

Post-processing of daily precipitation forecast output of the WRF model using artificial neural network models (Case study: East Azerbaijan Province)

Eslahi, M.¹  | Azadi, M.²  | Yarahmadi, J.³ | Pourasghar, F.⁴  | Mohammadi, A.⁵  | Akbarzadeh, Y.⁶

1- PhD in Climatology, East Azerbaijan Agricultural and Natural Resources Research and Education Center, Tabriz, Iran.

2- Professor, Institute of Meteorology and Atmospheric Sciences, Tehran, Iran.

3- Associate Professor, East Azerbaijan Agricultural and Natural Resources Research and Education Center, Tabriz, Iran.

4- PhD in Climatology, East Azerbaijan Meteorological Department, Tabriz, Iran.

5- PhD in Meteorology and Atmospheric Sciences Research and Education Center, Tehran, Iran.

6- PhD in Climatology, East Azerbaijan Meteorological Department, Tabriz, Iran.

Corresponding Author E-mail: m.eslahi@areeo.ac.ir

(Received: 02 Nov 2025, Revise: 01 Jul 2026, Accepted: 11 Jul 2026, Published online: 11 Jul 2026)

Abstract

Precipitation occurrence is influenced by numerous meteorological variables, making its prediction a complex task. Consequently, both numerical weather prediction (NWP) models and statistical approaches have been developed to forecast daily precipitation. One promising method for improving forecast accuracy involves the use of Artificial Neural Networks (ANNs), which can be employed either directly for precipitation prediction or for post-processing the outputs of NWP models. In this study, meteorological variables derived from the output of the WRF (Weather Research and Forecasting) model were utilized to enhance hourly and daily precipitation forecasts. Specifically, an ANN-based post-processing approach was applied to refine the WRF model outputs. The meteorological variables extracted hourly over a three-year period (2021–2023) included accumulated precipitation (APCP), dew point temperature (DPT), mean sea-level pressure (PRMSL), relative humidity at 2 meters (RH2), 2-meter air temperature (T2m), and wind speed (Wspeed). These variables were categorized into forecast lead times of 6, 12, 18, 24, 48, and 72 hours, with each lead time used independently as input to the ANN model for each station. The ANN architecture employed was a multilayer perceptron (MLP) consisting of two layers: a hidden layer with sigmoid activation functions and an output layer with linear activation. The model was trained to predict 6-hour observed precipitation at each station. The ANN was implemented across 16 synoptic meteorological stations in East Azerbaijan Province. Model performance was evaluated using statistical metrics including Mean Squared Error (MSE) and Pearson correlation coefficient (R), calculated for the training, testing, and validation datasets. The model was iteratively trained until the minimum MSE and maximum R values were achieved. Results indicated that the ANN-enhanced WRF model significantly improved precipitation forecasts, with MSE reductions ranging from 36% to 92% depending on the station. Also, the correlation index R for all stations was 0.85 on average. Furthermore, 95% daily error plots demonstrated that the modified model exhibited lower error magnitudes and reduced variability compared to the original WRF outputs.

Keywords: Precipitation, WRF, FFN model, MSE index, R correlation index

Cite this article: Eslahi, M., Azadi, M., Yarahmadi, J., Pourasghar, F., Mohammadi, S. A. and Akbarzadeh, Y. (2026). Post-processing of daily precipitation forecast output of the WRF model using artificial neural network models (Case study: East Azerbaijan Province). *Nivar*, 50(132-133), 222-243. doi: 10.30467/nivar.2026.553313.1357

E-mail: (2) azadi68@hotmail.com (3) yarahmadi1353@gmail.com (4) farnaz_pourasghar@yahoo.com (5) mohamadi.atefeh@yahoo.com (6) y.akbarzadeh@gmail.com

پس پردازش برون داد مدل WRF برای پیش بینی بارش روزانه با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: استان آذربایجان شرقی)

مهدی اصلاحي^{۱*} | مجید آزادی^۲ | جمشید یاراحمدی^۳ | فرناز پوراصغر^۴ | سیده عاطفه محمدی^۵ | یونس اکبرزاده^۶

۱- دکترای آب و هواشناسی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی آذربایجان شرقی، تبریز، ایران.

۲- استاد، پژوهشگاه هواشناسی و علوم جو، تهران، ایران.

۳- دانشیار مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی آذربایجان شرقی، تبریز، ایران.

۴- دکترای آب و هواشناسی، اداره کل هواشناسی آذربایجان شرقی، تبریز، ایران.

۵- دکتری، پژوهشگاه هواشناسی و علوم جو، تهران، ایران.

۶- دکترای آب و هواشناسی، اداره کل هواشناسی آذربایجان شرقی، تبریز، ایران.

رایانامه نویسنده مسئول: m.eslahi@areeo.ac.ir

(دریافت: ۱۴۰۴/۰۸/۱۱، بازنگری: ۱۴۰۵/۰۴/۱۰، پذیرش: ۱۴۰۵/۰۴/۲۰، انتشار آنلاین: ۱۴۰۵/۰۴/۲۰)

چکیده

رخدادهای بارش به متغیرهای هواشناسی زیادی وابسته است و سبب پیچیدگی پیش بینی بارش می شود یکی از روش ها جهت افزایش دقت پیش بینی استفاده از مدل های شبکه عصبی مصنوعی (ANN) است که به طور مستقیم برای پیش بینی بارش و یا پس پردازش برون داد مدل های عددی پیش بینی وضع هوا استفاده می شود. در این مقاله متغیرهای هواشناسی از برون داد مدل عددی WRF استخراج و برای بهبود پیش بینی بارش ساعتی و روزانه از مدل شبکه عصبی مصنوعی برای پس پردازش برون داد مدل WRF استفاده گردید. متغیرهای هواشناسی که طی دوره آماری سه ساله (۲۰۲۳-۲۰۲۱) به صورت ساعتی از برون داد مدل WRF گرفته شده، شامل بارش، نقطه شبنم، میانگین فشار سطح دریا، رطوبت و دمای دومتري و سرعت باد است. این متغیرها در بردهای پیش بینی ۶، ۱۲، ۱۸، ۲۴، ۴۸ و ۷۲ ساعته تقسیم بندی و هر بردی پیش بینی به طور جدا به عنوان ورودی برای هر ایستگاه به مدل شبکه عصبی مصنوعی داده شد. شبکه عصبی مصنوعی مورد استفاده یک پرسپترون چند لایه (MLP) با یک لایه پنهان و تابع فعال ساز سیگموئید است. بارش های مشاهداتی ۶ ساعته برای هر ایستگاه به عنوان خروجی مدل شبکه عصبی مصنوعی استفاده شد. مدل روی ۱۶ ایستگاه هواشناسی سینوپتیک استان آذربایجان شرقی اجرا گردید. در هر بار اجرای مدل شبکه عصبی مصنوعی، عملکرد مدل با شاخص های آماری میانگین توان دوم خطا (MSE) و ضریب همبستگی پیرسن (R) سنجیده شد. نتایج نشان داد که عملکرد مدل WRF پس از اعمال شبکه عصبی مصنوعی روی برون داد مدل برای شاخص MSE بین ۳۶ تا ۹۲ درصد برای ایستگاه های مورد نظر بهبود یافت. همچنین شاخص همبستگی R برای کل ایستگاهها به طور متوسط ۰/۸۵ درصد بوده است. همچنین نمودارهای خطای روزانه ۹۵ درصد مدل ها نشان داد که در تمام ایستگاهها خطای روزانه مدل اصلاح شده نسبت به مدل WRF به صفر نزدیک تر و تغییرات یا واریانس خطا بسیار کمتر است.

کلید واژه: بارش، WRF، شبکه عصبی مصنوعی، شاخص MSE، شاخص همبستگی

استناد: اصلاحي، مهدی، آزادی، مجید، یاراحمدی، جمشید، پوراصغر، فرناز، محمدی، سیده عاطفه و اکبرزاده، یونس. (۱۴۰۵). پس پردازش برون داد مدل WRF برای پیش

بینی بارش روزانه با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: استان آذربایجان شرقی) مجله نیوار، ۵۰ (۱۳۲-۱۳۳)، ۲۲۲-۲۴۳. DOI:

<https://doi.org/10.30467/nivar.2026.553313.1357>

رایانامه: (۲) azadi68@hotmail.com (۳) yarahmadi1353@gmail.com (۴) farnaz_pourasghar@yahoo.com (۵) mohamadi.atefeh@yahoo.com

(۶) y.akbarzadeh@gmail.com

ناشر: سازمان هواشناسی کشور.



DOI: <https://doi.org/10.30467/nivar.2026.553313.1357>

۱. مقدمه

بارندگی یکی از پیچیده‌ترین پدیده‌های طبیعی است. در واقع تأثیر عوامل محسوس آنچنان به طرز پیچیده‌ای در ایجاد وقوع بارش مؤثر است که این روند را از یک نظام قانونمند روشن به سوی یک ساختار پیچیده و آشوبناک سوق داده است. هوش مصنوعی یکی از ابزارهای علمی است که کاربرد آن در پیش‌بینی وضع هوا در حال گسترش است. هوش مصنوعی با استفاده از مدل‌های یادگیری عمیق می‌تواند از داده‌های وضع-هوا در گذشته برای پیش‌بینی آینده یاد بگیرد. لام^۱ و همکاران (۲۰۲۳)، یک روش مبتنی بر یادگیری ماشین را معرفی کردند که مستقیماً از داده‌های بازتحلیل جوی گذشته به عنوان ورودی استفاده کرده و مورد آموزش قرار می‌دهد. به این ترتیب، توانستند به سرعت صدها متغیر جوی را در سراسر جهان تا ۱۰ روز بعد و با تفکیک بالا پیش‌بینی کنند. پیش‌بینی‌های آن‌ها در ۹۰ درصد موارد آزمایش شده دقیق‌تر از مدل‌های پیش‌بینی عددی وضع‌هواست سنتی بود و پیش‌بینی رویدادهای شدید بهتری را برای طوفان‌های استوایی، رودخانه‌های جوی و دماهای شدید نشان داد.

