنی بر شبکه عصبی با توابع فعال‌سازی Tan-Sigmoid و الگوریتم بهینه‌ساز لونیبرگ-مارکواریت (LM) می‌توانند با ضریب همبستگی ۰/۹۶ و خطای MSE<sup>۹</sup> برابر با ۰/۰۴۴ برای پیش‌بینی پارامترهای هواشناسی مانند دمای بیشینه استفاده شوند. این پژوهش تأکید کرد که افزایش تعداد نوروهای لایه پنهان تا حد بهینه می‌تواند دقت مدل را بهبود بخشد، اما افزودن لایه‌های بیشتر ممکن است منجر به بیش‌برازش شود.

در زمینه پیش‌بینی بارش روزانه، ویراسینگه<sup>۱۰</sup> و همکاران (۲۰۱۰) با استفاده از داده‌های ۳۰ ساله ۱۰ ایستگاه

ارزیابی محصولات عملیاتی بارش ماهواره‌ای نیز موضوع مطالعات متعددی بوده است. نگوین و همکاران<sup>۱</sup> (۲۰۱۸) با مقایسه خانواده محصولات PERSIANN<sup>۲</sup>، (PERSIANN-CCS<sup>۳</sup>, CDR<sup>۴</sup>، PERSIANN)، دریافتند که PERSIANN-CDR به دلیل تصحیح بایاس با پایگاه داده بارش اقلیمی جهانی، کمترین خطای سیستماتیک را دارد، اما در بارش‌های شدید تمایل به کم‌برآوردی نشان می‌دهد. این یافته‌ها با نتایج بهبودیان و همکاران (۱۳۹۵) در استان‌های تهران و البرز نیز همخوانی دارد.

عبداللهی و همکاران (۱۳۹۶) در حوضه گرگانرود، عملکرد دو محصول CMORPH<sup>۵</sup> و TRMM 3B42RT را ارزیابی کردند و دریافتند که CMORPH در مقیاس‌های ماهانه و فصلی با ضریب همبستگی ۰/۹۳ از دقت بالاتری برخوردار است، اما هر دو محصول تمایل به کم‌برآوردی بارش دارند. این محدودیت در مطالعه مسعودیان و همکاران (۱۳۹۳) نیز تأیید شده است.

در سال‌های اخیر، خوارزمی و همکاران (۱۴۰۱) با استفاده از مجموعه داده دمای روشنایی سنجنده SEVIRI<sup>۶</sup>، ماهواره متئوست، مدل رگرسیون فرایند گاوسی نمایی را برای تخمین بارش در استان هرمزگان توسعه دادند. این مدل با RMSE<sup>۷</sup> برابر ۰/۴۴ و احتمال تشخیص ۰/۹۶، عملکرد بهتری نسبت به شبکه‌های عصبی مصنوعی نشان داد. غیبی و همکاران (۲۰۲۲) نیز با تحلیل مجموعه داده ماهواره متئوست تأیید کردند که کانال‌های مرئی (۰/۶ و ۰/۸ میکرومتر) بیشترین همبستگی را با بارش

<sup>۶</sup> pinning Enhanced Visible and Infrared Imager

<sup>۷</sup> Root Mean Square Error

<sup>۸</sup> Abhishek et al.

<sup>۹</sup> Mean Absolute Error

<sup>۱۰</sup> Virasinghe et al.

<sup>۱</sup> Nguyen et al.

<sup>۲</sup> Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks

<sup>۳</sup> PERSIANN-CCS (Cloud Classification System)

<sup>۴</sup> PERSIANN-CDR (Climate Data Record)

<sup>۵</sup> Climate Prediction Center MORPHing Technique

۰/۹۶ به دست آمد. در مقابل، برای ایستگاه دزفول، شبکه عصبی پرسپترون چندلایه با ساختار ۱-۴-۳-۶ نورون در لایه‌ها نتایج مطلوب‌تری نسبت به سایر پیکربندی‌ها نشان داد. یافته‌های این مطالعه بر نقش تعیین‌کننده نرمال‌سازی داده‌ها و انتخاب توپولوژی مناسب شبکه بر اساس ویژگی‌های اقلیمی و منطقه‌ای در بهبود دقت مدل‌های پیش‌بینی بارش تأکید دارد.

نگوین و همکاران (۲۰۲۱) در مطالعه‌ای نوآورانه از شش پارامتر هواشناسی، دما، دمای شبنم، رطوبت، فشار، دید و سرعت باد به عنوان ورودی شبکه عصبی برای پیش‌بینی بارش روزانه و ماهانه استفاده کردند. مدل توسعه‌یافته آن‌ها به ضریب همبستگی ۰/۸ برای پیش‌بینی روزانه و ماهانه دست یافت. این پژوهش نشان داد که مدل شبکه عصبی می‌تواند روابط پیچیده بین متغیرهای جوی و بارش را حتی با حجم محدودی از داده‌های آموزشی شناسایی کند.

رستم‌زاده و همکاران (۱۳۸۹) در ارزیابی تطبیقی دو پایگاه داده ماهواره‌ای TRMM و GPM با رادار داپلر در غرب ایران دریافته‌اند که اگرچه همبستگی بین مجموعه داده ماهواره‌ای و زمینی نسبتاً کم است، ضریب تعیین در حدود ۰/۲۲ تا ۰/۲۵، اما پس از اعمال تصحیحات مبتنی بر مدل‌های شبکه عصبی، این همبستگی به طور قابل توجهی بهبود می‌یابد. این یافته‌ها اهمیت ادغام روش‌های شبکه عصبی با داده‌های سنجش از دور را برای افزایش دقت تخمین بارش نشان می‌دهد.

این مطالعات نشان می‌دهد که شبکه‌های عصبی مصنوعی به دلیل توانایی در مدل‌سازی روابط غیرخطی و پیچیده بین متغیرهای جوی، گزینه مناسبی برای تخمین بارش هستند. با این حال، چالش‌هایی مانند نیاز به حجم زیاد

هواشناسی در سریلانکا، دو مدل شبکه عصبی را توسعه دادند: یکی برای طبقه‌بندی وقوع بارش و دیگری برای پیش‌بینی مقدار بارش. نتایج نشان داد که مدل‌های شبکه عصبی می‌توانند وقوع بارش را با دقت در حدود ۷۹ درصد پیش‌بینی کنند، اما دقت در مناطق خشک به‌ویژه برای بارش‌های شدید کاهش می‌یابد. این مطالعه همچنین نشان داد که استفاده از روش‌های فازی می‌تواند دقت پیش‌بینی مقادیر ناچیز بارش (Trace) را تا حدود ۸۰ درصد بهبود بخشد.

سوبهاجینی<sup>۱</sup> (۲۰۱۸) در یک مطالعه مقایسه‌ای با عنوان پیش‌بینی روزانه برخی از پارامترهای جوی مانند دما، رطوبت در هند، پنج نوع مختلف از شبکه عصبی شامل شبکه عصبی پس‌خور خطا، تابع پایه شعاعی، رگرسیون عمومی، شبکه عصبی نوری و فازی-عصبی را ارزیابی کرد. یافته‌های این پژوهش نشان داد که شبکه فازی-عصبی با دقت ۹۷/۸۵ درصد بهترین عملکرد را دارد، در حالی که شبکه عصبی پس‌خور خطا با دقت ۸۲/۴ درصد کمترین دقت را نشان داد. این تفاوت عمدتاً ناشی از توانایی شبکه عصبی-فازی در پردازش داده‌های غیرخطی و حفظ همزمان سرعت یادگیری بالا بود.

در ایران، گلابی و همکاران (۱۳۹۲) به مقایسه عملکرد دو معماری شبکه عصبی، شامل پرسپترون چندلایه و شبکه عصبی تابع پایه شعاعی، با الگوریتم‌های یادگیری مختلف در پیش‌بینی بارش فصلی ایستگاه‌های استان خوزستان پرداختند. نتایج این پژوهش نشان داد که در ایستگاه اهواز، شبکه عصبی تابع پایه شعاعی با به‌کارگیری الگوریتم لونبرگ-مارکوارت و ساختار ۱-۴-۶ نورون در لایه‌ها، بهترین عملکرد را ارائه کرده است، به گونه‌ای که مقدار میانگین مربعات خطا برابر با ۰/۰۴۴ و ضریب همبستگی

<sup>۱</sup> Subhajini

داده‌های آموزشی، حساسیت به انتخاب پارامترها و ویژگی‌های اولیه و مشکل تعمیم‌پذیری به مناطق مختلف همچنان وجود دارد. این محدودیت‌ها موجب شده تا در سال‌های اخیر، توجه پژوهشگران به سمت معماری‌های پیشرفته‌تر مانند یادگیری عمیق معطوف شود.

