



Investigating the Efficiency of the Multi-Model Ensemble System to Improve the Forecast Skill of Numerical Precipitation Models

Mitra Tanhapour¹ | Jaber Soltani² | Bahram Malekmohammadi³ |
Kamila Hlavcova⁴ | Mohammad Ebrahim Banihabib⁵

1. Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture and Natural Resources, University of Tehran, Tehran, Iran. E-mail: mitratanhapour@ut.ac.ir
2. Corresponding Author, Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture and Natural Resources, University of Tehran, Tehran, Iran. E-mail: jsoltani@ut.ac.ir
3. Department of Environmental Planning and Management, Graduate Faculty of Environment, University of Tehran, Tehran, Iran. E-mail: malekb@ut.ac.ir
4. Department of Land and Water Resources Management, Faculty of Civil Engineering, Slovak University of Technology, Bratislava, Slovakia. E-mail: kamila.hlavcova@stuba.sk
5. Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture and Natural Resources, University of Tehran, Tehran, Iran. E-mail: banihabib@ut.ac.ir

Article Info

ABSTRACT

Article type:

Research Article

Article history:

Received: October 18, 2022

Received in revised form:

January 20, 2023

Accepted: April 03, 2023

Published online: April 14, 2023

Keywords:

Ensemble precipitation forecasts,
GMDH model,
Multi-model ensemble,
Post-processing techniques,
Regression models.

The lead-time and accuracy of the precipitation forecasts have a substantial influence on the flood forecast and warning systems. This research aims to improve the skill of numerical precipitation models using post-processing techniques. In this regard, EPFs of three meteorological models, e.g., NCEP, UKMO, and KMA, were extracted for six precipitation events leading to flood in the Dez river basin. The statistical approaches and data-driven model were applied to post-process the EPFs. For this purpose, the raw forecast of every single model was corrected using linear and power regression models. Then, the corrected output of single models was combined using the proposed model of Group Method of Data Handling (GMDH) to construct the multi-model ensemble system. The results indicated that Power Regression Model (PRM) outperformed the mathematical linear models to correct raw forecasts. After correction of the dynamical models' output, more accurate results were obtained by NCEP and UKMO models. Moreover, the Multi-Model Ensemble (MME) system constructed by the GMDH model (MME_GMDH) had a great effect on the skill of numerical precipitation models, so that the Nash-Sutcliffe and normalized error (NRMSE) efficiency criteria for MME_GMDH respectively were improved on average 23 and 11 percent in comparison with the PRM. A comparative assessment of the discrimination capability of MME with single ensemble models using ROC curve at the thresholds of 2.5 and 10 mm represented a higher discrimination ability by MME_GMDH for both thresholds. Post-processed EPFs exert as a reliable input to the hydrological models for extreme events forecast.

Cite this article: Tanhapour, M., Soltani, J., Malekmohammadi, B., Hlavcova, K., & Banihabib, M. E. (2023). Investigating the Efficiency of the Multi-Model Ensemble System to Improve the Forecast Skill of Numerical Precipitation Models. *Journal of Water and Irrigation Management*, 13 (1), 275-293.

DOI: <https://doi.org/10.22059/jwim.2023.350086.1025>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2023.350086.1025>

Publisher: University of Tehran Press.



ارزیابی کارایی سامانه همادی چندگانه برای بهبود مهارت پیش‌بینی مدل‌های عددی بارش

میترا تنهاپور^۱ | جابر سلطانی^۲ | بهرام ملک‌محمدی^۳ | کامیلا هلاوجوا^۴ | محمد ابراهیم بنی‌حیب^۵