یکی از روش‌های کارآمد هوش مصنوعی که امروزه برای پیش‌بینی بارش و اصلاح خروجی مدل‌های پیش‌بینی عددی وضع‌هوا استفاده می‌گردد شبکه‌های عصبی مصنوعی (ANN)^۲ است که به عقیده متخصصان، علت اصلی مقبولیت و استفاده روزافزون آن، قدرت و سرعت بالا در شبیه‌سازی فرایندهایی است که درک و شناخت درستی از آن وجود نداشته و یا بررسی آن‌ها با دیگر روش‌های موجود، بسیار دشوار

و وقت‌گیر می‌باشد. مطالعات زیادی در مورد پیش‌بینی مستقیم بارش روزانه با استفاده از شبکه عصبی مصنوعی (ANN) انجام شده است (چن^۳ و تاکاگی^۴، ۱۹۹۳؛ کالا^۵ و وایدیاناثان^۶، ۲۰۱۸؛ چاند^۷ و ناند^۸، ۲۰۱۹؛ سنکان^۹ و همکاران، ۲۰۲۰؛ پیوندی^{۱۰} و همکاران، ۲۰۲۲؛ پیرون^{۱۱} و همکاران، ۲۰۲۲؛ اسپهلت^{۱۲} و همکاران، ۲۰۲۲؛ نجیب^{۱۳} و همکاران، ۲۰۲۳؛ و در داخل خلیلی و همکاران، ۱۳۸۹ و امیدوار و همکاران، ۱۳۹۴). در مورد روش‌های پس‌پردازش برون‌داد مدل (موناجی^{۱۴} و همکاران، ۲۰۱۱؛ گالانیس^{۱۵} و همکاران، ۲۰۰۶ و گالانیس و آندرانستاکیس^{۱۶}، ۲۰۰۲) می‌توان به روش آماری برون‌داد مدل (Model Output Statistics) MOS، روش پیش‌بینی کامل (Perfect Prognosis Method) PPM و روش واسنجی برون‌داد مدل (Model Output Calibration) اشاره کرد (آزادی و همکاران، ۱۳۸۷). یکی از محدودیت‌های اصلی این روش‌ها لزوم دسترسی به داده‌های بلندمدت است که همیشه در دسترس نیست. در سال‌های اخیر روش‌های دیگری توسعه یافته است که می‌توان بدون استفاده از داده‌های بلندمدت برون‌داد مدل را تصحیح کرد از آن جمله می‌توان به روش‌های پالایه کالمن (موناجی و همکاران، ۲۰۱۱؛ گالانیس و همکاران، ۲۰۰۶؛ هاملید^{۱۷}، ۱۹۹۵؛ کالمن^{۱۸} و باسی^{۱۹}، ۱۹۶۱؛ کالمن، ۱۹۶۰ و در داخل آزادی و همکاران، ۱۳۸۷)، میانگین متحرک (مکولر^{۲۰} و استال^{۲۱}، ۲۰۰۸)، روش-های بیزی (جلمن^{۲۲} و همکاران، ۲۰۱۳) و در نهایت روش شبکه عصبی مصنوعی (مرزبان^{۲۳}، ۲۰۰۳؛ در داخل ملبوسی و همکاران، ۱۴۰۱ و آزادی و همکاران، ۱۳۹۱)، اشاره کرد.

¹³Najib¹⁴Monache¹⁵Galanis¹⁶Anadranistakis¹⁷Homleid¹⁸Kalman¹⁹Bucy²⁰Mccollor²¹Stull²²Gelman²³Marzban¹ Lam² Artificial Neural Networks³ Chen⁴ Takagi⁵ Kala⁶ Vaidyanathan⁷ Chand⁸ Nand⁹ Senekane¹⁰ Biondi¹¹ Pirone¹² Espeholt

پیش بینی عددی WRF برای بارش با مدل های شبکه عصبی مصنوعی است که در نهایت ایجاد سامانه هشدار سریع سیل با استفاده از مدل های شبکه عصبی مصنوعی را ممکن می سازد.

۲. روش پژوهش

منطقه ی مورد مطالعه، استان آذربایجان شرقی است که در شمال غربی ایران بین ۳۶ درجه و ۴۷ دقیقه تا ۳۹ درجه و ۴۰ دقیقه عرض شمالی و ۴۵ درجه و ۳ دقیقه تا ۴۸ درجه و ۵۰ دقیقه طول شرقی از نصف النهار گرینویچ واقع شده است. داده های مشاهداتی شامل بارش روزانه ی شش ساعته ایستگاههای هواشناسی سینوپتیک استان است که به عنوان متغیر پیش بینی شونده در مدل شبکه عصبی وارد می شود و مورد آموزش قرار می گیرد. (شکل (۱) موقعیت این ایستگاهها به همراه ناهمواری های منطقه را نشان می دهد.

در این پژوهش برون داد پارامترهای مدل WRF به عنوان ورودی مدل های شبکه عصبی استفاده شد. شرایط مرزی و اولیه مدل از داده های اجرای ساعت ۱۲ UTC سامانه مدل سازی تمام کره ای موسوم به GFS از مرکز ملی پیش بینی های محیطی (NCEP) با تفکیک افقی ۵/۰ درجه گرفته شده است. اجرای مدل به صورت روزانه و برای ساعت ۱۲ UTC بوده و در هر اجرا پیش بینی تا ۷۲ ساعت آینده تولید شده است. برون داد مدل شامل ۹۷ متغیر در ۲۹ تراز جوی است. متغیرهای در دسترس در این تحقیق، متغیرهای سطح زمین حاصل از برون داد مدل WRF در دوره ی زمانی سه ساله ۲۰۲۱ تا ۲۰۲۳ میلادی است که عبارتند از بارش، نقطه شبنم (DPT)، فشار (PRMSL)، رطوبت و دمای دومتری و سرعت باد. برون دادهای مدل WRF با روش دوخطی به ایستگاه های مورد نظر درونیابی شده اند. این متغیرها به عنوان ورودی مدل شبکه عصبی وارد مدل می شوند.

با توجه به هدف پژوهش و داده های موجود در دسترس که شامل داده های برون داد سطح زمین مدل WRF برای دوره ی ۳ ساله ی ۲۰۲۱ تا ۲۰۲۳ است، متغیرهای برون داد مدل که شامل بارش ساعتی نیز هست به عنوان ورودی و داده های بارش

دسته ای از این مطالعات به پس پردازش پارامتر آب بارش شو پرداخته اند (تقوی و جلالی، ۱۴۰۱؛ محمدیها و همکاران، ۱۳۹۳ و مباشری و همکاران، ۱۳۸۹) و دسته ای دیگر از مطالعات پس- پردازش مستقیم پارامتر بارش برون داد مدل را مورد بررسی قرار داده اند (ملبوسی و همکاران، ۱۴۰۱؛ آزادی و همکاران، ۱۳۹۰ و ۱۳۹۱).


از مطالعاتی که با موضوع پژوهش مطابقت دارد می توان به مقاله ی آزادی و همکاران (۱۳۹۱) اشاره کرد که در آن برون داد مدل پیش بینی عددی را در سامانه همدی برای کمیت بارش با استفاده از یک شبکه عصبی مصنوعی مورد پس پردازش قرار دادند. در این مطالعه از بازه زمانی شش ماهه ی نوامبر ۲۰۰۸ تا آوریل ۲۰۰۹ استفاده شد. در نهایت با استفاده از روش بافت-نگار رتبه ای پیش بینی های احتمالاتی بارش برای آستانه های گوناگون بارش برای منطقه شمال ایران محاسبه و واسنجی کردند و در نهایت به این نتیجه رسیدند که استفاده از شبکه عصبی مصنوعی برای پس پردازش برون داد خام مدل و سپس واسنجی کردن اعضای سامانه ی همدی قبل از ترکیب اعضا می تواند پیش بینی احتمالاتی دقیق تری تولید کند. همچنین ملبوسی و همکاران (۱۴۰۱) از روش یادگیری عمیق شبکه عصبی برای پس پردازش برون داد بارش مدل WRF استفاده کردند. در این تحقیق مدل عددی WRF برای دو روز در سال ۲۰۱۸ (با پیش بینی ۴ روز برای هر روز) در منطقه خراسان رضوی اجرا شد و خروجی بارش ساعتی مدل به عنوان داده های متغیر هدف برای آموزش و امتحان الگوریتم ها در نظر گرفته شد. در این پژوهش از برون داد متغیرهای پیش بینی شده مدل WRF به عنوان ورودی مدل شبکه عصبی عمیق استفاده شد. آنها با ارائه الگوریتم پیشنهادی توانستند خطای پیش بینی را کاهش داده و صحت عملکرد پیش بینی را بهبود دهند.

هدف کلی در این پژوهش ارائه مدلی جهت پیش بینی بارش- های روزانه و ساعتی و بهینه سازی برون داد مدل های پیش بینی عددی وضع هوا برای بارش با استفاده از مدل های شبکه عصبی مصنوعی است. به طور جزئی تر هدف پس پردازش برون داد مدل

مشاهداتی ایستگاه به عنوان خروجی، وارد مدل شبکه عصبی شدند.