پیشینه تحقیق با روش‌های مبتنی بر یادگیری عمیق در تخمین بارش

یادگیری عمیق با ارائه معماری‌های جدید، انقلابی در زمینه تخمین بارش از مجموعه داده سنجش از دور ایجاد کرده است. تائو و همکاران<sup>۱</sup> (۲۰۱۶) مدلی مبتنی بر خودرمزگذار حذف نوفه انباشته (PERSIANN-SDAE<sup>2</sup>) برای کاهش بایاس در محصولات بارش ماهواره‌ای معرفی کردند. نتایج نشان داد که این روش به‌طور مؤثر بایاس را کاهش داده و توانایی مدل در تصحیح بارش‌ها را بهبود می‌بخشد. همچنین، مدل یادگیری عمیق قادر به تصحیح بارش‌ها در مناطق مختلف با استفاده از تصاویر ماهواره‌ای بود.

تائو (۲۰۱۷) در رساله دکتری خود، یک مدل مبتنی بر یادگیری عمیق برای تخمین بارش از داده‌های ماهواره‌ای دوطیفی فروسرخ و بخار آب ارائه دادند. این مدل از یک چارچوب دو مرحله‌ای شامل طبقه‌بندی دودویی بارش/بدون بارش و تخمین مقدار بارش استفاده می‌کند. نتایج نشان داد که این مدل دو مرحله‌ای عملکرد بهتری نسبت به مدل‌های پایه مانند PERSIANN-CCS در دوره‌های مختلف و در رویدادهای خاص در مرکز ایالات متحده داشت.

صادقی و همکاران (۲۰۱۹) با توسعه مدل PERSIANN-CNN<sup>3</sup> نشان دادند که شبکه‌های

عصبی پیچشی می‌توانند با استخراج خودکار ویژگی‌های مکانی از تصاویر ماهواره‌ای زمین ثابت، دقت تخمین بارش را در مقایسه با روش‌های مرسوم به‌طور چشمگیری بهبود دهند. نتایج این پژوهش حاکی از آن است که مدل پیشنهادی در شاخص موفقیت بحرانی بهبودی معادل ۵۴ درصد و در شاخص ریشه میانگین مربعات خطا کاهش ۳۷ درصدی را نسبت به سایر محصولات خانواده PERSIANN نشان می‌دهد. این بهبود عملکرد عمدتاً ناشی از توانایی شبکه‌های عصبی پیچشی در شناسایی الگوهای محلی و ساختارهای فضایی مرتبط با ابرهای بارشی عنوان شده است.

موراکس و همکاران<sup>۴</sup> (۲۰۱۹) با ارائه یک چارچوب یادگیری عمیق چندوظیفه‌ای مبتنی بر معماری ساعت‌شنی (Encoder-Decoder)، کارایی ادغام داده‌های چندمنبعی را در تخمین بارش به‌خوبی نشان دادند. در این پژوهش، ترکیبی از تصاویر حرارتی سنجنده MSG-SEVIRI در سه باند طیفی (۸/۷، ۸/۸ و ۱۲/۰ میکرومتر)، اطلاعات توپوگرافی و مشاهدات باران‌سنجی به‌عنوان ورودی مدل مورد استفاده قرار گرفت. نتایج نشان داد که مدل پیشنهادی به دقت احتمال تشخیص به میزان ۰/۷۵ و خطای RMSE برابر با ۱/۶ میلی‌متر بر ساعت دست یافته است. یافته‌های این مطالعه به‌طور روشن بر برتری رویکردهای چندورودی و چندمنبعی نسبت به روش‌های مبتنی بر یک منبع داده در برآورد بارش تأکید دارد.

در ادامه، صادقی و همکاران (۲۰۲۰) با معرفی و توسعه معماری‌های مبتنی بر U-Net گامی مهم در بهبود تخمین مکانی بارش برداشتند. آن‌ها نشان دادند که افزودن اطلاعات جغرافیایی شامل عرض و طول جغرافیایی به‌عنوان

<sup>3</sup> Convolutional Neural Network

<sup>4</sup> Moraux et al.

<sup>1</sup> Tao et al.

<sup>2</sup> Stacked Denoising Autoencoder

وو و همکاران<sup>۳</sup> (۲۰۲۰) با تلفیق یادگیری عمیق و یادگیری گسترده (Broad Learning System - BLS)، یک سامانه ترکیبی ارائه کردند که دقت کلی پیش‌بینی طبقه‌بندی‌شده بارش را به ۸۵ درصد رساند. این مدل در شناسایی بارش‌های شدید (کلاس‌های ۴ و ۵) عملکرد بهتری نسبت به مدل LSTM<sup>۴</sup> خالص از خود نشان داد، به طوری که مقدار دقت (Precision) برابر با ۴۷ درصد و بازخوانی (Recall) برابر با ۳۵ درصد به دست آمد. این یافته‌ها بیانگر اهمیت بهره‌گیری هم‌زمان از معماری‌های یادگیری مختلف در بهبود تشخیص رخدادهای حدی بارش است.

کو و همکاران<sup>۵</sup> (۲۰۲۲) با ارائه یک چارچوب پیش‌آموزش خودنظارتی و به‌کارگیری تابع زیان متوازن مبتنی بر معماری U-Net، به بهبود پیش‌بینی کوتاه‌مدت بارش به صورت طبقه‌بندی سه‌سطحی و نیز برآورد پیوسته بارش از داده‌های راداری پرداختند. روش پیشنهادی با استفاده از داده‌های هفت‌ساله کشور کره جنوبی، شاخص موفقیت بحرانی بارش‌های سنگین (بیش از ۱۰ میلی‌متر بر ساعت) را در افق پیش‌بینی ۵ ساعته تا ۹۵/۷ درصد افزایش داد و هم‌زمان خطای برآورد بارش‌های خفیف را حدود ۱۰/۷ درصد کاهش داد. این پژوهش نقش مؤثر یادگیری خودنظارتی و مدیریت عدم تعادل داده‌ها را در حوزه هواشناسی محاسباتی برجسته می‌سازد.

خلأهای پژوهشی و نوآوری تحقیق حاضر

با وجود پیشرفت‌های قابل توجه در تخمین بارش با استفاده از داده و اطلاعات ماهواره‌ای، مطالعات پیشین در ایران با محدودیت‌های مهمی مواجه بوده‌اند که عمدتاً ناشی

کانال‌های کمکی در ورودی شبکه، منجر به بهبود قابل توجه عملکرد مدل می‌شود؛ به طوری که شاخص موفقیت بحرانی حدود ۷۳ درصد افزایش یافته و ضریب همبستگی نسبت به مدل پایه PERSIANN-CCS حدود ۸۵ درصد بهبود پیدا کرده است. همچنین، نتایج این پژوهش حاکی از آن است که مدل پیشنهادی در بازسازی الگوهای مکانی بارش، به‌ویژه در رخدادهای حدی و شدید نظیر طوفان هاروی (۲۰۱۷)، از دقت و توان پیش‌بینی بالاتری نسبت به روش‌های مرسوم برخوردار است.

وانگ و همکاران<sup>۱</sup> (۲۰۲۱) با بهره‌گیری از یادگیری انتقالی، مدل IPEC<sup>۲</sup>-V2 را در گام نخست با استفاده از داده‌های ماهواره‌های زمین‌ثابت بر فراز ایالات متحده آموزش دادند و سپس آن را با داده‌های ماهواره‌های FengYun در کشور چین سازگار کردند. نتایج نشان داد که این راهبرد موجب افزایش ضریب همبستگی از ۰/۱۶ به ۰/۲۸ و کاهش RMSE از ۱/۰ به ۰/۸۲ میلی‌متر بر ساعت نسبت به مدل‌های پایه در مقیاس سراسر چین شده است. این پژوهش راهکاری عملی و مؤثر برای برآورد بارش در مناطقی با کمبود داده‌های زمینی ارائه می‌دهد.