۱. گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشگاه تهران، تهران، ایران. رایانامه: mitratanhapour@ut.ac.ir
۲. نویسنده مسئول، گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشگاه تهران، تهران، ایران. رایانامه: jsoltani@ut.ac.ir
۳. گروه برنامه‌ریزی و مدیریت محیط زیست، دانشکده محیط زیست، دانشگاه تهران، تهران، ایران. رایانامه: malekb@ut.ac.ir
۴. گروه مدیریت منابع آب و خاک، دانشکده مهندسی عمران، دانشگاه فنی اسلواکی، براتیسلاوا، اسلواکی. رایانامه: kamila.hlavcova@stuba.sk
۵. گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشگاه تهران، تهران، ایران. رایانامه: banihabib@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	زمان پیش‌بینی های بارندگی اثر قابل ملاحظه‌ای بر سیستم‌های پیش‌بینی و هشدار سیلاب دارد. هدف این پژوهش، بهبود مهارت پیش‌بینی مدل‌های عددی بارش توسط تکنیک‌های پس‌پردازش است. در این راستا، پیش‌بینی همادی بارندگی سه مدل هواشناسی NCEP، UKMO و KMA برای شش رویداد بارش مولد سیلاب در حوضه ذ استخراج شد. جهت پس‌پردازش پیش‌بینی‌های همادی بارش از رویکردهای آماری و مدل داده‌محور استفاده شد. بدین‌منظور، پیش‌بینی خام هر مدل منفرد با استفاده از مدل‌های رگرسیونی خطی و توانی تصحیح شد. سپس به‌منظور ساخت سامانه همادی چندگانه، خروجی تصحیح شده مدل‌های منفرد توسط مدل پیشنهادی کنترل گروهی داده‌ها (GMDH) ترکیب شدند. نتایج نشان داد برای اصلاح پیش‌بینی‌های خام، عملکرد مدل‌های توانی بهتر از مدل ریاضی خطی است. پس از تصحیح برونداد مدل‌های دینامیکی، نتایج دقیق‌تری با استفاده از مدل‌های NCEP و UKMO بدست آمد. هم‌چنین، سامانه همادی چندگانه ساخته شده توسط مدل GMDH اثر قابل ملاحظه‌ای بر مهارت پیش‌بینی مدل‌های عددی بارش داشت، به‌گونه‌ای که معیارهای ارزیابی نش-ساتکلیف و خطای نرمال شده به‌طور متوسط ۲۳ درصد و ۱۱ درصد نسبت به مدل‌های ریاضی توانی بهبود یافتند. ارزیابی مقایسه‌ای قابلیت تفکیک‌پذیری مدل‌های همادی چندگانه با مدل‌های منفرد توسط متحنی ROC در دو سطح آستانه ۰/۲۵ و ۰/۱۰ میلی‌متر بیانگر توانایی تفکیک‌پذیری بالاتر مدل‌های همادی چندگانه در هر دو سطح آستانه بارش بود. پیش‌بینی‌های پس‌پردازش شده بارندگی همادی به عنوان یک ورودی قابل اعتماد برای مدل‌های هیدرولوژیکی جهت پیش‌بینی وقایع حدی به کار می‌آید.
کلیدواژه‌ها:	پیش‌بینی‌های همادی بارش، تکنیک‌های پس‌پردازش، مدل‌های رگرسیونی، مدل همادی چندگانه، مدل GMDH.
تاریخ دریافت:	۱۴۰۱/۰۷/۲۶
تاریخ بازنگری:	۱۴۰۱/۱۰/۳۰
تاریخ پذیرش:	۱۴۰۲/۰۱/۱۴
تاریخ انتشار:	۱۴۰۲/۰۱/۲۵

استناد: تنهاپور، م.، سلطانی، ج.، ملک‌محمدی، ب.، هلاوجوا، ک. و بنی‌حیب، م. (۱۴۰۲). ارزیابی کارایی سامانه همادی چندگانه برای بهبود مهارت پیش‌بینی مدل‌های عددی بارش. نشریه مدیریت آب و آبیاری، ۱۳(۱)، ۲۷۵-۲۹۳.



۱. مقدمه

دقت و زمان پیش‌بینی هشدار بارش از مهم‌ترین اجزای یک سیستم پیش‌بینی و هشدار سیلاب است. اولین مرحله برای پیش‌بینی مؤثر سیلاب، پیش‌بینی دقیق تر بارندگی با زمان پیش‌بینی هشدار کافی است (Hapuarachchi *et al.*, 2011; Wang *et al.*, 2022 2011; Chen *et al.*, 2020; Wu *et al.*, 2022). بارندگی یکی از مهم‌ترین متغیرهای ورودی در اکثر مدل‌های پیش‌بینی و هشدار سیلاب است که از طریق شبکه‌های رادار، باران‌سنج‌ها و یا بارندگی ناشی از مدل‌های پیش‌بینی عددی جو^۱ (NWP) تحت عنوان پیش‌بینی‌های همادی (گروهی)^۲ بارش (EPFs) به دست می‌آید (Liu *et al.*, 2021). مدل‌های عددی بارش به منظور غلبه بر محدودیت‌های مدل‌های قطعی توسعه و گسترش یافته‌اند. در مدل‌های قطعی، یک سناریو پیش‌بینی منفرد از وضعیت آینده بارش بدون درنظر گرفتن عدم قطعیت، فراهم می‌گردد. در حالی که پیش‌بینی‌های همادی به جای تولید یک پیش‌بینی قطعی منفرد از وضعیت آینده بارش، یک گروه یا مجموعه‌ای از حالت‌های محتمل آینده برای بارش تولید می‌کنند و بدین ترتیب عدم قطعیت را در پیش‌بینی‌ها لحاظ می‌کنند (Liu *et al.*, 2021). نظر به مزایای بالقوه پیش‌بینی‌های همادی، سازمان هواسناسی جهان از یک سیستم تحقیقاتی و ارزیابی قابلیت پیش‌بینی تحت عنوان پروژه بین‌المللی THORPEX جهت بهبود مهارت پیش‌بینی‌های همادی مراکز هواسناسی با یک روز تا دو هفته زمان پیش‌بینی هشدار، حمایت کرده است. پایگاه داده TIGGE^۳ به عنوان بخشی از پروژه مذکور، با جمع‌آوری پیش‌بینی‌های تولید شده توسط مراکز مختلف NWP، به منظور کمک به ارزیابی و بهبود دقت پیش‌بینی‌های همادی کوتاه‌مدت تا میان‌مدت، ایجاد شده است. این پایگاه داده، شامل مراکز هواسناسی متعددی نظیر مرکز ملی پیش‌بینی‌های زیست‌محیطی^۴ (NCEP)، مرکز پیش‌بینی میان‌مدت اروپا^۵ (ECMWF)، سازمان هواسناسی انگلیس^۶ (UKMO)، آژانس هواسناسی کره^۷ (KMA)، و دیگر مراکز می‌باشد که پیش‌بینی‌های گروهی کاربردی را در مقیاس‌های مختلف زمانی و مکانی در سطح جهان ارائه می‌کنند (Krishnamurti *et al.*, 2009; Tao *et al.*, 2014). در واقع این پیش‌بینی‌ها از طریق اعمال تغییرات کوچک در شرایط اولیه مدل‌های بارش و پارامترسازی فرایندهای فیزیکی مختلف ایجاد می‌شوند (Wu *et al.*, 2020; Jain *et al.*, 2018). به طور کلی، این مدل‌ها با حل مجموعه‌ای از معادلات دینامیکی و فیزیکی جو، قادر به فراهم کردن پیش‌بینی‌هایی با زمان پیش‌بینی هشدار طولانی‌تر نسبت به شبکه‌های رادار می‌باشند (Liguori *et al.*, 2012; Maddah *et al.*, 2021). بر همین اساس استفاده از این مدل‌ها به ویژه برای مدل‌سازی هیدرولوژیکی دارای اهمیت است.