هر شبکه‌ی عصبی مصنوعی به طور معمول از لایه‌ی ورودی، لایه‌ی میانی یا پنهان و لایه‌ی خروجی تشکیل شده است. لایه‌ی ورودی یک لایه انتقال دهنده و وسیله‌ای برای خواندن داده‌هاست. لایه‌ی خروجی شامل مقادیر پیش‌بینی شده به وسیله‌ی شبکه است و لایه‌ی پنهان محل پردازش داده‌هاست. تعداد لایه‌ها و نرون‌ها در هر لایه‌ی پنهان، به‌طور معمول به وسیله‌ی روش آزمون و خطا مشخص می‌شود (haykin, 2001).

2001). در این مدل‌ها درصد زیادی از داده‌ها برای آموزش و درصد کمی برای آزمون استفاده می‌شود. هر نرون ساده شامل R ورودی است و هر بردار ورودی با انتخاب وزن مناسب W، وزن‌دار شده و جمع ورودی‌های وزن‌دار، ورودی تابع فعال‌ساز F را تشکیل می‌دهند. می‌توان از توابع مختلفی برای تولید خروجی بهره برد. توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع فعال‌ساز خطی، متداول‌ترین آن‌ها محسوب می‌شوند (Demuth and Beale, 2000).




شکل ۱- موقعیت ایستگاه‌های هواشناسی و ناهمواری‌های استان آذربایجان شرقی (نگارنده)

در سال‌های اخیر، انواع زیادی از شبکه‌های عصبی مصنوعی در زمینه‌ها و اهداف گوناگون علوم به ویژه برای تخمین و پیش‌بینی پدیده، طراحی و به کار گرفته شده‌اند. برای استفاده از شبکه‌های عصبی جهت حل مسائل، نیاز به انتخاب شبکه‌ی عصبی مناسب است. نوع یک شبکه‌ی عصبی توسط ساختار و آموزش آن مشخص می‌شود. انتخاب این شبکه به ماهیت مسئله مورد بررسی و نوع داده‌های آن وابسته است. با توجه به توانایی‌های شبکه‌ی پرسپترون چندلایه (MLP) و قابلیت

آموزش و یادگیری زیاد این نوع شبکه‌ی عصبی، به منظور برآورد عناصر جوی در مطالعات زیادی از این روش استفاده می‌شود (ایلدرمی و همکاران، ۱۳۹۲؛ امیدوار و همکاران، ۱۳۹۳ و فرجی و همکاران، ۱۴۰۲). شبکه‌ی پرسپترون چند لایه (MLPs) شبکه‌ی عصبی پیشخور آموزش دیده با الگوریتم پس‌انتشار استاندارد است که تحت نظارت عمل می‌کند به‌طوری‌که برای آموزش نیاز به یک پاسخ مورد نظر دارد. شبکه یاد می‌گیرد که چگونه برای تبدیل داده‌های ورودی به

۴۸ و ۷۲ ساعته تقسیم‌بندی می‌شود و هر کدام به صورت جدا برای هر ایستگاه وارد مدل شبکه عصبی می‌شود. همانطور که قبلاً ذکر شد داده‌های در دسترس مدل متغیرهای سطح زمین شامل داده‌های بارش ساعتی، دمای نقطه شبنم، فشار سطح دریا، رطوبت، دمای دومتري و سرعت باد است که به عنوان متغیرهای ورودی برای مدل شبکه عصبی در نظر گرفته می‌شود و متغیر هدف یا خروجی مدل همان بارش مشاهداتی ایستگاه مورد نظر است. با توجه به ماهیت مسئله مورد بررسی و نوع داده‌های آن برای مدل‌بندی از مدل شبکه عصبی پرسپترون چندلایه (MLP) با دو لایه (لایه پنهان و لایه خروجی) استفاده می‌شود. به عبارت جزئی‌تر از یک شبکه پیش‌خور (feed-forward network) دو لایه با نرون‌های پنهان سیگموئیدی و نرون‌های خروجی خطی که می‌تواند مشکلات نگاشت چند بعدی را به‌طور دلخواه با توجه به داده‌های ثابت و نرون‌های کافی در لایه پنهان آن، به خوبی جا دهد، استفاده می‌شود. شکل شماتیک این مدل در شکل (۲) آورده شده است.



شکل ۲- نمای شماتیک از مدل شبکه عصبی پیش‌خور دولایه

برای حل مسئله کمینه مربعات برای توابع غیرخطی استفاده می‌شود. در مسائل مربوط به برازش، یک متغیر برآوردکننده به عنوان ورودی و یک متغیر هدف به عنوان خروجی در مدل شبکه عصبی نقش ایفا می‌کند. ابزار FFN در نرم‌افزار متلب به ما کمک می‌کند داده‌ها انتخاب، یک شبکه ایجاد و مورد آموزش قرار گیرد و عملکرد مدل با شاخص آماری مجموع

پاسخ مطلوب عمل کند. برای شروع الگوریتم پس‌انتشار یک مقدار اولیه برای تعیین هر وزن مورد نیاز است (به‌طور معمول یک مقدار تصادفی کوچک) و ادامه می‌دهیم تا زمانی که برخی از معیارها متوقف شوند. سه معیار مهم عبارتند از تعداد تکرار، میانگین مربعات خطای داده‌های آموزشی و میانگین مربعات خطای داده‌های اعتبارسنجی متقابل. اعتبارسنجی متقابل قوی‌ترین آن‌هاست که در آن آموزش در یک نقطه بهینه متوقف می‌شود (یعنی خطای اعتبارسنجی متقابل حداقل می‌شود). برای پیاده سازی اعتبارسنجی متقابل باید درصد کوچکی (۱۰ درصد) از داده‌ها را برای تعیین میزان کارایی و چگونگی یادگیری شبکه آموزش کنار گذاشت. وقتی عملکرد در دوره اعتبارسنجی متقابل شروع به کاهش می‌کند، آموزش را باید متوقف کرد. این نوع شبکه به‌طور گسترده‌ای برای طبقه بندی الگوها استفاده می‌شود. اکثر برنامه‌های کاربردی شبکه‌ی عصبی از الگوریتم MLPs پیروی می‌کنند (haykin, 2001).

برای پس‌پردازش برون‌داد بارش ساعتی مدل WRF داده‌های بارش و بقیه‌ی متغیرهای سطح زمین اخذشده از برون‌داد مدل WRF برای ۷۲ ساعت آینده به صورت پیش‌بینی ۶، ۱۲، ۲۴،

در این مدل برازشی، تابع آموزش شبکه تابعی است که وزن‌ها و مقادیر اربابی را مطابق الگوریتم بهینه‌سازی لونیبرگ-مارکواردت (Levenberg-Marquardt) بروزرسانی می‌کند. الگوریتم لونیبرگ-مارکواردت روشی است برای یافتن کمینه یک تابع غیر خطی چندمتغیره که به عنوان یک روش استاندارد

۳. بحث و نتایج


از آنجاکه اساس کار مدل شبکه عصبی در هنگام آموزش و آزمون داده‌ها محاسبه‌ی خطای داده‌های ورودی و خروجی در مدل است، لذا جهت تعیین تعداد مناسب داده‌ها برای آموزش می‌توان از پایداری شاخص میانگین قدرمطلق خطا (MAE) استفاده کرد. به همین منظور مقدار شاخص MAE برای هر روز به صورت تجمعی روزهای قبل محاسبه شد و مقادیر آن در نمودار روند شکل (۳) آورده شده است. طبق شکل (۳) مقدار MAE تقریباً از داده‌ی ۸۵۰ام به بعد پایدار یا ثابت شده است. بنابراین مناسب به نظر می‌رسد که ۸۵۰ داده اول یا ۸۰ درصد از داده‌ها برای آموزش یا یادگیری در مدل شبکه عصبی استفاده شود.

توان‌های دوم خطا و تحلیل همبستگی ارزیابی شود. نتایج مدل شبکه عصبی براساس تعداد لایه‌های پنهان و تعداد نرون‌ها و درصد داده‌های آموزش داده‌شده با استفاده از شاخص‌های MSE و همبستگی R مورد ارزیابی قرار می‌گیرد که فرمول این شاخص‌های آماری در زیر آمده است:

$$MSE = \frac{\sum_{i=1}^N (O_i - T_i)^2}{N} \quad (1)$$

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(T_i - \bar{T})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \sum_{i=1}^N (T_i - \bar{T})^2}} \quad (2)$$

که در آن O_i و T_i به ترتیب مقادیر داده‌های ورودی و خروجی مدل و N تعداد کل داده‌هاست.



شکل ۳- مقادیر میانگین قدرمطلق خطا (MAE) به صورت تجمعی برای روزهای مختلف در ایستگاه تبریز

آموزش، ۱۰ درصد به عنوان آزمون و ۱۰ درصد به عنوان اعتبارسنجی مدل شبکه عصبی استفاده می‌شود. با همان تعداد ۱۰ لایه پنهان شروع کرده و پس از هر بار آموزش مدلی که دارای کمترین میانگین مربعات خطا (MSE) و بیشترین همبستگی (R) در بخش داده‌های آموزش است به عنوان مدل بهینه انتخاب می‌شود. در همین رابطه خلیلی و همکاران (۱۳۸۹) از ۴ تا ۷ نرون و امیدوار و همکاران (۱۳۹۴) از ۷ تا ۱۴ نرون

۳-۱. مدل بندی شبکه عصبی FFN برای پس پردازش پرونداد مدل WRF برای بارش ۲۴ ساعته ایستگاه تبریز

داده‌های پیش‌بینی ۲۴ ساعته بارش روزانه و پنج متغیر دیگر حاصل از پرونداد مدل WRF که شامل سه سال داده‌ی روزانه است به عنوان ورودی و داده‌های بارش دیدبانی شده در ساعت ۱۲ هر روز را به عنوان خروجی یا متغیر هدف وارد مدل شبکه عصبی FFN می‌شود. طبق نتایج قسمت قبل ۸۰ درصد به عنوان

روزانه مدل شبکه عصبی به مقدار صفر نزدیک تر است. همچنین مجموع ماهانه بارش پیش‌بینی‌شده‌ی ۲۴ ساعته مدل شبکه عصبی در مقابل سری زمانی ماهانه بارش ۲۴ ساعته‌ی مشاهداتی به همراه نمودار مشابه برای مدل WRF در کنار نمودار اخیر در قالب شکل (۸) آورده شده است. از شکل (۸) مشخص است که دقت مدل شبکه عصبی FFN به عنوان مدل پس‌پردازشی برون‌داد مدل WRF بالاتر از مدل WRF است. به عبارت دیگر اصلاح برون‌داد مدل WRF برای پیش‌بینی بارش ۲۴ ساعته نتیجه داده است.