در سال‌های اخیر، پیشرفت‌های قابل توجهی به سمت مدل‌های ادغام داده‌های چندمنبعی مشاهده می‌شود. افضل‌ی و همکاران (۲۰۲۲) در مدل Deep-STEP با ترکیب داده‌های مایکروویو سنجنده GMI و داده‌های فرسوخ با وضوح مکانی ۴ کیلومتر، و با انجام تحلیل اهمیت ویژگی‌ها، نشان دادند که کانال‌های ۳۶/۶ و ۸۹ گیگاهرتز بیشترین تاثیر را در بهبود دقت تخمین بارش دارند. این نتایج نقش کلیدی داده‌های مایکروویو پرفرکانس را در برآورد کمی بارش تأیید می‌کند.

<sup>۴</sup> Long Short-Term Memory

<sup>۵</sup> Ko et al.

<sup>۱</sup> Wang et al.

<sup>۲</sup> IR Precipitation Estimation using CNN

<sup>۳</sup> Wu et al.

درجه به عنوان داده‌ی مرجع استفاده شده است. این مجموعه داده که حاصل تلفیق بهینه‌ی مشاهدات زمینی، راداری و خروجی مدل عددی مرکز اروپایی پیش‌بینی میان‌مدت جوی (ECMWF<sup>2</sup>) است، از قابلیت اطمینان بالایی برخوردار بوده و به‌طور گسترده در مطالعات هیدرولوژیکی و هواشناسی به عنوان داده مرجع مورد استفاده قرار می‌گیرد. نوآوری اصلی این تحقیق در ترکیب هوشمندانه این مجموعه داده با معماری پیشرفته یادگیری عمیق Attention U-Net است که برای اولین بار امکان تخمین دقیق بارش در ایران مرکزی را با تفکیک زمانی یک‌ساعته فراهم می‌سازد. این رویکرد نه تنها مشکل کمبود داده زمینی با وضوح زمانی مناسب را تا حدودی حل می‌کند، بلکه راهکاری عملی برای مناطق با داده‌های نامتوازن ارائه می‌دهد. نتایج این مطالعه کاربردهای گسترده‌ای در سیستم‌های پایش و پیش‌بینی بارش، مدیریت منابع آب و مطالعات خشکسالی دارد. به‌ویژه، این روش می‌تواند مبنایی برای توسعه سیستم‌های هشدار سیل و مدیریت بهینه منابع آب در حوضه‌های آبریز کم‌داده ایران مرکزی باشد. این پژوهش گامی مهم در بهبود دقت تخمین بارش در مناطق مرکزی ایران محسوب می‌شود و الگویی برای مطالعات مشابه در دیگر مناطق با شرایط اقلیمی مشابه ارائه می‌دهد.

### مواد و روش‌ها

این پژوهش از مجموعه‌های داده ماهواره‌ای و زمینی با وضوح زمانی ساعتی و وضوح مکانی ۰/۱ درجه در محدوده جغرافیایی ۲۸/۵ تا ۳۵/۵ درجه شمالی و ۵۲ تا ۵۹ درجه شرقی شکل (۱)، طی روزهای منتخبی از سال‌های ۲۰۱۹ تا ۲۰۲۲ بهره برده است. انتخاب این بازه زمانی با هدف دسترسی پیوسته به داده‌های باکیفیت، همگنی زمانی مجموعه داده‌ها و تمرکز بر توسعه و ارزیابی رفتار یادگیری

از تمرکز بر محصولات جهانی مانند GPM، TRMM یا PERSIANN بوده است. این محصولات به دلیل فاصله مداری ماهواره GOES<sup>1</sup> (فاصله بیش از ۱۰۰ درجه از منطقه مورد مطالعه) و محدودیت‌های وضوح مکانی ماهواره، دقت کافی برای مناطق ایران مرکزی را ندارند. علاوه بر این، فقدان داده‌های زمینی با تفکیک زمانی مناسب (یک‌ساعته) در این مناطق و مشکل مجموعه داده بارش بسیار نامتوازن، چالش‌های اساسی در توسعه مدل‌های یادگیری عمیق دقیق ایجاد کرده است. در این پژوهش، برای غلبه بر این چالش‌ها، راهکارهای نوآورانه متعددی ارائه شده است. نخست، از معماری پیشرفته Attention U-Net با بهبودهای اساسی شامل توابع زیان ترکیبی و روش‌های وزن‌دهی مناسب و استفاده شده است که توانایی قابل توجهی در مدیریت مجموعه داده‌های بارش نامتوازن از خود نشان می‌دهد. این معماری به‌طور خاص برای حل مشکل تخمین بارش‌های نادر که در مناطق خشک و نیمه‌خشک ایران مرکزی شایع است، طراحی شده است. در بخش مجموعه داده‌های ورودی و خروجی مدل، در این تحقیق از دو منبع اصلی داده استفاده شده است؛ نخست، داده‌های ماهواره MSG با وضوح زمانی یک‌ساعته و وضوح مکانی حدود ۰/۰۳ درجه به کار گرفته شده‌اند. موقعیت مداری مناسب این ماهواره (۴۱/۵ درجه طول شرقی) امکان پایش پیوسته و دقیق منطقه ایران را فراهم می‌کند و آن را به منبعی کارآمد برای استخراج اطلاعات مرتبط با سامانه‌های بارشی تبدیل می‌سازد. دوم، با توجه به پراکندگی نامناسب ایستگاه‌های هواشناسی، کمبود داده‌های ایستگاهی قابل اعتماد و همچنین نیاز مدل‌های یادگیری عمیق به داده‌های پیوسته و منظم در فضا و زمان، از مجموعه داده‌ی ERA5-Land با وضوح مکانی ۰/۱

<sup>2</sup> European Centre for Medium-Range Weather Forecasts

<sup>1</sup> Geostationary Operational Environmental Satellites

و زمان، از مجموعه داده بازتحلیل ERA5-Land با وضوح زمانی یک ساعته و تفکیک مکانی ۰/۱ درجه که توسط مرکز اروپایی پیش‌بینی میان‌مدت هواشناسی تولید شده است، به عنوان داده مرجع استفاده شد. این محصول که از تلفیق مشاهدات زمینی و خروجی مدل‌های عددی پیش‌بینی به دست آمده، امکان دستیابی به یک مجموعه داده منظم و شبکه‌بندی شده از بارش ساعتی را فراهم می‌کند. داده‌های مورد نیاز از طریق آدرس <https://cds.climate.copernicus.eu/datasets/rea-nalysis-era5-land> دریافت شده‌اند.

#### روش پژوهش

این پژوهش با هدف توسعه یک مدل تخمین بارش ساعتی با دقت بالا و قابلیت کاربرد عملیاتی در مناطق با داده‌های زمینی محدود انجام شده است. رویکرد اصلی مطالعه، ترکیب داده‌های چندطیفی ماهواره‌ای با معماری‌های پیشرفته یادگیری عمیق به منظور غلبه بر چالش‌های اساسی تخمین بارش، به‌ویژه در رخدادهای بارش شدید و نامتوازن، است.


مدل انجام شده و شامل طیف متنوعی از شرایط بارشی، از دوره‌های خشک تا رخدادهای همرفتی و بارش‌های نسبتاً شدید، می‌باشد.

#### مجموعه داده ماهواره‌ای

داده ماهواره‌ای مورد استفاده در این پژوهش، شامل تصاویر و یا ماتریس‌های رادیانس (Radiance) با ابعاد  $205 \times 242$  از چهار کانال طیفی در محدوده طول موج‌های فروسرخ شامل  $10/8$ ،  $12$ ، و  $13/4$  میکرومتر هستند؛ که اطلاعات ارزشمندی درباره ساختار فیزیکی، ضخامت، ارتفاع و دمای قله‌ی ابرها فراهم می‌کنند. داده‌های ماهواره‌ای با وضوح زمانی یک‌ساعته و وضوح مکانی حدود  $0/03$  درجه از پایگاه <https://www.eumetsat.int> اخذ شد.