ماهیت آشفته جو، منجر به ایجاد عدم قطعیت در پیش‌بینی‌های مدل‌های عددی بارش می‌شود. منشاً اصلی عدم قطعیت در پیش‌بینی‌های بارندگی ناشی از انتشار خطاهای کوچک در شرایط اولیه این مدل‌هاست و با توجه به ماهیت غیرخطی روابط در این مدل‌ها، این خطاهای کوچک در نهایت باعث ایجاد خطاهای بزرگ در برونداد مدل‌های عددی بارش می‌شوند (Sikder and Hossain, 2018). اگرچه استفاده از مدل‌های عددی بارش در افزایش زمان پیش‌بینی هشدار و اعمال عدم قطعیت در پیش‌بینی‌های هواسناسی مؤثر است (Maddah *et al.*, 2021)، اما با توجه به بزرگی عدم قطعیت پیش‌بینی‌های بارندگی مدل‌های عددی، کاربرد مستقیم برونداد خام این مدل‌ها در مدل‌سازی‌های هیدرولوژیکی، منجر به ایجاد خطاهای بزرگ در نتایج شبیه‌سازی‌ها می‌شود (Jha *et al.*, 2018). لذا پس پردازش برونداد خام این مدل‌ها به دلایلی نظیر دقت پایین برونداد خام مدل‌های عددی بارش جهت استفاده در شبیه‌سازی‌های هیدرولوژی و عدم تطابق مقیاس مکانی پیش‌بینی‌های همادی با پیش‌بینی‌های هیدرولوژیکی ضرورت دارد (Tao *et al.*, 2014).

یکی از راههای رفع مسائل ذکر شده در فوق، استفاده از رویکردهای آماری برای پسپردازش برونداد خام مدل‌های عددی بارش است. روش‌های آماری به طور وسیع در پژوهش‌های گذشته به منظور پسپردازش پیش‌بینی‌های گروهی استفاده شده است. برای نمونه Medina *et al.* (2019) کارایی رویکرد پسپردازش مبتنی بر آنالوگ را نسبت به روش رگرسیون لجستیک به منظور پسپردازش بارندگی همادی مراکز ECMWF و GEFS در بربازی، نشان دادند. در رویکردهای مبتنی بر آنالوگ پیش‌بینی‌های فعلی یک مرکز هواشناسی در برایر پیش‌بینی‌های گذشته همان مرکز، در یک دوره زمانی مشابه در سال، مقایسه می‌شود. همچنین Du *et al.* (2022) از تبدیل‌های توانی جهت پسپردازش بارندگی مدل‌های NWP در استرالیا استفاده کردند. آن‌ها پسپردازش توسط تبدیل‌های توانی را به سه روش مختلف شامل استفاده از ضرایب ثابت برای پارامترهای تبدیل توانی و ضرایب متغیر در مقیاس منطقه‌ای و محلی انجام دادند. نتایج پژوهش آن‌ها نشان داد استفاده از ضرایب متغیر عملکرد بهتری نسبت به ضرایب ثابت در رویکرد تبدیل توانی دارد. در پژوهشی Verkade *et al.* (2013) عملکرد سه رویکرد مختلف شامل روش نگاشت چندک، رگرسیون خطی و لجستیک جهت پسپردازش پیش‌بینی‌های همادی بارش و دما به عنوان ورودی به مدل پیش‌بینی جریان با یکدیگر مقایسه کردند. نتایج نشان داد روش نگاشت چندک در کاهش خطای پیش‌بینی جریان مؤثر بوده است. علاوه بر این، نتایج پژوهش Manzanas *et al.* (2019) بیانگر کارایی دو روش رگرسیون گوسین ناهمگن^۱ و نگاشت چندک برای اصلاح بایاس پیش‌بینی‌های همادی بارش و دما بود. به طور کلی، نتایج این پژوهش‌های گویای کارایی رویکردهای آماری جهت بهبود کیفیت پیش‌بینی مدل‌های عددی بارش است.