۳-۲. پس‌پردازش برون‌داد بارش مدل WRF

ایستگاههای استان با استفاده از مدل شبکه عصبی FFN

طبق روش‌های مدل‌بندی شبکه عصبی که برای ایستگاه تبریز برای خروجی بارش مدل WRF انجام شده است، ایستگاه‌های دیگر استان نیز برون‌داد بارش‌شان برای مدل WRF با استفاده از شبکه عصبی مورد پس‌پردازش قرار می‌گیرد. طبق نتایجی که از مدل‌بندی شبکه عصبی بارش ایستگاه تبریز گرفته شد، تکرار آموزش در مدل شبکه عصبی تأثیر زیادی در بالا رفتن دقت مدل شبکه عصبی دارد. به دلیل وجود چند ایستگاه جهت بالا بردن سرعت انجام مدل‌بندی برنامه رایانه‌ای با متلب نوشته شد که در آن با دادن تعداد نرون مورد نظر در مدل شبکه عصبی، آموزش مدل تا زمان رسیدن به مقادیر بهینه شاخص آماری (MSE و R) تکرار می‌شود. مقدار بهینه شاخص‌های آماری با توجه به مقادیر شاخص آماری مدل WRF مشخص می‌شود. به طوریکه مقادیر بهینه شاخص‌های حداقل تا ۵۰ درصد کاهش (MSE) یا افزایش (R) یابد.


برای پیش‌بینی بارش روزانه برای مدل شبکه عصبی استفاده کردند.

نتایج شاخص‌های مدل بهینه‌ی انتخابی و داده‌ها قبل از مدل‌بندی در جدول (۱) مشاهده می‌گردد. در کل ۱۴ مدل شبکه عصبی مناسب برای تعداد نرون‌های مختلف در لایه پنهان و مقدار میانگین توان دوم خطاها (MSE) و ضریب همبستگی پیرسن (R) برای داده‌های آموزش داده شده است. برای انتخاب مدل بهینه، مقادیر شاخص‌های MSE و R در نمودار پراکنش شکل (۴) آورده شده است. طبق نمودار مدل شماره ۱۰ در جدول (۱) به عنوان مدل بهینه انتخاب شده که دارای کمترین شاخص MSE و بیشترین همبستگی R است و دارای ۴۰ نرون در لایه پنهان در اجرای سوم است. شاخص MSE کل داده‌ها قبل از مدل‌بندی ۳/۷۳۵ بود که پس از مدل‌بندی شبکه عصبی بهینه این شاخص به طور میانگین به ۱/۴۴ رسید که ۶۲ درصد کاهش یافته است. مقدار همبستگی کل مدل بهینه ۰/۸۴۳۸ است که نسبت به داده‌ها قبل از مدل که ۰/۶۵ بود که ۲۹/۸ درصد افزایش داشته است. عملکرد مدل شبکه عصبی بهینه به صورت نموداری در شکل (۵) آمده است. طبق شکل شاخص MSE برای داده‌های اعتبارسنجی به حداقل مقدار ۱/۵۲۱۹ رسید. نتایج نمودار رگرسیونی مدل شبکه عصبی در شکل (۶) داده شده است. در این نمودار رابطه بین متغیر هدف (بارش دیدبانی شده) و برآورد این متغیر یا مقدار برازش شده داده شده است. در این نمودار نزدیک بودن خط برازش شده به خط نیمساز نمودار نشان‌دهنده برآورد بهتر مدل است.


فاصله اطمینان خطای روزانه مدل شبکه عصبی FFN و خطای روزانه مدل WRF در قالب نمودار شکل (۷) نشان می‌دهد که فاصله اطمینان خطا برای مدل شبکه عصبی FFN کوتاه‌تر از مدل WRF است که این امر نشان‌دهنده بالا بودن دقت مدل اصلاح شده‌ی شبکه عصبی است علاوه بر آن میانگین خطای

جدول ۱- نتایج شاخص‌های مدل شبکه عصبی FFN برای بارش ۲۴ ساعته ایستگاه تبریز


ردیف	تعداد نرون‌ها در	اجرای	میانگین توان دوم	ضریب همبستگی
۱	۱۰	اجرای	۲/۳۴۶۰	۰/۷۰۷۰
۲	۱۰	اجرای	۲/۱۰۰۶	۰/۷۶۸۶
۳	۲۰	اجرای	۲/۵۸۶۶	۰/۶۹۸۲
۴	۲۰	اجرای	۲/۱۸۵۱	۰/۷۴۹۴
۵	۲۰	اجرای	۱/۹۱۹۹	۰/۷۷۶۵
۶	۳۰	اجرای	۲/۱۴۶۰	۰/۷۷۳۸
۷	۳۰	اجرای	۲/۳۵۲۰	۰/۷۲۲۵
۸	۴۰	اجرای	۲/۰۵۲۲	۰/۷۵۳۹
۹	۴۰	اجرای	۰/۰۲۹۳	۰/۷۸۲۵
۱۰	۴۰	اجرای	۱/۴۴۱۴	۰/۸۴۳۸
۱۱	۵۰	اجرای	۱/۸۷۳۸	۰/۷۸۸۱
۱۲	۵۰	اجرای	۱/۸۱۳۶	۰/۷۷۴۸
۱۳	۵۰	اجرای	۲/۰۸۶۰	۰/۷۴۵۴
۱۴	۶۰	اجرای	۱/۸۹۳۲	۰/۸۰۵۲
شاخص‌های مقایسه ای داده‌های بارش مشاهداتی و بارش مدل WRF				۰/۶۵۰۰۹
۳/۷۳۵۳				




شکل ۵- عملکرد مدل شبکه عصبی FFN برای داده‌های بارش و ضریب پیش‌بینی شده‌ی ۱۲ ساعته ایستگاه تبریز



شکل ۴- پراکنش همزمان دو شاخص آماری میانگین توان دوم خطا (MSE) همبستگی (R)




شکل ۷- نمودار فاصله اطمینان ۹۵ درصد برای خطای روزانه مدل WRF و مدل ANN خروجی WRF برای پیش‌بینی ۲۴ ساعته



شکل ۶- نتایج نمودار رگرسیونی مدل شبکه عصبی بهینه FFN برای بارش پیش‌بینی شده ۲۴ ساعته ایستگاه تبریز

نمود. مدل‌بندی به ترتیب برای پیش‌بینی بارش ۶، ۱۲، ۲۴، ۴۸ و ۷۲ ساعته برای هر ایستگاه انجام می‌شود که مشخصات آنها در شکل (۱) بخش قبل آورده شده است.

برای پیش‌بینی بارش ۶ و ۱۲ ساعته فقط می‌توان از داده‌های بارش مشاهداتی ایستگاه‌های سینوپتیک ۲۴ ساعته استفاده کرد و در بقیه حالات می‌توان ایستگاه‌های ۱۲ ساعته را نیز اضافه



شکل ۸- سری زمانی مجموع بارش ماهانه پیش‌بینی شده ۲۴ ساعته مشاهداتی و مدل برای مدل WRF (الف) و مدل شبکه عصبی پس‌پردازش شده مدل WRF در ایستگاه تبریز (ب)

می‌شود. درصد تغییرات شاخص‌های MSE و R مدل اصلاح- شده نسبت به مدل WRF در دو سطر آخر جدول آمده است. مقادیر درصدها حاکی از بهبود شاخص MSE با کاهش شاخص به میزان ۷۰ تا ۸۶ درصد و شاخص R با افزایش شاخص به مقدار ۳۴ تا ۵۱ درصد در ایستگاه‌های مختلف است. جهت بررسی دقیق‌تر، خطای روزانه مدل WRF و مدل شبکه عصبی بهبود یافته‌ی آن در قالب نمودار فاصله اطمینان ۹۵ درصد خطا برای هر ایستگاه بطور تجمیع یافته در شکل (۹) ترسیم شدند. طبق این نمودار فاصله اطمینان مدل اصلاح شده WRF کوتاه‌تر از مدل WRF است که این امر نشان‌دهنده‌ی دقیق‌تر بودن مدل اصلاح شده است. میانگین خطای مدل اصلاح شده WRF نیز نسبت به مدل WRF در تمام ایستگاه‌ها به صفر نزدیک‌تر است.