#### مجموعه داده زمینی

با توجه به پراکندگی نامناسب ایستگاه‌های هواشناسی، کمبود داده‌های ایستگاهی قابل اعتماد و همچنین نیاز مبرم مدل‌های یادگیری عمیق به داده‌های پیوسته و منظم در فضا



شکل ۱. محدوده جغرافیایی مورد مطالعه در این پژوهش

## مدل‌سازی

فراهم‌سازی مجموعه داده فیزیکی قابل تفسیر برای ورودی مدل یادگیری عمیق بود.

جدول ۱. طول موج و عدد موج کانال‌های ماهواره‌ای مورد استفاده

| کانال | طول موج<br>( $\mu\text{m}$ ) | عدد موج<br>مرکزی<br>( $\text{cm}^{-1}$ ) |
|-------|------------------------------|--|
| ch6   | ۷/۳                          | ۱۳۶۲/۰۸۱                                 |
| ch9   | ۱۰/۸                         | ۹۳۰/۶۴۷                                  |
| ch10  | ۱۲/۰                         | ۸۳۹/۶۶۰                                  |
| ch11  | ۱۳/۴                         | ۷۵۲/۳۸۷                                  |

تطبیق وضوح مکانی داده‌ها

با وجود یکسان بودن محدوده مکانی داده‌های دمای روشنایی و بارش، این دو مجموعه داده دارای وضوح مکانی متفاوت بودند. وضوح مکانی داده بارش برابر با ۰/۱ درجه و وضوح مکانی داده دمای روشنایی در حدود ۰/۰۳ درجه است؛ در نتیجه ابعاد تصاویر دما و بارش یکسان نبودند. به منظور هم‌ترازی داده‌های ورودی و خروجی مدل و با توجه به اینکه هدف این پژوهش تخمین بارش در مقیاس ۰/۱ درجه بوده است، تصاویر دمای روشنایی به صورت آگاهانه به وضوح مکانی داده بارش بازنمونه‌برداری شدند. این فرایند با استفاده از درون‌یابی دوبعدی خطی (Bilinear Interpolation) انجام گرفت؛ روشی پایدار و پرکاربرد که ضمن حفظ پیوستگی مکانی داده‌ها، از ایجاد نوسانات مصنوعی در میدان‌های دما جلوگیری می‌کند و برای نگاشت اطلاعات ریزمقیاس به مقیاس هدف مناسب است. اگرچه این روش، مشابه سایر روش‌های بازنمونه‌برداری، می‌تواند منجر به هموارسازی محدود برخی ساختارهای همرفتی شود، این گام امکان

هدف اصلی، طراحی و آموزش یک مدل یادگیری عمیق برای تخمین پیوسته‌ی بارش سطح زمین بر اساس داده‌های ماهواره‌ای دمای روشنایی (Brightness Temperature) است. بدین منظور، معماری Attention U-Net به عنوان هسته اصلی مدل انتخاب شد و مسئله به صورت رگرسیون تعریف گردید. یکی از چالش‌های مهم در این مسئله، نامتوازن بودن توزیع بارش و چولگی مثبت داده‌ها است؛ به گونه‌ای که بخش عمده‌ای از نمونه‌ها دارای بارش صفر یا بسیار کم بوده و تنها درصد اندکی شامل بارش‌های شدید است. این ویژگی می‌تواند منجر به گرایش مدل به تخمین مقادیر میانگین یا نزدیک به صفر شود. از این رو، در طراحی مدل و توابع مربوطه، تمهیداتی به منظور افزایش حساسیت مدل نسبت به بارش‌های شدید اندیشیده شد.

تبدیل رادیانس به دمای روشنایی

داده‌های اولیه‌ی ماهواره‌ای به صورت رادیانس طیفی برای هر پیکسل در دسترس بودند و نیاز به تبدیل آن‌ها به دمای روشنایی بود تا به عنوان ورودی مدل یادگیری عمیق مورد استفاده قرار گیرند. برای این منظور، از رابطه‌ی معکوس قانون پلانک استفاده شد که امکان تبدیل رادیانس طیفی به دمای روشنایی را در هر کانال طیفی فراهم می‌کند. رابطه‌ی مورد استفاده به شکل زیر تعریف شده است:

$$T = C_2 \times v / \ln(1 + C_1 \times v^3 \times L) \quad (1)$$

که در آن  $T$  دمای روشنایی (کلوین)،  $L$  رادیانس طیفی،  $v$  عدد موج مرکزی کانال و  $C_1$  و  $C_2$  ثابت‌های پلانک هستند. طول موج و عدد موج‌های استفاده‌شده در این مطالعه برای چهار کانال ماهواره‌ای در جدول ۱ آورده شده است. این مرحله از پردازش، گام ضروری برای

یادگیری مؤثر ارتباط مکانی بین دمای روشنایی و بارش را در چارچوب مدل فراهم کرده است.

پیش‌پردازش و تقسیم داده‌ها

برای داده‌های بارش، از مجموعه داده بازتحلیل مدل عددی ECMWF طی سال‌های ۲۰۱۹ تا ۲۰۲۲ با وضوح زمانی ساعتی و وضوح مکانی ۰/۱ درجه استفاده شد. بررسی آماری داده‌ها نشان داد که حدود ۶۹ درصد از نمونه‌ها دارای بارش کمتر از ۰/۱ میلی‌متر هستند که بیانگر نامتوازن بودن شدید داده‌هاست. به منظور کاهش چولگی مثبت توزیع بارش و بهبود فرایند یادگیری، مقادیر بارش پس از اعمال تبدیل لگاریتمی، در بازه ۰ تا ۱ نرمال‌سازی شدند. همچنین دماهای روشنایی چهار کانال فرسوخ با استفاده از بیشینه و کمینه مشترک کل داده‌ها به بازه ۰ تا ۱ نرمال‌سازی شدند. در نهایت، مجموعه داده به سه بخش آموزش (۷۰٪) اعتبارسنجی (۱۵٪) و آزمون (۱۵٪) تقسیم گردید.

معماری مدل

برای حل مسئله تخمین پیوسته بارش، از معماری Attention U-Net استفاده شده است. این معماری توسعه‌ای از مدل U-Net کلاسیک بوده و با افزودن دروازه‌های توجه (Attention Gates) در مسیرهای اتصال پرشی، امکان شناسایی و برجسته‌سازی نواحی مکانی مرتبط با بارش را فراهم می‌سازد. این ویژگی به‌ویژه در داده‌های بارش که دارای پراکنندگی مکانی بالا و نواحی گسترده بدون بارش هستند، اهمیت ویژه‌ای دارد. ساختار کلی مدل از یک مسیر رمزگذار (Encoder) برای استخراج ویژگی‌های چندمقیاسی، یک مسیر رمزگشا (Decoder) برای بازسازی میدان بارش، و مسیرهای اتصال پرشی مبتنی بر توجه تشکیل شده است. در مسیر رمزگذار، با افزایش

عمق شبکه، ویژگی‌های مکانی سطح بالاتر استخراج می‌شوند، در حالی که مسیر رمزگشا این اطلاعات را برای بازسازی دقیق الگوی بارش به کار می‌گیرد. اتصال‌های پرشی، پس از عبور از دروازه‌های توجه، عمدتاً اطلاعات مکانی مؤثر را از رمزگذار به رمزگشا منتقل می‌کنند.

در بلوک‌های پیچشی شبکه از لایه‌های پیچشی متوالی، توابع فعال‌سازی غیرخطی و نرمال‌سازی استفاده شده است تا پایداری فرآیند آموزش و کیفیت استخراج ویژگی‌ها بهبود یابد. همچنین، برای کاهش بیش‌برازش و افزایش تعمیم‌پذیری مدل، از راهبردهای منظم‌سازی شامل Dropout و جریمه‌سازی وزن‌ها (Weight Decay/L2 Regularization) استفاده شده است.

در لایه خروجی، یک لایه پیچشی یک‌دریک به همراه تابع فعال‌سازی Sigmoid به کار رفته است تا خروجی مدل در بازه نرمال‌شده [۰،۱] تولید شود. در نهایت، این خروجی به مقیاس واقعی بارش بازگردانده می‌شود.