یکی دیگر از روش‌های ارتقای مهارت پیش‌بینی مدل‌های عددی، تلفیق برونداد چند مدل NWP به جای استفاده از یک مدل هواشناسی منفرد است. بسیاری از پژوهش‌گران از تکنیک ترکیب داده‌ها برای پسپردازش مدل‌های NWP استفاده کردند. در این راستا، Pakdaman *et al.* (2022) از مدل‌های شبکه عصبی مصنوعی و جنگل تصادفی جهت ترکیب بارش ماهانه چهار مدل همادی آمریکای شمالی^۹ (NMME) در جنوب‌غرب آسیا استفاده کردند. یافته‌های پژوهش آن‌ها نشانگر عملکرد بهتر مدل جنگل تصادفی نسبت به شبکه عصبی برای بهبود مهارت پیش‌بینی مدل‌های همادی بود. در پژوهشی دیگر، Saedi *et al.* (2020) کارایی رویکرد میانگین‌گیری بیزین به منظور ساخت یک سامانه همادی بزرگ متشکل از پنج مدل همادی پایگاه داده TIGGE جهت پسپردازش پیش‌بینی‌های بارش در حوضه‌های واقع در شمال و غرب ایران را نشان دادند. همچنین Fallah Kalaki *et al.* (2020) از مدل رگرسیون خطی چندگانه برای ترکیب هفت مدل بارندگی همادی آمریکای شمالی در حوضه کرخه استفاده کردند. ارزیابی‌ها در سه افق زمانی یک تا سه ماه انجام شده است. نتیجه پژوهش آن‌ها بیانگر عملکرد بهتر مدل همادی چندگانه ساخته شده نسبت به مدل‌های منفرد بود. تحقیقات مشابه توسط پژوهش‌گران دیگر (Wei we al., 2022; Osman *et al.*, 2021) در زمینه ترکیب برونداد مدل‌های NWP جهت بهبود مهارت پیش‌بینی آن‌ها انجام شده است. بنابراین ارزیابی‌ها نشان می‌دهد کاربست ترکیبی از مدل‌های NWP می‌تواند تأثیر بهسزایی در افزایش اعتمادپذیری پیش‌بینی‌های همادی بارش داشته باشد.

اکثر روش‌های پسپردازش استفاده شده در پژوهش‌های قبل، به یک مجموعه داده بزرگ بارندگی (حدود چندین سال) نیاز دارد. در واقع نیاز به مجموعه داده بزرگ، استفاده از این روش‌ها را برای کاربردهای عملیاتی بهویژه در حوضه‌های فاقد آمار با محدودیت مواجه می‌کند. لذا در این مطالعه برای برطرف کردن این محدودیت، مدل پیشنهادی کنترل گروهی داده‌ها^{۱۰} (GMDH) به منظور ترکیب داده‌های بارش و ساخت سامانه همادی بزرگ توسعه داده شده است. از طرف دیگر تا به حال کارایی مدل GMDH برای بهبود مهارت پیش‌بینی‌های همادی بارندگی بررسی نشده است. ارزیابی‌ها نشان می‌دهد این مدل در موارد محدودی برای پیش‌بینی جریان (Adnan *et al.*, 2021; Mehri *et al.*, 2021)

(2019)، تخمین فرسایش و بار معلق (Safari *et al.*, 2019) و پیش‌بینی سطح آب زیرزمینی (Jahanara and Khodashenas, 2019) استفاده شده است.

با توجه به توضیحات فوق الذکر، هدف این پژوهش ارزیابی قابلیت رویکردهای آماری و داده‌محور جهت بهبود مهارت پیش‌بینی مدل‌های عددی بارش است. بدین‌منظور از مدل‌های عددی NCEP، UKMO و KMA مستخرج از پایگاه داده TIGGE استفاده شد. هم‌چنین جهت تصحیح بروون‌داد خام مدل‌های عددی بارش از مدل‌های رگرسیونی خطی و غیرخطی و سپس به‌منظور ترکیب بروون‌داد تصحیح شده مدل‌های منفرد همادی بارش، از مدل GMDH استفاده شده است. در انتها نتایج مربوطه برای قبل و بعد از پس‌پردازش داده‌های بارش با یکدیگر مقایسه شده است.

۲. مواد و روش‌ها

در مطالعه حاضر برای کمی کردن عدم قطعیت پیش‌بینی بارندگی، از مدل‌های پیش‌بینی عددی جو استفاده شد. شکل (۱) فلوچارت روند پژوهش را نشان می‌دهد. براساس این شکل، ابتدا بارش همادی برای سه مدل هواشناسی NCEP و UKMO و KMA به‌ازای شش واقعه بارندگی مولد سیلان استخراج شد. پس از درونیابی داده‌های مستخرج مربوط به ایستگاه‌های بارندگی در حوضه، دقت خروجی خام مدل‌های هواشناسی نسبت به بارندگی مشاهداتی برآورد شد. پس‌پردازش داده‌های بارندگی در دو مرحله انجام شد. در مرحله اول، مدل‌های رگرسیونی خطی و غیرخطی بر روی میانگین اعضای همادی هر مدل منفرد NWP برازش داده شد. سپس مدل رگرسیونی برتر براساس معیارهای ارزیابی در مراحل آموزش و آزمون تعیین گردید و از آن جهت تصحیح کلیه اعضای همادی بارش استفاده شد. در مرحله دوم، جهت ساخت مدل همادی چندگانه، بروون‌داد تصحیح شده مدل‌های منفرد NWP توسط مدل GMDH با یکدیگر ترکیب شد. درنهایت جهت تعیین میزان بهبود در مهارت پیش‌بینی مدل‌های NWP، نتایج حاصل برای قبل و پس از پس‌پردازش داده‌های بارندگی با یکدیگر مقایسه شد.