هشت ایستگاه سینوپتیک ۲۴ ساعته شامل تبریز، اهر، جلفا، مراغه، میانه، سراب، کلیر و سهند در استان وجود دارد که در ساعت ۱۸ بارش ۶ ساعته ثبت می‌شود. مدل‌بندی شبکه عصبی FFN با تعداد نرون مشخص روی هر ایستگاه روی برون‌داد بارش ۶ ساعته مدل WRF انجام می‌شود. برنامه رایانه‌ای متلب طوری طراحی شده است که حداکثر تا هزار بار آموزش مدل شبکه عصبی با تعداد نرون مشخص انجام می‌شود تا به مقادیر بهینه از پیش تعیین شده شاخص‌های آماری (MSE و R) برسد. جدول (۲) نتایج خروجی مدل شبکه عصبی FFN را برای هر ایستگاه نشان می‌دهد. مدل بر اساس تعداد نرون‌های لایه‌ی پنهان از ۱۰ تا ۶۰ نرون توسط برنامه نوشته شده‌ی متلب اجرا شد. همان‌طور که قبلاً ذکر شد کمترین مقدار شاخص MSE و بیشترین مقدار همبستگی R به عنوان مدل بهینه در نظر گرفته

جدول (۲)- نتایج اجرای مدل شبکه عصبی FFN برای برون‌داد بارش ۶ ساعته مدل WRF

ایستگاه	تعداد نرون	مدل شبکه عصبی FFN		مدل WRF		میزان بهبود شاخص‌های مدل WRF	
		MSE	MSE	MSE	R	درصد کاهش MSE	مقدار افزایش R
تبریز	۱۰	۰/۲۸۲۷	۰/۸۵۴۳	۱/۱۴۷۶	۰/۴۰۳۹	۷۵/۳۷	۰/۴۵۰۴
اهر	۲۰	۰/۲۶۳۳	۰/۸۴۱	۰/۹۲۳۰	۰/۳۹۹۹	۷۱/۴۷	۰/۴۴۱۱
جلفا	۲۰	۰/۱۷۷۸	۰/۸۸۰۸	۰/۸۶۰۶	۰/۴۷۲۶	۷۹/۳۴	۰/۴۰۸۲
مراغه	۳۰	۰/۲۷۳۵	۰/۸۴۵۹	۰/۹۴۹۶	۰/۵۰۶۹	۷۱/۲	۰/۳۳۹
میانه	۴۰	۰/۱۹۷	۰/۹۲۱۳	۱/۱۲۳۰	۰/۴۱۷۶	۸۲/۴۶	۰/۵۰۳۷
سراب	۳۰	۰/۲۹۹۱	۰/۸۴۹۸	۰/۹۰۵۴	۰/۴۵۰۵	۶۶/۹۶	۰/۳۹۹۳
سهند	۲۰	۰/۲۰۵۴	۰/۸۹۰۱	۰/۹۷۸۵	۰/۳۷۹۴	۷۹/۰۰	۰/۵۱۰۷
کلیر	۱۰	۰/۳۷۳	۰/۸۸۱۱	۲/۷۴۹۶	۰/۵۳۴۱	۸۶/۴۳	۰/۳۴۷

هر ایستگاه روی برون‌داد بارش ۶ ساعته‌ی مدل WRF در ساعت صفر مدل‌بندی می‌شود.

برای پس‌پردازش پیش‌بینی بارش ۱۲ ساعته آینده بارش ۶ ساعته مدل WRF برای ایستگاه‌های استان، هشت ایستگاه سینوپتیک ۲۴ ساعته که در ساعت صفر بارش ۶ ساعته ثبت می‌شود با استفاده از مدل شبکه عصبی FFN با تعداد نرون مشخص روی




شکل ۹- نمودار فاصله اطمینان ۹۵ درصد خطای روزانه مدل WRF و مدل اصلاح شده ANN برای ایستگاه‌های استان برای پیش‌بینی بارش ۶ ساعت آینده

می‌شود. درصد تغییرات شاخص‌های MSE و R مدل اصلاح- شده نسبت به مدل WRF در دو سطر آخر جدول آمده است. مقادیر درصدها حاکی از بهبود (کاهش) شاخص MSE به میزان ۷۰ تا ۹۰ درصد و بهبود (افزایش) شاخص R به مقدار ۲۹ تا ۵۴ درصد در ایستگاه‌های مختلف است.

جدول (۳) نتایج خروجی مدل شبکه عصبی FFN را برای هر ایستگاه نشان می‌دهد. مدل بر اساس تعداد نرون‌های لایه‌ی پنهان از ۱۰ تا ۶۰ نرون توسط برنامه نوشته شده‌ی متلب اجرا شد. همان‌طور که قبلاً ذکر شد کمترین مقدار شاخص MSE و بیشترین مقدار همبستگی R به عنوان مدل بهینه در نظر گرفته

جدول (۳) - نتایج اجرای مدل شبکه عصبی FFN برای پس پردازش برون‌داد پیش بینی بارش ۱۲ ساعت آینده بارش ۶ ساعته مدل WRF

ایستگاه	مدل	مدل شبکه عصبی FFN			مدل WRF		میزان بهبود شاخص‌های مدل WRF	
		تعداد نرون	MSE	MSE	MSE	R	درصد کاهش MSE	مقدار افزایش R
تبریز	۵۰	۰/۲۹۴۱	۰/۸۳۰۵	۰/۹۷۱۹	۰/۴۷۵۹	۶۹/۷۴	۰/۳۵۴۶	
اهر	۱۰	۰/۲۹۲۴	۰/۸۴۳۴	۱/۰۴۴۵	۰/۵۳۱۸	۷۲/۰۰	۰/۳۱۱۶	
جلفا	۱۰	۰/۰۸۶۳	۰/۸۹۰۰	۰/۴۲۳۱	۰/۵۰۶۸	۷۹/۶۰	۰/۳۸۳۲	
مراغه	۵۰	۰/۱۸۸۱	۰/۸۷۶۵	۰/۸۲۲۴	۰/۵۰۴۲	۷۷/۱۳	۰/۳۷۲۳	
میانه	۵۰	۰/۱۳۳۷	۰/۹۱۶۹	۰/۸۴۵۴	۰/۵۱۶۶	۸۴/۱۹	۰/۴۰۰۳	
سراب	۵۰	۰/۱۱۲۷	۰/۹۵۱۲	۱/۱۴۰۲	۰/۴۰۲۲	۹۰/۱۲	۰/۵۴۹	
سهند	۲۰	۰/۱۱۴۱	۰/۸۹۶۲	۰/۵۹۲۱	۰/۶۰۵۵	۸۰/۷۳	۰/۲۹۰۷	
کلیر	۳۰	۰/۲۸۹۱	۰/۸۹۸۹	۱/۵۵۴۷	۰/۵۷۲۳	۸۱/۴۰	۰/۳۲۶۶	




شکل ۱۰- نمودار فاصله اطمینان ۹۵ درصد خطای روزانه مدل WRF و مدل اصلاح شده ANN برای ایستگاههای استان برای پیش‌بینی بارش ۱۲ ساعت آینده

دقیق‌تر بودن مدل اصلاح‌شده است. میانگین خطای مدل اصلاح‌شده WRF نیز نسبت به مدل WRF در تمام ایستگاه‌ها به صفر نزدیک‌تر است.


جهت بررسی دقیق‌تر، خطای روزانه مدل WRF و مدل شبکه عصبی بهبود یافته‌ی آن در قالب نمودار فاصله اطمینان ۹۵ درصد خطا برای هر ایستگاه بطور تجمیع یافته در شکل (۱۰) ترسیم شدند. طبق این نمودار فاصله اطمینان مدل اصلاح‌شده WRF کوتاه‌تر از مدل WRF است که این امر نشان‌دهنده‌ی

جدول ۴- نتایج اجرای مدل شبکه عصبی FFN برای پس پردازش برون داد پیش بینی بارش ۱۸ ساعت آینده بارش ۶ ساعته مدل WRF

ایستگاه	مدل	مدل شبکه عصبی FFN				مدل WRF		میزان بهبود شاخص های	
		تعداد نرون	MSE	MSE	MSE	R	MSE	درصد کاهش MSE	مقدار افزایش R
تبریز	۱۰	۰/۰۷۵۵	۰/۹۱۵۴	۰/۴۷۹۳	۰/۶۵۷۲	۸۴/۲۵	۰/۲۵۸۲		
اهر	۳۰	۰/۱۲۸۰	۰/۸۴۸۶	۰/۴۶۷۴	۰/۳۱۷۷	۷۴/۳۳	۰/۵۳۰۹		
جلفا	۱۰	۰/۰۴۵۴	۰/۹۲۶۸	۰/۳۲۹۵	۰/۳۵۵۲	۸۶/۲۲	۰/۵۷۱۶		
مراغه	۳۰	۰/۳۴۰۱	۰/۸۴۷۷	۱/۲۳۲۴	۰/۴۷۱۰	۸۷/۱۴	۰/۳۷۶۷		
میانه	۵۰	۰/۱۰۴۴	۰/۸۷۵۴	۰/۴۵۴۶	۰/۴۵۱۶	۸۴/۴۹	۰/۴۲۳۸		
سراب	۴۰	۰/۱۴۹۰	۰/۸۵۱۵	۰/۵۳۱۳	۰/۴۱۸۵	۸۷/۱۴	۰/۴۳۳		
سهند	۱۰	۰/۱۳۱۲	۰/۸۶۷۷	۰/۵۰۶۴	۰/۴۶۱۳	۷۴/۰۹	۰/۴۰۶۴		
کلیر	۲۰	۰/۲۹۴۶	۰/۸۳۷۷	۱/۰۲۲۹	۰/۴۳۶۹	۷۲/۴۶	۰/۴۰۰۸		
مرند	۱۰	۲/۰۹۵۴	۰/۹۱۰۱	۱۲/۴۸۹۴	۰/۴۶۲۷	۸۳/۲۲	۰/۴۴۷۴		
ورزقان	۳۰	۰/۷۱۰۴	۰/۶۸۶۰	۰/۴۰۵۱	۰/۵۲۰۳	۳۶/۱۴	۰/۱۶۵۷		
شبستر	۵۰	۰/۹۸۲۶	۰/۸۰۵۰	۲/۹۲۷۹	۰/۵۲۶۱	۷۶/۶۷	۰/۲۷۸۹		
هریس	۱۰	۲/۸۸۱۶	۰/۷۴۹۰	۶/۹۱۲۴	۰/۲۸۶۶	۵۸/۳۱	۰/۴۶۲۴		
عجب شیر	۴۰	۰/۹۴۰۲	۰/۸۴۳۶	۳/۳۷۳۵	۰/۴۲۹۱	۷۷/۵۶	۰/۴۱۴۵		
بستان آباد	۱۰	۱/۸۲۲۵	۰/۸۴۰۷	۶/۴۸۸۸	۰/۴۴۶۱	۷۲/۹۱	۰/۳۹۴۶		
چاراویماق	۴۰	۲/۴۴۵۳	۰/۷۸۷۲	۶/۶۹۸۶	۰/۶۷۱۸	۷۸/۴۹	۰/۱۱۵۴		
ملکان	۲۰	۱/۸۵۸۶	۰/۸۲۳۸	۵/۹۳۱۲	۰/۳۶۹۶	۷۲/۸۳	۰/۴۵۴۲		