دروازه توجه

یکی از اجزای کلیدی مدل پیشنهادی، استفاده از دروازه‌های توجه در مسیرهای اتصال پرشی است. این ماژول‌ها وظیفه دارند عمدتاً ویژگی‌های مکانی مرتبط با تخمین بارش را از لایه‌های رمزگذار به مسیر رمزگشا منتقل کرده و اطلاعات غیرمرتبط یا نوفه‌دار را تضعیف کنند. دروازه‌های توجه با یادگیری ماسک‌های مکانی، اهمیت نسبی هر ناحیه از تصویر را تعیین می‌کنند و باعث می‌شوند مدل تمرکز بیشتری بر ساختارهای مکانی بارش، به‌ویژه سلول‌های بارشی و الگوهای موضعی، داشته باشد. این سازوکار به‌ویژه برای مناطق خشک و نیمه‌خشک، که بارش‌ها ماهیتی پراکنده و ناپیوسته دارند و در بیشتر زمان‌ها

با مقادیر بسیار کم همراهاند، مزیت قابل توجهی در بهبود عملکرد مدل ایجاد می‌کند.

تابع زیان و راهبرد آموزش

با توجه به چولگی مثبت و عدم تعادل شدید در توزیع مقادیر بارش، استفاده از توابع زیان متعارف مانند MSE یا MAE می‌تواند منجر به تمرکز مدل بر نمونه‌های غالب اما کم‌اهمیت (بارش صفر یا ضعیف) شده و دقت در شناسایی رویدادهای بارش شدید را کاهش دهد. از این‌رو، در این پژوهش از نسخه‌ی بهبودیافته‌ای از تابع زیان Huber همراه با وزن‌دهی تطبیقی استفاده شده است. این تابع زیان برای خطاهای کوچک رفتاری مشابه MSE و برای خطاهای بزرگ رفتاری مشابه MAE دارد و در نتیجه نسبت به مقادیر پرت از پایداری بیشتری برخوردار است. وزن‌دهی به صورت تابعی از مقدار بارش واقعی اعمال شده است (رابطه ۲).

$$w = 1 + 8(y_{true})^3 \quad (2)$$

که در آن، استفاده از توان سوم موجب تقویت غیرخطی سهم بارش‌های شدید شده و ضریب انتخاب‌شده بر اساس آزمایش‌های تجربی به گونه‌ای تنظیم شده است که ضمن افزایش حساسیت مدل به رخداد‌های بارش شدید، پایداری فرآیند آموزش و رفتار گرادیان‌ها حفظ شود. به این ترتیب، پیکسل‌هایی با بارش زیاد وزن بیشتری در محاسبه‌ی زیان دارند و مدل حساسیت بالاتری نسبت به بارش‌های شدید پیدا می‌کند. آموزش مدل با استفاده از بهینه‌ساز AdamW انجام شده است که با کنترل هم‌زمان نرخ یادگیری و پیچیدگی وزن‌ها، به همگرایی پایدار و تعمیم‌پذیری بهتر مدل کمک می‌کند. به منظور پایش عملکرد مدل و جلوگیری از بیش‌برازش، از راهبردهایی نظیر توقف زودهنگام، کاهش تطبیقی نرخ یادگیری و

ذخیره‌سازی بهترین مدل بر اساس داده‌های اعتبارسنجی استفاده شده است.

جمع‌بندی روش‌شناسی

معماری طراحی شده در این پژوهش با بهره‌گیری از روش‌های مدرن یادگیری عمیق از جمله دروازه توجه، نرمال‌سازی گروهی، رهاسازی تدریجی، منظم‌سازی و تابع زیان تطبیقی، به گونه‌ای طراحی شده است که هم از بیش‌برازش جلوگیری کند و هم حساسیت مدل نسبت به نمونه‌های با بارش شدید را افزایش دهد. این ویژگی‌ها باعث می‌شوند مدل پیشنهادی عملکردی مؤثر در تخمین بارش از مجموعه داده ماهواره‌ای نشان دهد، حتی در شرایطی که مجموعه‌های داده دارای عدم تعادل و نوفه بالا هستند.

### بحث و نتایج

در این بخش، نتایج حاصل از مدل پیشنهادی به منظور ارزیابی رفتار یادگیری، پایداری فرآیند آموزش و قابلیت تعمیم آن تحلیل و تفسیر می‌شوند. تمرکز اصلی بر بررسی همگرایی مدل و نحوه مواجهه آن با نامتوازن بودن داده‌های بارش، به ویژه در رخداد‌های بارش شدید، است. رفتار یادگیری و قابلیت تعمیم مدل بررسی روند تغییرات تابع خطا و شاخص میانگین قدرمطلق خطا در مراحل آموزش و اعتبارسنجی (شکل‌های ۲ و ۳) بیانگر فرآیند یادگیری پایدار و همگرا در مدل پیشنهادی است. کاهش هم‌زمان و هماهنگ این شاخص‌ها در هر دو مجموعه آموزشی و اعتبارسنجی نشان می‌دهد که مدل بدون بروز بیش‌برازش، الگوهای اصلی مرتبط با بارش را به درستی فراگرفته است. کاهش سریع خطا در دوره‌های اولیه آموزش حاکی از توان بالای مدل در استخراج ویژگی‌های مکانی و طیفی غالب مرتبط با سامانه‌های بارشی است. پایدار شدن روند کاهش

ارزیابی کمی عملکرد مدل در مرحله آزمون

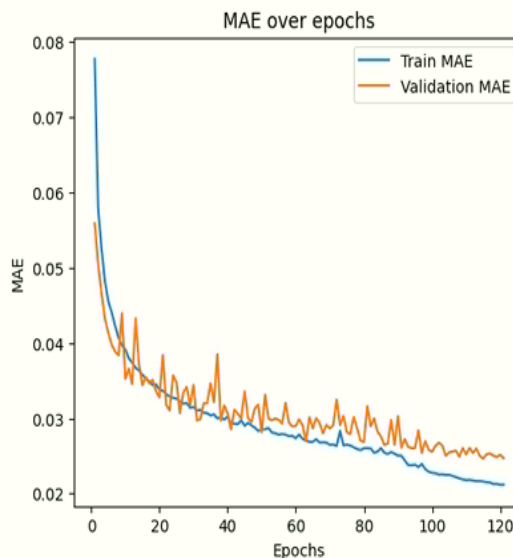
نتایج ارزیابی کمی مدل در مرحله آزمون که بر اساس داده‌های مستقل و دیده نشده توسط مدل انجام شده است، نشان‌دهنده دقت قابل قبول مدل پیشنهادی در برآورد بارش ساعتی می‌باشد (جداول ۲ و ۳). مقادیر ضریب همبستگی و ضریب تعیین بیانگر توافق مناسب بین مقادیر برآوردشده و داده‌های مرجع است و نشان می‌دهد بخش قابل توجهی از تغییرپذیری بارش به‌درستی توسط مدل توضیح داده شده است. اختلاف مشاهده‌شده بین MAE و RMSE نشان می‌دهد که خطاهای بزرگ‌تر، که در عمده‌ی موارد به رخدادهای بارشی شدید مربوط می‌شوند، سهم بیشتری در مقدار RMSE دارند. این موضوع با حساسیت بیشتر این معیار ارزیابی نسبت به خطاهای بزرگ سازگار بوده و در ارزیابی عملکرد مدل در شرایط بارش شدید اهمیت دارد.

ارزیابی کیفی و تحلیل مکانی الگوهای بارش

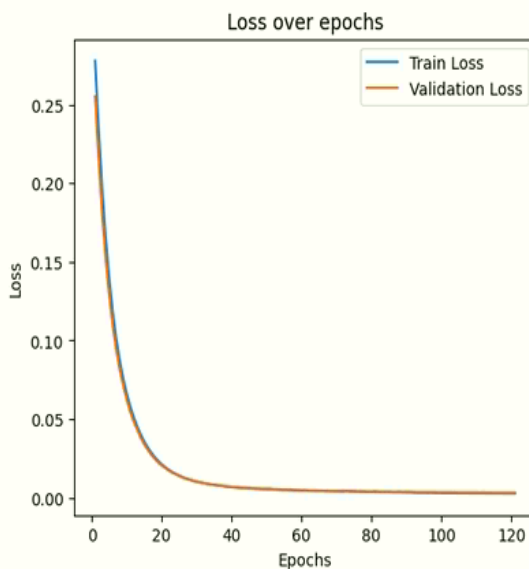
مقایسه کیفی و بصری نقشه‌های بارش تولیدشده توسط مدل پیشنهادی با داده‌های مرجع ERA5-Land و محصولات برآورد بارش ماهواره‌ای PERSIANN با وضوح مکانی ۰/۲۵ درجه و PERSIANN-CCS با وضوح ۰/۰۴ درجه (شکل‌های ۴ تا ۶) نشان می‌دهد که مدل Attention U-Net با وضوح مکانی ۰/۱ درجه بازتولید دقیق‌تری از شدت و گستره مکانی سامانه‌های بارشی ارائه می‌دهد. در حالی که محصول PERSIANN به‌طور کلی تمایل به کم‌برآورد بارش‌ها دارد و PERSIANN-CCS در برخی موارد بیش‌برآورد موضعی رخدادهای شدید را نشان می‌دهد.