۳. ا. منطقه مطالعاتی و داده‌ها

حوضه رودخانه ذ در جنوب‌غرب ایران و از زیرحوضه‌های کارون بزرگ، در حد فاصل مختصات جغرافیایی ۳۲ درجه و ۴۳ دقیقه تا ۳۴ درجه و ۰۷ دقیقه عرض شمالی و ۴۸ درجه و ۱۱ دقیقه طول شرقی گسترده شده است. عمدۀ مساحت این حوضه در استان‌های لرستان و خوزستان واقع شده است. هم‌چنین بخشی از مساحت حوضه در استان‌های اصفهان و مرکزی واقع شده است. رودخانه ذ از تلاقی دو رودخانه بختیاری و سزار در محل تنگ‌پنج واقع در مسیر راه‌آهن دورود- اندیمشک تشکیل می‌شود (Tanhapour *et al.*, 2022).

مساحت این حوضه ۱۶۲۱۳ کیلومترمربع، متوسط ارتفاع ۱۹۷۶ متر از سطح دریا و متوسط بارش سالانه ۷۸۴ میلی‌متر است. هم‌چنین این حوضه از شمال با حوضه زاینده‌رود، از شرق و جنوب با حوضه کارون و از غرب با حوضه کرخه هم‌مرز است. شکل (۲) موقعیت مکانی حوضه ذ و ایستگاه‌های بارندگی سینوپتیک را نشان می‌دهد. وقوع سیلان‌های Malekmohammadi *et al.*, 2010; Samadi *et al.*, 2010; Samadi *et al.*, 2019 بر همین اساس، این مطالعه بر روی شش رویداد بارش مولد سیلان‌های سنگین در محدوده سالی ۱۳۹۸-۱۳۹۱ انجام شده است. مشخصات رویدادهای بارندگی در جدول (۱) ارائه شده است.

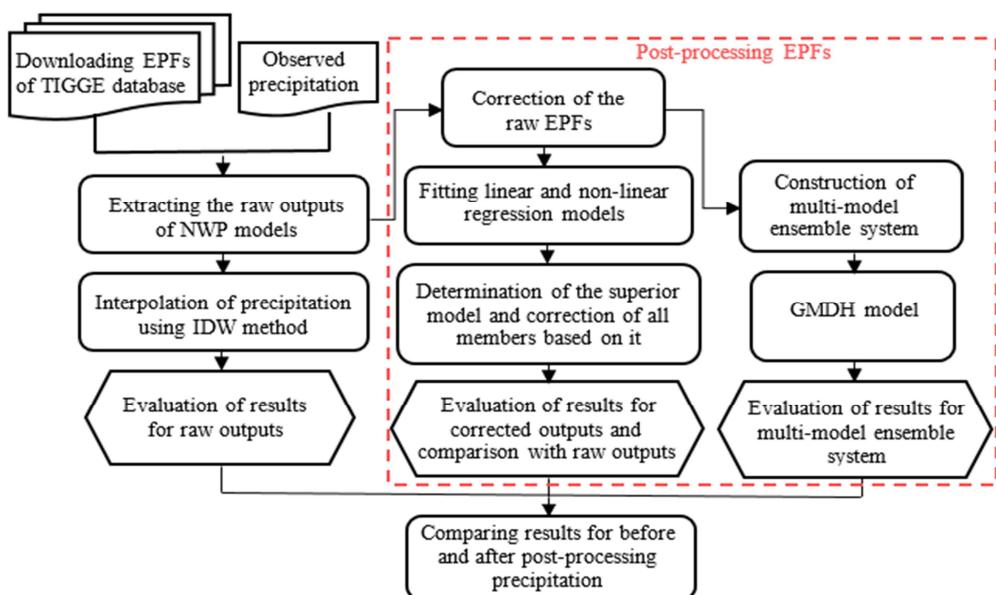


Figure 1. Flowchart of the methodology used in this research

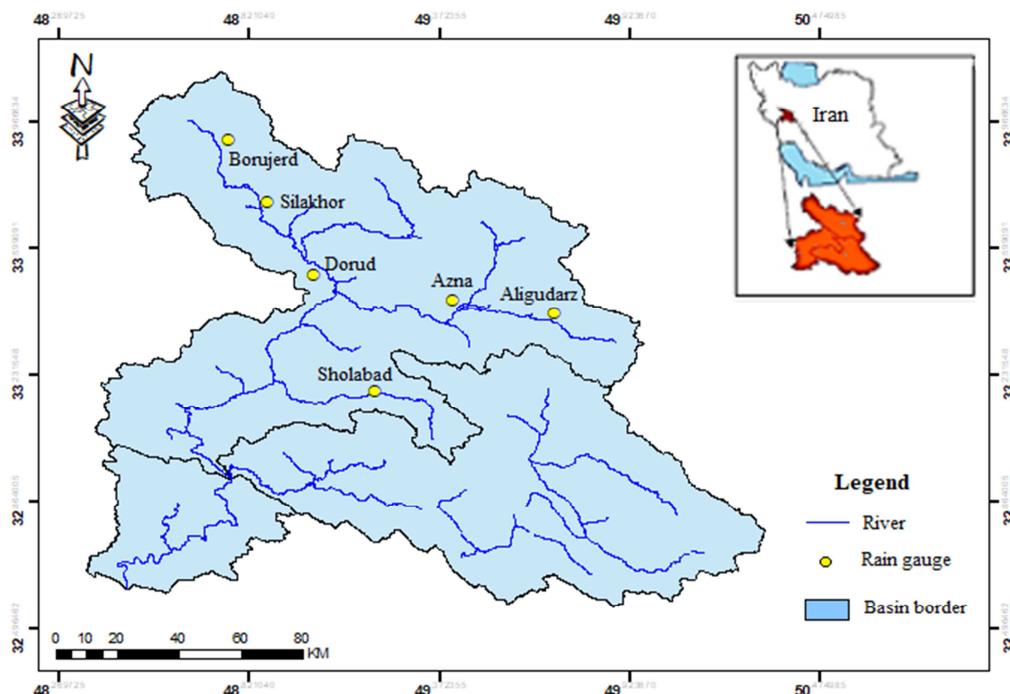
Table 1. Characteristics of precipitation events in the studied area