شکل ۱۰- نمودار فاصله اطمینان ۹۵ درصد خطای روزانه مدل WRF و مدل اصلاح شده ANN برای ایستگاه‌های استان برای پیش‌بینی بارش ۱۸ ساعت آینده



ادامه شکل ۱۱- نمودار فاصله اطمینان ۹۵ درصد خطای روزانه مدل WRF و مدل اصلاح شده ANN برای ایستگاه‌های استان برای پیش‌بینی بارش ۱۸ ساعت آینده

انجام می‌شود. نتایج در جدول (۴) برای هر ایستگاه آورده شده است که در آن مدل بر اساس تعداد نرون‌های لایه‌ی پنهان از ۱۰ تا ۶۰ نرون توسط برنامه نوشته شده‌ی متلب اجرا شد. درصد تغییرات شاخص‌های MSE و R مدل اصلاح شده نسبت به مدل WRF در دو سطر آخر جدول آمده است. مقادیر درصد‌ها حاکی از بهبود (کاهش) شاخص MSE به میزان ۳۶ تا ۸۷ درصد و بهبود (افزایش) شاخص R به مقدار ۱۱ تا ۵۷ درصد در ایستگاه‌های مختلف است.


برای پس‌پردازش برون‌داد پیش‌بینی بارش ۱۸ ساعت آینده بارش ۶ ساعته مدل WRF برای ایستگاه‌های استان، داده‌های بارش ۱۸ ساعت آینده در ساعت ۰۶ ثبت می‌شود. بنابراین تمام ایستگاه‌های ۱۲ و ۲۴ ساعته را شامل می‌شود. با این وضعیت در کل ۱۶ ایستگاه سینوپتیک در استان موجود است که در ساعت ۰۶ بارش ۶ ساعته را ثبت می‌کنند. در اینجا با استفاده از مدل شبکه عصبی FFN با تعداد نرون مشخص روی هر ایستگاه روی برون‌داد بارش ۶ ساعته‌ی مدل WRF در ساعت ۰۶ پس‌پردازش

امر نشان دهنده ی دقیق تر بودن مدل اصلاح شده است. میانگین خطای مدل اصلاح شده WRF نیز نسبت به مدل WRF در تمام ایستگاه ها به صفر نزدیک تر است.


جهت بررسی دقیق تر، خطای روزانه مدل WRF و مدل شبکه عصبی بهبود یافته ی مدل WRF در قالب نمودار فاصله اطمینان ۹۵ درصد خطا برای هر ایستگاه بطور تجمیع یافته در شکل (۱۱) ترسیم شدند. طبق این نمودار در تمام ایستگاه ها فاصله اطمینان مدل اصلاح شده WRF کوتاه تر از مدل WRF است که این

جدول ۵- نتایج اجرای مدل شبکه عصبی FFN برای پس پردازش برون داد پیش بینی بارش ۲۴ ساعت آینده بارش ۶ ساعته مدل WRF

ایستگاه	مدل	مدل شبکه عصبی FFN				مدل WRF		میزان بهبود شاخص های مدل WRF	
		تعداد نرون	MSE	R		MSE	R	درصد کاهش MSE	مقدار افزایش R
تبریز	۳۰	۰/۰۷۶۹	۰/۹۰۸۸	۰/۴۶۹۹	۰/۴۳۱۵	۸۳/۶۳	۰/۴۷۷۳		
اهر	۲۰	۰/۱۱۳۰	۰/۹۰۳۲	۰/۶۲۲۰	۰/۴۸۳۰	۸۱/۸۳	۰/۴۲۰۲		
جلفا	۱۰	۰/۰۴۵۰	۰/۹۱۶۲	۰/۲۸۵۴	۰/۳۰۸۶	۸۴/۲۳	۰/۶۰۷۶		
مراغه	۳۰	۰/۱۳۹۱	۰/۸۴۱۱	۰/۴۷۷۸	۰/۲۴۱۰	۷۰/۸۷	۰/۶۰۰۱		
میانه	۲۰	۰/۰۴۳۶	۰/۹۳۸۹	۰/۳۷۲۰	۰/۳۹۰۹	۸۸/۲۸	۰/۵۴۸		
سراب	۲۰	۰/۱۳۷۱	۰/۹۱۹۱	۰/۹۰۱۶	۰/۳۸۶۵	۸۴/۷۹	۰/۵۳۲۶		
سهند	۲۰	۰/۱۵۹۵	۰/۸۵۰۶	۰/۵۸۵۰	۰/۴۱۴۵	۷۲/۷۴	۰/۴۳۶۱		
کلبر	۲۰	۰/۱۹۵۵	۰/۸۸۲۳	۰/۹۰۱۶	۰/۳۸۶۵	۷۸/۳۲	۰/۴۹۵۸		
مروند	۵۰	۰/۲۸۱۹	۰/۹۱۳۷	۱/۷۵۰۲	۰/۳۹۹۴	۸۳/۸۹	۰/۵۱۴۳		
ورزقان	۵۰	۰/۳۹۳۴	۰/۸۰۰۳	۱/۱۲۰۹	۰/۳۰۰۳	۶۴/۹۰	۰/۵		
شبستر	۴۰	۰/۰۴۱۳	۰/۹۴۳۶	۰/۳۸۲۳	۰/۴۳۷۱	۸۹/۲۰	۰/۵۰۶۵		
هریس	۱۰	۰/۲۵۵۴	۰/۸۵۳۵	۰/۹۷۴۸	۰/۳۲۹۰	۷۳/۸۰	۰/۵۲۴۵		
عجب شیر	۴۰	۰/۰۶۸۹	۰/۹۱۸۷	۰/۴۴۹۲	۰/۲۵۰۸	۸۴/۶۶	۰/۶۶۷۹		
بستان آباد	۶۰	۰/۳۴۷۰	۰/۸۴۰۸	۱/۲۱۷۱	۰/۳۶۶۲	۷۱/۴۹	۰/۴۷۴۶		
چارا ویماق	۴۰	۰/۱۶۵۰	۰/۹۵۷۲	۱/۹۸۲۵	۰/۲۹۰۴	۹۱/۶۸	۰/۶۶۶۸		
ملکان	۱۰	۰/۰۹۶۴	۰/۹۲۹۱	۰/۷۱۸۵	۰/۴۳۲۴	۸۶/۵۸	۰/۴۹۶۷		



شکل ۱۲- نمودار فاصله اطمینان ۹۵ درصد خطای روزانه مدل WRF و مدل اصلاح شده ANN برای ایستگاههای استان برای پیش‌بینی بارش ۲۴ ساعت آینده



ادامه شکل ۱۲- نمودار فاصله اطمینان ۹۵ درصد خطای روزانه مدل WRF و مدل اصلاح شده ANN برای ایستگاههای استان برای پیش‌بینی بارش ۲۴ ساعت آینده

جدول (۵) نتایج خروجی مدل شبکه عصبی FFN را برای هر ایستگاه نشان می‌دهد. مدل بر اساس تعداد نرون‌های لایه‌ی پنهان از ۱۰ تا ۶۰ نرون توسط برنامه نوشته شده‌ی متلب اجرا شد. درصد تغییرات شاخص‌های MSE و R مدل اصلاح شده نسبت به مدل WRF در دو سطر آخر جدول آمده است. مقادیر درصدها حاکی از بهبود (کاهش) شاخص MSE به میزان ۶۵ تا ۹۲ درصد و بهبود (افزایش) شاخص R به مقدار ۴۷ تا ۶۶ درصد در ایستگاه‌های مختلف است.

برای پس‌پردازش برون‌داد پیش‌بینی بارش ۲۴ ساعت آینده‌ی بارش ۶ ساعته مدل WRF برای ایستگاه‌های استان داده‌های بارش ۲۴ ساعت آینده در ساعت ۱۲ ثبت می‌شود بنابراین تمام ایستگاه‌های ۱۲ و ۲۴ ساعته را شامل می‌شود. با این وضعیت در کل ۱۶ ایستگاه سینوپتیک در استان موجود است که در ساعت ۱۲ بارش ۶ ساعته را ثبت می‌کنند. در اینجا با استفاده از مدل شبکه عصبی FFN با تعداد نرون مشخص روی هر ایستگاه روی برون‌داد بارش ۶ ساعته‌ی مدل WRF در ساعت ۱۲ پس‌پردازش انجام می‌شود.

ایستگاه های مختلف در روش میانگین متحرک، بین ۵ تا ۵۰ درصد (با میانگین در حدود ۲۵٪) و در روش بهترین برآوردگر ساده به طور میانگین در حدود ۱۳٪ بهبود یافته است. در مقایسه با تحقیق حاضر که در آن مدل شبکه عصبی ۳۶ تا ۹۲ درصد برون داد مدل WRF را بهبود بخشیده است، مدل شبکه عصبی عملکرد بهتری داشته است.