مدل پیشنهادی پیوستگی فضایی بهتری را حفظ کرده و از ایجاد نوسانات غیرواقعی جلوگیری می‌کند. این ویژگی منجر به شباهت بالاتر الگوهای بارشی مدل با

خطا در دوره‌های بعدی نیز بیانگر همگرایی مدل به یک پاسخ بهینه می‌باشد. استفاده از تابع هزینه وزن‌دار هابر (Weighted Huber Loss) به همراه بهینه‌ساز AdamW نقش مؤثری در کنترل ناپایداری‌های یادگیری و مدیریت توزیع نامتقارن داده‌های بارش داشته است.



شکل ۲. روند تغییرات MAE با داده‌های آموزش و اعتبارسنجی



شکل ۳. روند تغییرات مقدار خطا (Loss) با داده‌های آموزش و اعتبارسنجی

داده‌های مرجع شده است.

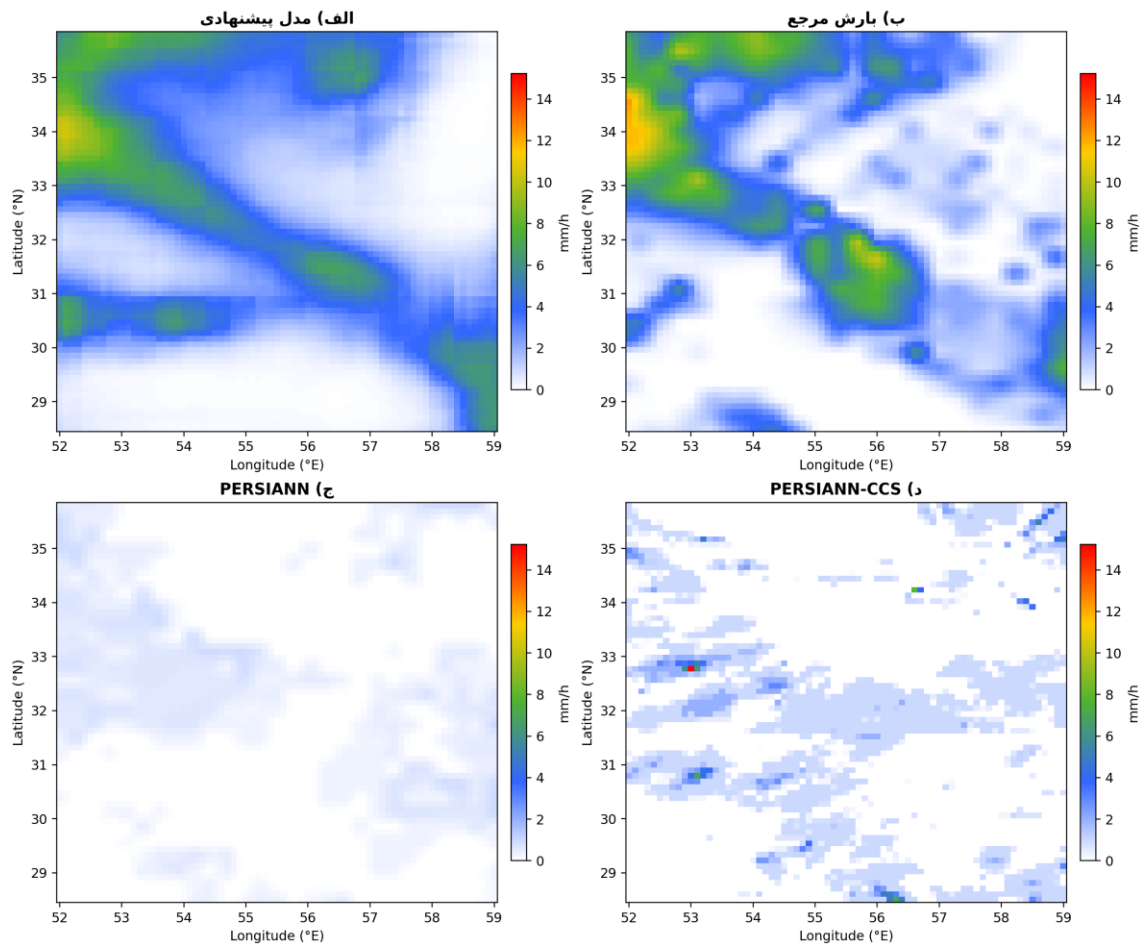
جدول ۲. عملکرد مدل Attention U-Net بر روی مجموعه آزمون با داده‌های نرمال شده

| مقدار | معیار ارزیابی          |
|-------|------------------------|
| ۰/۰۲۵ | MAE (mm)               |
| ۰/۰۰۲ | MSE (mm <sup>2</sup> ) |
| ۰/۰۴۹ | RMSE (mm)              |
| ۰/۶۲۵ | R <sup>2</sup>         |
| ۰/۷۹۱ | R                      |

جدول ۳. عملکرد مدل Attention U-Net بر روی مجموعه آزمون با داده‌های در مقیاس واقعی

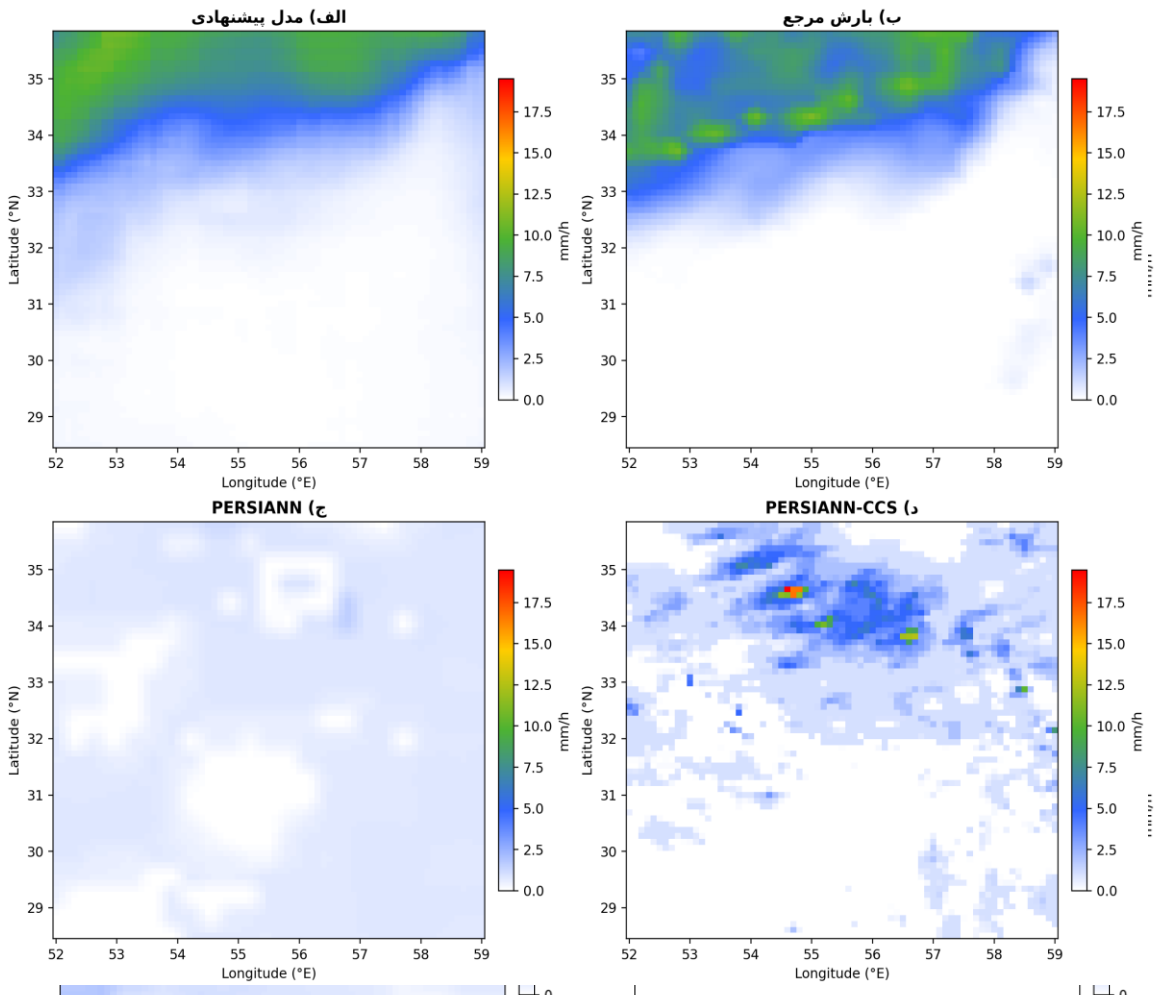
| مقدار | معیار ارزیابی          |
|-------|------------------------|
| ۰/۳۹  | MAE (mm)               |
| ۰/۷۴  | MSE (mm <sup>2</sup> ) |
| ۰/۸۶  | RMSE (mm)              |
| ۰/۶۳  | R <sup>2</sup>         |
| ۰/۸۰  | R                      |