No	Date of start	Date of end	Time (hr)	Precipitation depth (mm)
1	28.01.2013	29.01.2013	48	31.33
2	25.12.2016	28.12.2016	84	101.26
3	22.03.2017	24.03.2017	72	37.93
4	16.02.2018	18.02.2018	72	48.80
5	23.02.2018	25.02.2018	72	19.67
6	31.03.2019	01.04.2019	48	104.39

داده‌های بارش همادی برای سه مدل UKMO NCEP و KMA از پایگاه داده TIGGE برای وقایع بارش مذکور در محدوده منطقه مطالعاتی پژوهش استخراج شد. مشخصات مدل‌های بارش استفاده شده در پژوهش حاضر در جدول (۲) ارائه شده است. هر مدل هواشناسی در این پایگاه داده دارای قدرت تفکیک افقی متفاوت است که با استفاده از روش درونیابی دوخطی با قدرت تفکیک یکسان در دسترس قرار می‌گیرد. همچنین، پیش‌بینی‌های بارش در این پایگاه داده در گام‌های زمانی شش ساعته (صفر، شش، ۱۲ و ۱۸) بهروزرسانی می‌گردد. بر همین اساس در مطالعه حاضر از داده‌های بارش همادی شش ساعته با قدرت تفکیک 0.5×0.5 درجه و زمان پیش‌بندی ۲۴ ساعته استفاده شده است. لازم به ذکر است که پیش‌بینی‌های مربوط به هر یک از ایستگاه‌های بارندگی با استفاده از روش میانیابی نزدیک‌ترین همسایگی استخراج شد. همچنین، جهت ارزیابی صحت داده‌های بارش پیش‌بینی شده، از اطلاعات ایستگاه‌های بارندگی سینوپتیک ارائه شده در شکل (۲) که دارای آمار کامل بودند به عنوان بارش مشاهداتی استفاده شد. لازم به ذکر است که به دلیل عدم ثبت داده‌های بارش ساعتی مولد سیلاب در زیرحوضه بختیاری به‌ازای کلیه وقایع سیلاب منتخب در بازه زمانی سال‌های ۹۸-۱۳۹۱ از اطلاعات بارندگی این زیرحوضه استفاده نشده است. سپس بارندگی‌های شش ساعته مستخرج در محل ایستگاه‌ها توسط روش وزن‌دهی عکس فاصله^{۱۱} (IDW) در سراسر حوضه درونیابی شد. از آنجاکه روش IDW یکی از رویکردهای متداول برای درونیابی بارندگی جهت ورود به مدل‌های هیدرولوژیکی است و همچنین به دلیل قابلیت ارائه نتایج رضایت‌بخش برای شبیه‌سازی جریان توسط این روش، از آن جهت درونیابی بارش استفاده شده است (Gilewski, 2022; Aminyavari *et al.*, 2019; Tanhapour *et al.*, 2022).

Table 2. Characteristics of the numerical precipitation models used in this research

Center	Forecast length (day)	Model resolution (lon×lat)	Number of ensemble members	Base time (UTC)
NCEP	16	1.00°×1.00°	20	00/06/12/18
UKMO	15	0.83°×0.56°	23	00/12
KMA	10	1.00°×1.00°	24	00/12

**Figure 2. The location of the Dez basin and rain gauges**

۲.۰.۲. مدل‌های رگرسیونی

پس از استخراج داده‌های بارش مشاهداتی و پیش‌بینی شده توسط مدل‌های عددی، جهت تصحیح و پس‌پردازش داده‌های پیش‌بینی شده نسبت به بارش مشاهداتی، از رویکرد آماری مدل‌های رگرسیونی توانی^{۱۲} (PRM) و خطی استفاده شد (Du *et al.*, 2022; Theoccharides *et al.*, 2020). در مدل‌های رگرسیونی متغیر ورودی (پیش‌بینی‌کننده) و متغیر خروجی (پیش‌بینی‌شونده) به ترتیب به عنوان متغیرهای مستقل و وابسته شناخته می‌شوند. زمانی که معادله رگرسیونی تنها از یک متغیر مستقل تشکیل شود، معادله رگرسیونی ساده و در صورتی که دارای بیش از یک متغیر مستقل باشد، معادله رگرسیونی چندگانه می‌باشد. از آنجاکه در پژوهش حاضر، هدف از به کارگیری این روش تصحیح و پس‌پردازش برون‌داد هر مدل منفرد بارش به صورت مجزا بوده است، از مدل رگرسیونی ساده استفاده شده است که فرم کلی مدل‌های ریاضی توانی و خطی به صورت روابط (۱) و (۲) است (Du *et al.*, 2022):