۴. نتیجه گیری

در این پژوهش از داده های سه ساله (۲۰۲۱-۲۰۲۳) برون داد مدل WRF که شامل پارامترهای جوی فشار، دمای نقطه شبنم، دمای دومتري هوا، رطوبت، سرعت باد و بارش است، برای هر ایستگاه به عنوان ورودی مدل شبکه عصبی استفاده شد. مدل شبکه عصبی مصنوعی انتخابی مدل FFN است که از یک شبکه پیش خور (feed-forward network) دو لایه با نرون های پنهان سیگموئیدی و نرون های خروجی خطی تشکیل شده است. شاخص ارزیابی عملکرد مدل شاخص آماری مجموع توانهای دوم خطا (MSE) و همبستگی پیرسن (R) است. بنابراین با کم شدن شاخص MSE و زیاد شدن شاخص همبستگی R عملکرد مدل بهتر می شود. نتایج نشان می دهد با زیاد شدن داده های ورودی و تکرار آموزش، شاخص ها رفته رفته بهتر می شوند. تعداد نرون ها در مدل شبکه عصبی مصنوعی نیز در بهتر شدن عملکرد مدل تأثیر دارند.

جهت بررسی دقیق تر، خطای روزانه مدل WRF و مدل شبکه عصبی بهبود یافته ی مدل WRF در قالب نمودار فاصله اطمینان ۹۵ درصد خطا برای هر ایستگاه بطور تجمیع یافته در شکل (۱۳) ترسیم شدند. طبق این نمودار در تمام ایستگاه ها فاصله اطمینان مدل اصلاح شده WRF به طور معنی داری کوتاه تر از مدل WRF است که این امر نشان دهنده ی دقیق تر بودن مدل اصلاح شده است. میانگین خطای مدل اصلاح شده WRF نیز نسبت به مدل WRF در تمام ایستگاه ها به صفر نزدیک تر است. جهت بررسی معنی دار بودن بهبود خطاهای مدل WRF پس از پس پردازش، آزمون آماری مقایسه ای خطای مدل WRF و مدل اصلاح شده ی آن با استفاده از مدل شبکه عصبی FFN، انجام شد. از آنجا که بارش روزانه خارج از توزیع نرمال است از آزمون ناپارامتری ویلکاکسن استفاده شده است. جدول ۶ نتایج آزمون را برای همه ایستگاه ها در چهار دوره ی پیش بینی ۶، ۱۲، ۱۸ و ۲۴ ساعته نشان می دهد. طبق جدول ۶ نتایج آزمون معنی داری ویلکاکسن نشان می دهد که در اکثر ایستگاه ها (به جز در دو تا چهار مورد بسته به دوره ی پیش بینی) اختلاف خطای مدل WRF در حالت اولیه و پس پردازش شده معنی دار است. همین امر نشان دهنده بهبود مدل در بیشتر ایستگاه ها است.

آزادی و همکاران (۱۳۹۰) در مقاله خود برای پس پردازش برون داد مدل WRF برای بارندگی روزانه در ایران از روش بهترین برآوردگر ساده و میانگین متحرک استفاده کردند. در این تحقیق که از دوره ی آماری ۶ ماهه استفاده شده است، نتایج نشان داد که هر دو روش پس پردازش، برون داد مستقیم مدل را بهبود می بخشند؛ به گونه ای که میانگین مطلق خطا برای

جدول (۶)- نتایج آزمون مقایسه ای ویلکاکسن برای مقایسه ی خطای مدل WRF و مدل پس پردازش شده آن با استفاده از مدل شبکه عصبی FFN

نام ایستگاه	پیش بینی ۲۴ ساعته		پیش بینی ۱۸ ساعته		پیش بینی ۱۲ ساعته		پیش بینی ۶ ساعته	
	Z_آماره آزمون	P_value	Z_آماره آزمون	P_value	Z_آماره آزمون	P_value	Z_آماره آزمون	P_value
تبریز	-۴/۶۸۱	۰/۰۰۰	-۱۵/۵۳۵	۰/۰۰۰	-۴/۹۳۱	۰/۰۰۰	-۶/۸	۰/۰۰۰
جلفا	-۸/۳۰۵	۰/۰۰۰	-۱۷/۳۲۵	۰/۰۰۰	-۸/۷۸۵	۰/۰۰۰	-۲/۹۵۹	۰/۰۰۳
اهر	-۶/۹۸۶	۰/۰۰۰	-۰/۸۱۶	۰/۴۱۴	-۱۰/۰۸۱	۰/۰۰۰	-۸/۳۲	۰/۰۰۰
سهند	-۱/۵۱۸	۰/۱۲۹	-۱۶/۷۹۳	۰/۰۰۰	-۰/۳۷۲	۰/۷۱۰	-۷/۲۰۸	۰/۰۰۰
سراب	-۱/۵۶۸	۰/۱۱۷	-۱/۳۷۵	۰/۱۶۹	-۱۰/۶۶۱	۰/۰۰۰	-۶/۶۱۶	۰/۰۰۰
کلیر	-۶/۴۸	۰/۰۰۰	-۳/۸۸۵	۰/۰۰۰	-۰/۱۵۳	۰/۸۷۸	-۲/۵۴	۰/۰۱۱
مراغه	-۲/۴۴	۰/۰۱۵	-۱/۴۹۹	۰/۱۳۴	-۳/۸۶۹	۰/۰۰۰	-۲/۸۹۸	۰/۰۰۴
میانه	-۲/۰۵۲	۰/۰۴۰	-۲/۳۱۴	۰/۰۲۱	-۳/۸۳۸	۰/۰۰۰	-۲/۲۳۷	۰/۰۲۵
مرند	-۱۰/۱۲	۰/۰۰۰	-۱۷/۳۷۶	۰/۰۰۰	****	****	****	****
ورزقان	-۱۲/۸۷	۰/۰۰۰	-۱۱/۹۴۱	۰/۰۰۰	****	****	****	****
شستر	-۱۳/۲۹۷	۰/۰۰۰	-۰/۸۲۸	۰/۴۰۸	****	****	****	****
هریس	-۰/۱۴۱	۰/۸۸۸	-۱۷/۹۲۷	۰/۰۰۰	****	****	****	****
عجب شیر	-۴/۸۳۲	۰/۰۰۰	-۵/۵۳۷	۰/۰۰۰	****	****	****	****
بستان آباد	-۶/۳۳	۰/۰۰۰	-۱۳/۶۰۳	۰/۰۰۰	****	****	****	****
چاراویماق	-۴/۱۴۸	۰/۰۰۰	-۱۰/۴۹۸	۰/۰۰۰	****	****	****	****
ملکان	-۱۲/۱۱۳	۰/۰۰۰	-۱۰/۹۱۵	۰/۰۰۰	****	****	****	****

نتایج مدل بندی روی بارش ۲۴ ساعته در ایستگاه تبریز نشان داد که با انتخاب تعداد نرون های مختلف (از ۱۰ تا ۶۰ نرون) انجام تکرار فراوان، برای دوره های زمانی مختلف، شاخص MSE، ۶۲ درصد کاهش و شاخص همبستگی R نزدیک به ۳۰ درصد افزایش داشته است. برای مشاهده ی دقت عملکرد مدل مجموع بارش ماهانه مدل شبکه عصبی اصلاح شده ی WRF به همراه بارش مشاهداتی و همچنین مدل WRF در قالب نمودار سری زمانی ماهانه برای هر یک از دوره های زمانی ترسیم شد. نمودارها نشان دهنده ی عملکرد بهتر مدل اصلاح شده شبکه عصبی مدل WRF است.

کار مدل بندی و اصلاح مدل WRF روی ۱۶ ایستگاه استان

انجام شد. نتایج کار هر ایستگاه در قالب شاخص عملکرد MSE و R ارائه گردید. علاوه بر آن مقادیر خطای روزانه مدل اصلاح شده و مدل WRF به صورت نمودار فاصله اطمینان خطای ۹۵ درصد ترسیم شد. نتایج حاکی از کاهش ۷۰ تا ۸۶ درصدی شاخص MSE برای دوره ی زمانی ۶ ساعته، ۷۰ تا ۹۰ درصدی برای دوره ی زمانی ۱۲ ساعته، ۳۶ تا ۸۷ درصدی برای دوره ۱۸ ساعته و ۶۵ تا ۹۲ درصدی برای دوره ی زمانی ۲۴ ساعته دارد. همچنین شاخص همبستگی R برای کل ایستگاهها به طور متوسط ۳۴ تا ۵۱ درصد برای دوره ی زمانی ۶ ساعته، ۲۹ تا ۵۴ درصد برای دوره ی زمانی ۱۲ ساعته، ۱۱ تا ۵۷ درصد برای دوره ی زمانی ۱۸ ساعته و ۴۷ تا ۶۶ درصدی برای دوره ی ۲۴ ساعته