### مقایسه بارش مدل‌ها با بارش واقعی – 2019021114



شکل ۴. مقایسه‌ی مکانی بارش برای رویداد ۱۴:۰۰ گرینویچ در تاریخ ۱۱ فوریه ۲۰۱۹ در محدوده‌ی ایران مرکزی؛ (الف) خروجی مدل پیشنهادی مبتنی بر Attention U-Net، (ب) داده‌های مرجع بارش ERA5-Land، (ج) داده‌های بارش PERSIANN و (د) داده‌های PERSIANN-CCS.

مقایسه بارش مدل‌ها با بارش واقعی – 2022010209



شکل ۶. به مانند شکل ۴، مربوط به رویداد ساعت ۰۹ گریجوی در تاریخ ۲ فوریه ۲۰۲۲

شکل ۵. به مانند شکل ۴، مربوط به رویداد ساعت ۰۴ گریجوی در تاریخ ۶ دسامبر ۲۰۲۰

نقش سازوکار توجه و سازگاری فیزیکی مدل

به کارگیری سازوکار توجه در معماری Attention U-Net نقش تعیین کننده‌ای در بهبود بازسازی بارش داشته است. این سازوکار با تأکید بر نواحی فعال بارشی و کاهش تأثیر نواحی فاقد بارش، موجب انتقال هدفمند ویژگی‌ها بین بخش Encoder و Decoder شده است. از منظر فیزیکی،

الگوهای تولیدشده توسط مدل از انسجام مناسبی با ساختار سامانه‌های بارشی برخوردار بوده و بیشینه شدت بارش به درستی در هسته‌های بارشی متمرکز شده است. این ویژگی به ویژه در مناطق خشک و نیمه‌خشک، که بارش دارای پراکندگی مکانی بالایی است، اهمیت ویژه‌ای دارد

و نشان‌دهنده برتری معماری‌های مبتنی بر توجه در مدل‌سازی این‌گونه مناطق می‌باشد.

### نتیجه‌گیری

در این پژوهش، یک چارچوب یادگیری عمیق مبتنی بر Attention U-Net به‌منظور برآورد بارش ساعتی با استفاده از داده‌های ماهواره‌ای توسعه داده شد. نتایج حاصل از این مطالعه نشان داد که مدل پیشنهادی توانایی بالایی در بازتولید هم‌زمان ویژگی‌های مکانی و شدت بارش دارد و از نظر عملکرد کمی و کیفی، برتری محسوسی نسبت به روش‌های متداول و محصولات مرجع ماهواره‌ای نشان می‌دهد. ارزیابی‌های آماری حاکی از قابلیت تعمیم مناسب مدل پیشنهادی است. هرچند مقادیر MAE و RMSE هر دو کمتر از ۱ میلی‌متر بر ساعت بوده و بیانگر دقت کلی مناسب مدل هستند، بزرگ‌تر بودن RMSE نسبت به MAE نشان می‌دهد که خطاهای بزرگ‌تر سهم بیشتری در مقدار RMSE دارند. از آنجا که این خطاها عمدتاً در رخداد‌های بارشی شدید رخ می‌دهند، این رفتار با حساسیت ذاتی RMSE به خطاهای بزرگ و با توزیع نامتقارن و دنباله‌سنگین پدیده بارش سازگار است و می‌تواند به‌عنوان نشانه‌ای غیرمستقیم از عملکرد مدل در مواجهه با بارش‌های حدی تفسیر شود.

تحلیل‌های کیفی نیز بیانگر بازتولید واقع‌گرایانه ساختارهای فضایی بارش است. استفاده از سازوکار توجه به همراه تابع هزینه مناسب برای داده‌های نامتوازن، نقش مهمی در بهبود عملکرد مدل، به‌ویژه در رخداد‌های بارشی شدید، ایفا کرده است. به‌طور کلی، یافته‌های این پژوهش نشان می‌دهد که بهره‌گیری از معماری‌های یادگیری عمیق مبتنی بر توجه می‌تواند رویکردی کارآمد و سازگار با منطق فیزیکی پدیده بارش برای بهبود برآورد بارش در

مقیاس‌های زمانی کوتاه فراهم آورد. در مطالعات آینده، گسترش دامنه زمانی و مکانی داده‌ها، استفاده از داده‌های مشاهداتی دقیق‌تر و به‌کارگیری معماری‌های پیشرفته زمانی و مکانی می‌تواند به افزایش دقت و پایداری این مدل‌ها منجر شود.

### منابع

۱. بهبودیان، م.، حسینی، م.، & کرایجان، ر. (۱۳۹۵). ارزیابی و مقایسه محصول بارش ماهواره‌ای PERSIANN-CCS و مشاهدات باران‌سنجی، مطالعه موردی: شبکه باران‌سنجی استان‌های تهران - البرز. نهمین کنگره ملی مهندسی عمران. دانشگاه فردوسی مشهد.
۲. خوارزمی، س.، غیبی، ا.، & رهنما، م. (۱۴۰۱). تحلیل تأثیرات روشنایی، بازتابندگی و دما بر ابرناکی با استفاده از داده‌های ماهواره‌ای: یک مطالعه موردی از ماهواره متئوست در ایران. نشریه پژوهش‌های اقلیمی، ۵۱(۵۱)، ۸۷-۱۰۵.
۳. رستم‌زاده، ه.، رسولی، ع. ا.، وظیفه، م. د. & ملکی، ن. (۱۳۹۸). مطالعه تطبیقی بارش‌های به‌دست‌آمده از ماهواره‌های GPM و TRMM با داده‌های رادار زمینی ایستگاه‌های رادار داپلر. نشریه پژوهش‌های اقلیمی، ۱۰(۳۸)، ۶۱-۹۴.
۴. طارمی، م.، عزیزیان، ا.، & لوکا، ب. (۱۳۹۹). تخمین بارش با استفاده از تصاویر ماهواره‌ای رطوبت سطحی خاک ASCAT در حوضه‌های نیمه‌خشک و مرطوب ایران. تحقیقات آب و خاک ایران، ۵۱(۶)، ۱۴۴۰-۱۴۲۷.
۵. عبداللهی، ب.، حسینی موغاری، س.، م. & ابراهیمی، ک. (۱۳۹۶). ارزیابی داده‌های بارش ماهواره‌ای CMORPH و TRMM 3B42RT V7 به‌منظور تخمین بارش در حوضه گرگانود. نشریه علوم و مهندسی آب‌خیزداری ایران، ۱۱(۳۶)، ۵۵-۶۴.
۶. غیبی، ا.، خوارزمی، س.، & رهنما، م. (۱۴۰۰). بازیابی بارش با استفاده از دمای روشنایی کانال‌های IR سنجنده SEVIRI. تحقیقات منابع آب ایران، ۱۷(۱)، ۱۰۱-۱۱۵.
۷. گلابی، م. ر.، آخوندعلی، ع.، & رادمنش، ف. (۱۳۹۲). مقایسه عملکرد الگوریتم‌های مختلف شبکه عصبی مصنوعی در مدل سازی بارندگی فصلی موردی: ایستگاه‌های منتخب استان خوزستان. نشریه تحقیقات کاربردی علوم جغرافیایی، ۳۰(۱)، ۱۵۵-۱۶۹.