$$P_o = aP_r^b \quad (1)$$

$$P_o = a + bP_r \quad (2)$$

در روابط فوق، P_o بارش مشاهداتی و P_r برون‌داد خام پیش‌بینی شده مدل‌های NWP و a و b ضرایب معادلات هستند. در مدل‌های رگرسیونی ضرایب به گونه‌ای برآورد می‌شوند که مجموع مربعات خطای بین متغیر وابسته و مستقل

حدائق شود. در این پژوهش، برای هر مدل منفرد عددی بارش، معادلات رگرسیونی توانی و خطی به صورت مجزا بین میانگین بروندامنی کلیه عضوهای همدادی بارش (متغیر مستقل) و بارش مشاهداتی متناظر (متغیر وابسته) بارش داده شده‌اند. همچنین ۷۰ درصد داده‌ها به صورت تصادفی برای آموزش و ۳۰ درصد برای آزمون در نظر گرفته شد (Theocharides *et al.*, 2020). سپس ارزیابی روابط براساس شاخص‌های نش-ساتکلیف و میانگین مطلق خطا در هر دو مرحله آموزش و آزمون صورت گرفت و از معادله رگرسیونی برتر به منظور پس‌پردازش کلیه عضوهای مدل‌های عددی بارش استفاده شد.

۴.۳. مدل GMDH

GMDH یک رویکرد اکتشافی خود-سازمانده است که رابطه بین متغیرهای ورودی و خروجی یک سیستم پیچیده را با استفاده از توابع انتقال دو جمله‌ای به صورت یک شبکه چندلایه پیش‌رو مدل‌سازی می‌کند. ساختار کلی این الگوریتم بدین صورت است که در ابتدا هیچ اطلاعی در مورد سیستم ندارد. بدین‌ترتیب تعداد نرون‌های لایه اول معادل با تعداد متغیرهای ورودی است. در لایه دوم، کلیه ترکیب‌های دو متغیره ممکن بین متغیرهای ورودی در لایه قبل تولید و با یکدیگر مقایسه می‌شود تا بهترین برازش ممکن برای متغیر خروجی به دست آید. به طور کلی، اگر n متغیر ورودی داشته باشیم، تعداد $n(n-1)/2$ نرون در لایه دوم و لایه‌های بعدی خواهیم داشت که هر نرون متشکل از ترکیب دوتایی از متغیرهای ورودی آن است (Shaghaghi *et al.*, 2017). بنابراین، هر چه تعداد لایه‌ها بیشتر می‌شود، تعداد نرون‌ها بیشتر می‌شود و رفتارهای مدل پیچیده‌تر می‌شود. به همین علت، در هر لایه از شبکه، یک آستانه خودگزین^{۱۳} به منظور فیلتر کردن نرون‌هایی که در پیش‌بینی متغیر خروجی نقشی ندارند، به کار می‌رود. تنها نرون‌هایی که شاخص عملکرد آن‌ها از مقدار آستانه تجاوز می‌کند، به لایه بعد منتقل می‌شوند. این فرایند تا زمانی که به یک نتیجه رضایت‌بخش برسد، تکرار می‌شود (Walton *et al.*, 2019; Shaghaghi *et al.*, 2017). شکل (۳) ساختار کلی الگوریتم GMDH و تبدیل متغیرهای ورودی- خروجی را نشان می‌دهد.

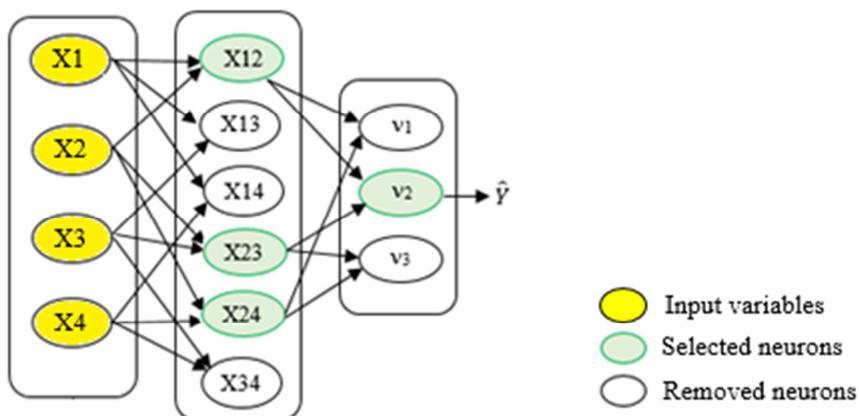


Figure 3. General structure of the GMDH model with four input variables and two hidden layers

مدل GMDH از چند جمله‌ای کلموگروف-گابور (رابطه ۳) برای توصیف رابطه بین متغیرهای ورودی و خروجی استفاده می‌کند (Chang and Hwang, 1999).