- temperature using Kalman filter, Journal of Earth and Space Physics, 2008, Volume 34, Issue 1; Page 45 to Page 61. (in Persian)
4. Azadi, Majid, Shirgholami, Mohammad Reza, Hijam, Sohrab, and Sahraian, Fatemeh. (2011). Postprocessing of WRF model output for daily rainfall in Iran. Iranian Water Resources Research, 7(4 (Issue 22)), 71-81. SID. <https://sid.ir/paper/100248/fa>. (in Persian)
 5. Azadi, Majid, Vashani, Saeed and Hijam, Sohrab (2011). Probabilistic Precipitation Forecasting Using Post-Processing of the Output of a Hamadi System, Quarterly Journal of Earth and Space Physics, 38(3), 203. magiran.com/p1069698. (in Persian)
 6. Biondi, Riccardo and Chkeir, Sandy and Anesiadou, Aikaterini and Mascitelli, Alessandra, 2022, Nowcasting Extreme Weather with Machine Learning Techniques Applied to Different Input Datasets. Available at SSRN: <https://ssrn.com/abstract=4144317>.
 7. Demuth, H., Beale, M., 2000. Neural Network Toolbox User's Guide. Copyright 1992-2002. BT The Math Works, Inc, Version 4, 840P.
 8. Faraji, Mozafar, Rezaei Banafsheh, Majid, Sari Sarraf, Behrouz, Mohammad Khorshiddoost, Ali. 2023, Numerical Simulation of Iranian Climate Change Using Artificial Neural Network Algorithm, Climate Change Research, 4(14), pp. 43-64. doi: 10.30488/ccr.2023.397215.1135. (in Persian)
 9. Espeholt, L., Agrawal, S., Sønderby, C. et al. 2022, Deep learning for twelve hour precipitation forecasts. Nat Commun 13, 5145 (2022). <https://doi.org/10.1038/s41467-022-32483-x>.
 10. F. Najib, Yusriadi, I. W. Mustika and S. Sulisty, 2023, Rainfall Prediction using Artificial Neural Network with Forward Selection Method, 2023 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT), BALI, Indonesia, 2023, pp. 102-107, doi:10.1109/IAICT59002.2023.10205930.
 11. Fulop, I.A., Jozsa, J., Karamer, T., 1998. A neural network application in estimating windinduced shallow lake motion. Hydro informatics, 98, 2, pp 753-757.

افزایش یافته است. همچنین نمودارهای خطای روزانه ۹۵ درصد مدل ها نشان داد که در تمام ایستگاهها میانگین خطای روزانه مدل اصلاح شده نسبت به مدل WRF به صفر نزدیک تر و مقادیر خطا بسیار کمتر است. آزمون معنی داری ویلکاکسن نیز نشان می دهد در اکثر ایستگاهها (به جز در دو تا چهار مورد بسته به دوره ی پیش بینی) بهبود مدل معنی دار است. لازم به ذکر است که بهبود مدل WRF در کل ایستگاهها یکسان نیستند. بنابراین با توجه به نتایج گرفته شده از این پژوهش می توان به این نتیجه ی کلی رسید که اگر از داده های برون داد مدل پیش بینی عددی وضع هوا به عنوان ورودی مدل های شبکه عصبی استفاده شود، نسبت به مدل های پیش بینی عددی وضع هوا برای پیش بینی بارش از دقت بیشتری برخوردارند. بنابراین می توان دقت خروجی مدل های عددی پیش بینی بارش را با استفاده از روش شبکه عصبی مصنوعی بهبود بخشید.

۵. تشکر و قدردانی

از سازمان هواشناسی کشور بخاطر اجازه دسترسی به سروهای آن جهت اخذ داده های مدل WRF تشکر و قدردانی می شود.

منابع

1. A. Chand and R. Nand, 2019, Rainfall prediction using Artificial Neural Network in the South Pacific region, IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE), Melbourne, VIC, Australia, 2019, pp. 1-7, doi: 10.1109/CSDE48274.2019.9162367.
2. A. Kala and S. G. Vaidyanathan, 2018, Prediction of Rainfall Using Artificial Neural Network, International Conference on Inventive Research in Computing Applications (ICIRCA), Coimbatore, India, 2018, pp. 339-342, doi: 10.1109/ICIRCA.2018.8597421.
3. Azadi, Majid, Jafari, Somayeh, Mirzaei, Ebrahim, Arabli, Parvin. (2008), Postprocessing of MM5 mesoscale model output for maximum and minimum

- Nov 2023, Vol 382, Issue 6677, pp. 1416-1421, DOI: 10.1126/science.adi2336.
23. Malboosi, Sharara, Seyed Mahdavi, Seyed Javad, Pakdaman, Morteza. 2014. 'Precipitation forecasting using deep neural networks (sparse stack autoencoder with hard neuron-based denoiser)', *Climatological Research*, 2014(50), pp. 201-215. (in Persian)
 24. Marzban, C., 2003, Neural network for post processing model output, *ARPS, Mon. Wea. Rev.*, 131, 1103-1111.
 25. Makhmisa Senekane, Mhlambululi Mafu, Molibeli Benedict Taele, 2020. Book chapter: Data Mining - Methods, Applications and Systems DOI: <http://dx.doi.org/10.5772/intechopen.84552>
 26. Mccollor, D. and Stull, R., 2008, Hydro meteorological accuracy enhancement via post processing of numerical weather forecasts in complex terrain, *Wea. Forecasting*, 23, 131-144.
 27. Mobasheri, Mohammad Reza, Pourbagerkerdi, Seyed Mehdi, Farajzadeh Asl, Manouchehr and Sadeghi Nayini, Ali, 2010. Estimation of Total Precipitable Water Using MODIS Satellite Images and Radiosound Data: Tehran Region, *Journal of the Humanities Lecturer*, 14(1), 107-126. magiran.com/p785823. (in Persian)
 28. Mohammadiha, Amir, Memarian, Mohammad Hossein, Azadi, Majid, Reyhani Parori, Mohammad. 2014. Investigation of WRF model predictions for precipitation and its relationship with precipitation estimates using Tehran radar data, *Iranian Journal of Geophysics*, 8(3), pp. (in Persian)
 29. Monache, L. D., Nipen, T., Liu, Y., Roux, G., and Stull, R., 2011, Kalman filter and analog schemes to post-process numerical weather predictions: *Monthly Weather Review*, 139, 3554-3570.
 30. Omidvar, Kamal, Nabavizadeh, Masoumeh. 2014. 'Predicting Daily Precipitation in Kerman Province with Artificial Neural Networks (Case Study: Kerman, Baft and Jiroft Midpoint)', *Regional Geography and Development*, 12(2), pp. -. doi: 10.22067/geography.v12i23.26991. (in Persian)
 31. Omidvar, Kamal, Nabavizadeh, Masoumeh, Samareh Ghasem, Meysam. 2015.
 12. Galanis, G., and Anadranistakis, M., 2002, A one-dimensional Kalman filter for the correction of near surface temperature forecasts: *Meteorological Applications*, 9, 437-441.
 13. Galanis, G., Louka, P., Katsafados, P., Kallos, G., and Pytharoulis, I., 2006, Applications of Kalman filter based on non-linear functions to numerical weather predictions: *Annals of Geophysics*, 24, 2451-2460.
 14. Gelman, A., Carlin, J.B., Stern, H.S., Dunson, D.B., Vehtari, A. and Rubin, D.B., 2013, *Bayesian data analysis*. Chapman and Hall/CRC.
 15. Glossary of Meteorology, 2012. American Meteorological Society. Retrieved 2014-11-13
 16. Haykin, Simon, 2001, *Neural Networks: A comprehensive Foundation*, An imprint of Pearson Education.
 17. Homleid, M., 1995, Diurnal corrections of short-term surface temperature forecasts using the Kalman filter: *Weather Forecast*, 10, 689-707.
 18. Ildarmi, Alireza, Zare Abyaneh, Hamid, Bayat Varkshi, Maryam. 2013. Precipitation estimation using artificial neural networks with non-rainfall meteorological data in three regions of Shiraz, Mashhad and Kerman, *Geography and Planning*, 17(43), pp. 21-40. (in Persian)
 19. Kalman, R. E., 1960, A new approach to linear filtering and prediction problems: *Journal of Basic Engineering*, 82(1), 35-45.
 20. Kalman, R. E., and Bucy, R. S., 1961. New results in linear filtering and prediction problems, *Trans. ASME, Ser. D.*, 83, 95-108.
 21. Khalili, Najmeh, Khodashenas, Saeed Reza, Davari, Kamran, and Mousavi Bayegi, Mohammad. 2010. Daily Precipitation Forecasting Using Artificial Neural Networks (Case Study: Mashhad Synoptic Station). *Watershed Management Research (Research and Construction)*, 23(4 (89)), 7-15. SID. <https://sid.ir/paper/200564/fa>. (in Persian)
 22. Lam, R., , Sanchez-Gonzalez, A., Willson, M., Wirnsberger, P., Fortunato, M., Alet, F., Ravuri, S. Ewalds, T., Eaton-Rosen, Z. and Battaglia, P. 2023. Learning skillful medium-range global weather forecasting, *Science*, 14

- Assessment of the Accuracy of the Recurrent Artificial Neural Network Narx in Forecasting Daily Precipitation in Kerman Province, *Natural Geography*, , 8(27), pp. 73-90. (in Persian)
32. Pirone D., Cimorelli L., Del Giudice G. and Pianese D., 2022. Rainfall Nowcasting Exploiting Machine-Learning Techniques: A Case Study in Southern Italy. *Environ. Sci. Proc.* 2022, 21(1), 49; <https://doi.org/10.3390/environsciproc2022021049>.
33. Taghavi, Farahnaz, Jalali, Mojtaba. 2014. 'Post-processing of the WRF Model Output for the Precipitation Water Parameter Using Satellite Data', *Iranian Journal of Geophysics*, 16(3), pp. 37-55. doi: 10.30499/ijg.2022.321906.1387. (in Persian)
34. Tao Chen and M. Takagi, 1993. Rainfall prediction of geostationary meteorological satellite images using artificial neural network, *Proceedings of IGARSS '93 - IEEE International Geoscience and Remote Sensing Symposium*, Tokyo, Japan, 1993, pp. 1247-1249 vol.3, doi: 10.1109/IGARSS.1993.322107.