- precipitation estimation using a U-Net convolutional neural network and geographical information. *Environmental Modelling & Software*, 134, 104856.
18. Sadeghi, M., Asanjan, A. A., Faridzad, M., Nguyen, P. H. U., Hsu, K., Sorooshian, S., & Braithwaite, D. A. N. (2019). PERSIANN-CNN: Precipitation estimation from remotely sensed information using artificial neural networks-convolutional neural networks. *Journal of Hydrometeorology*, 20(12), 2273-2289.
  19. Subhajini, A. C. (2018). Application of neural networks in weather forecasting. *International Journal of Weather, Climate Change and Conservation Research*, 4(1), 8-18.
  20. Tao, Y., Gao, X., Hsu, K., Sorooshian, S., & Ihler, A. (2016). A deep neural network modeling framework to reduce bias in satellite precipitation products. *Journal of Hydrometeorology*, 17(3), 931-945.
  21. Tao, Y. (2017). A Deep Learning Framework for Precipitation Estimation from Bispectral Satellite Information. University of California, Irvine.
  22. Wang, C., Tang, G., Xiong, W., Ma, Z., & Zhu, S. (2021). Infrared precipitation estimation using convolutional neural network for FengYun satellites. *Journal of Hydrology*, 603, 127113.
  23. Weerasinghe, H. D. P., Premaratne, H. L., & Sonnadara, D. U. J. (2010). Performance of neural networks in forecasting daily precipitation using multiple sources. *Journal of the National Science Foundation of Sri Lanka*, 38(3).
  24. Wu, Z., Wu, F., Chai, J., Zhan, C., & Yu, Z. (2020). Prediction of daily precipitation based on deep learning and broad learning techniques. *IEEE Access*, 8, 147150-147163.
  ۸. مسعودیان، س. ا.، رعیت‌پیشه، ف. & کیخسروی کیانی، م. (۱۳۹۳). معرفی و مقایسه پایگاه داده بارش TRMM و اسفزاری: یک مطالعه تطبیقی. *مجله ژئوفیزیک ایران*، ۸(۴)، ۱۳۹۳-۱۴۱۵.
  9. Abhishek, K., Singh, M. P., Ghosh, S., & Anand, A. (2012). Weather forecasting model using artificial neural network. *Procedia Technology*, 4, 311-318.
  10. Gorooh, V. A., Asanjan, A. A., Nguyen, P., Hsu, K., & Sorooshian, S. (2022). Deep neural network high SpatioTEmporal resolution precipitation estimation (Deep-STEP) using passive microwave and infrared data. *Journal of Hydrometeorology*, 23(4), 597-617.
  11. Jeniffer, K., Su, Z., Woldai, T., & Maathuis, B. (2010). Estimation of spatial-temporal rainfall distribution using remote sensing techniques: A case study of Makanya catchment, Tanzania. *International journal of applied earth observation and geoinformation*, 12, S90-S99.
  12. Ko, J., Lee, K., Hwang, H., Oh, S. G., Son, S. W., & Shin, K. (2022). Effective training strategies for deep-learning-based precipitation nowcasting and estimation. *Computers & Geosciences*, 161, 105072.
  13. Levizzani, V., Amorati, R., & Meneguzzo, F. (2002). A review of satellite-based rainfall estimation methods. *European Commission Project MUSIC Report (EVK1-CT-2000-00058)*, 66.
  14. Moraux, A., Dewitte, S., Cornelis, B., & Munteanu, A. (2019). Deep learning for precipitation estimation from satellite and rain gauges measurements. *Remote Sensing*, 11(21), 2463.
  15. Nguyen, H. N., Nguyen, T. A., Ly, H. B., Tran, V. Q., Nguyen, L. K., Nguyen, M. V., & Ngo, C. T. (2021). Prediction of daily and monthly rainfall using a backpropagation neural network. *Journal of Applied Science and Engineering*, 24(3), 367-379.
  16. Nguyen, P., Ombadi, M., Sorooshian, S., Hsu, K., AghaKouchak, A., Braithwaite, D., ... & Thorstensen, A. R. (2018). The PERSIANN family of global satellite precipitation data: A review and evaluation of products. *Hydrology and Earth System Sciences*, 22(11), 5801-5816.
  17. Sadeghi, M., Nguyen, P., Hsu, K., & Sorooshian, S. (2020). Improving near real-time

# Precipitation Estimation Using Satellite Data and Deep Learning Model for Central Regions of Iran

Seyed Abbas Mirhoseini<sup>1</sup>, Abolhassan gheiby<sup>2\*</sup>, Mohammad Hossein Memarian<sup>3</sup>, Elham Abbasi<sup>4</sup>

<sup>1</sup>Seyed Abbas Mirhoseini, PHD student of Meteorology, Department of Atmospheric and Oceanographic Sciences, University of Hormozgan, Bandar Abbas, Iran

<sup>2\*</sup>Abolhassan gheiby, Associate Professor, Department of physics, Faculty of sciences, University of Hormozgan, Bandar abbas, Iran

<sup>3</sup>Mohammad Hossein Memarian, Associate Professor, Faculty of physics, Yazd University, Yazd, Iran

<sup>4</sup>Elham Abbasi, assistant professor, Department of Computer Sciences, Faculty of Mathematics, Yazd University, Yazd, Iran

\*Corresponding Author Email: [Abolhassang@hormozgan.ac.ir](mailto:Abolhassang@hormozgan.ac.ir)

Received: 07 January 2026, Accepted: 15 February 2026

## Abstract

Estimating precipitation using traditional methods is usually associated with considerable errors, particularly during convective and heavy rainfall events. To enhance the accuracy of precipitation estimation, a deep learning framework integrating satellite observations and reanalysis data was employed. In this study, an attention-based U-shaped model was developed, in which the inputs consisted of multi-channel hourly brightness temperatures from second-generation Meteosat satellites, and the outputs were fifth-generation land surface reanalysis data (ERA5-Land) for the period 2019–2022, with an hourly temporal resolution and a spatial resolution of 0.1°. To improve model performance, an enhanced adaptive weighted version of the Huber loss function was utilized. By combining the advantages of mean squared error and mean absolute error, this loss function provides greater robustness against extreme precipitation values. In addition, an attention gating mechanism was applied to facilitate information transfer between the encoder and decoder pathways and to suppress irrelevant features, acting as an intelligent filter that selectively passes features most relevant to precipitation prediction. After training, the model achieved a mean absolute error of 0.39 mm, a root mean square error of 0.862 mm, and a correlation coefficient of 0.80, demonstrating strong spatial consistency with ERA5-Land data. This study was conducted over the geographical domain bounded by 28.5°–35.5° N latitude and 52°–59° E longitude. Overall, the results indicate that the proposed multi-source data integration approach combined with the developed attention-based U-shaped architecture can serve as an effective tool for precipitation monitoring and estimation, particularly in regions with sparse or insufficient rain gauge networks.

**Keywords:** precipitation estimation, reanalysis data, brightness temperature, convolutional neural networks, advanced deep learning

## HOW TO CITE THIS ARTICLE

Mirhoseini, S. A., gheiby, A., Memarian, M.H. and Abbasi, E. (2026). Precipitation Estimation Using Satellite Data and Deep Learning Model for Central Regions of Iran. *Journal of Meteorology and Atmospheric Science*, 8(1): 46- 62. Doi: 10.22034/jmas.2026.571346.1264

## COPYRIGHTS

Copyright for this article is retained by the author(s), with publication rights granted to the JMAs Journal. This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>).