$$Y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad \text{رابطه ۳}$$

در رابطه فوق، $(x_1, x_2, \dots, x_n) = X$ بردار متغیرهای ورودی و $A = (a_1, a_2, \dots, a_n)$ ضرایب و در واقع مجهولات رابطه است. اگر چندجمله‌ای فوق به طور مستقیم به منظور تخمین ضرایب معادله استفاده شود، زمانی که تعداد ورودی‌های مسئله زیاد است، تعداد پارامترهای رابطه فوق افزایش می‌یابد و لذا تخمین همزمان کلیه پارامترها برای شبکه مشکل است. بر همین اساس، مدل GMDH با ترکیب کلیه چندجمله‌ای‌های جزیی دو متغیره در یک ساختار چند لایه‌ای، این مسئله را برطرف می‌کند. فرایند اصلی که توسط مدل دنبال می‌شود در ادامه شرح داده می‌شود:

گام اول) انتخاب متغیرهای ورودی: در این مرحله کلیه متغیرهای ورودی به عنوان نرون‌های لایه اول در نظر گرفته می‌شوند.

گام دوم) تقسیم داده‌ها به دو مجموعه آموزش و تست

گام سوم) ساخت نرون‌های جدید: هر نرون در شبکه GMDH دارای دو متغیر ورودی (برای نمونه x_1 و x_2) است که برای تخمین مقدار متغیر خروجی، از ترکیب چندجمله‌ای جزیی دو متغیره استفاده می‌کند. بدین ترتیب،تابع انتقال هر نرون توسط رابطه (۴) بیان می‌شود:

$$Y = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1^2 + a_4 x_2^2 + a_5 x_1 x_2 \quad \text{رابطه (۴)}$$

در معادله فوق ضرایب $\{a_0, a_1, \dots, a_5\}$ ضرایب مجهول هستند که برای تخمین آن‌ها از روش حداقل مربعات استفاده می‌شود، طوری که معادله، بهترین تطابق را با متغیر خروجی (Y) داشته باشد.

گام چهارم) انتخاب نرون‌های برتر: پس از برآورد ضرایب مجهول در گام قبل، یک معیار آستانه بهمنظور فیلترکردن نرون‌هایی که اثر کمتری دارند، تعیین می‌شود. در این پژوهش حداقل کردن جذر میانگین مربعات خطأ به عنوان معیار آستانه استفاده شد. بدین ترتیب تها بهترین نرون‌ها که قدرت پیش‌بینی بهتری نسبت به نسل قبل دارند مجاز هستند به لایه بعد منتقل شوند.

گام پنجم) در این مرحله بهترین نتایج لایه موجود با لایه قبل مقایسه می‌شود. اگر نتایج بهبود نیابد، فرایند متوقف می‌شود. در غیر این صورت دوباره به گام سوم برمی‌گردد.

گام ششم) محاسبه مقادیر پیش‌بینی شده: مدل پیش‌بینی را می‌توان با استفاده از نرون‌های باقی‌مانده در لایه آخر به دست آورد (Chang and Hwang, 1999).

در این پژوهش، متغیرهای ورودی شبکه، مقادیر پیش‌بینی شده بارش توسط مدل‌های NWP است و متغیر خروجی، مقادیر مشاهداتی بارندگی می‌باشد. هم‌چنین ۷۰ درصد داده‌های بارش مربوط به هر عضو به صورت تصادفی برای آموزش شبکه و ۳۰ درصد برای آزمون انتخاب شدند (Theocharides et al., 2020). همان‌گونه که دیده می‌شود ساختار این مدل، مشابه شبکه عصبی مصنوعی است با این تفاوت که برای تعداد لایه‌ها و نرون‌ها یک مقدار اولیه توسط کاربر در مرحله آموزش تعیین می‌شود و سپس مقدار بهینه آن‌ها در طی فرایند آموزش براساس معیار آستانه به دست می‌آید. ازانجاکه این مدل جهت تخمین متغیر خروجی از تفکیک اطلاعات به صورت کارآمد و ناکارآمد استفاده می‌کند، نسبت به مدل شبکه عصبی دقت بالاتری دارد و به تعداد داده‌های مشاهداتی زیادی نیاز ندارد (Kardan Moghaddam et al., 2021). به همین علت در این پژوهش جهت ترکیب برونداد مدل‌های مختلف عددی بارش از مدل GMDH استفاده شده است.

۲.۴. راستی آزمایی پیش‌بینی‌های پس‌پردازش شده

میزان صحت پیش‌بینی‌های پس‌پردازش شده نسبت به بارش مشاهداتی، توسط شاخص‌های عملکرد ارائه شده در جدول (Fallah Kalaki et al., 2020) ارزیابی شده است.

Table 3. Evaluation metrics for verification of the post-processed precipitation forecasts

Evaluation metrics	Equation	Description	Best fit/ Poorest fit
Nash-Sutcliffe Efficiency	$NSE = 1 - \frac{\sum(O - F)^2}{\sum(O - \bar{O})^2}$	Measure of the relative magnitude of the residual variance compared to the observed data variance	1/-∞
Kling-Gupta Efficiency	$KGE = 1 - \sqrt{(1 - r)^2(1 - \beta)^2(1 - \gamma)^2}$	A function of correlation, bias, and variability	1/-∞
Pearson coefficient	$r = \frac{\sum(O - \bar{O})(F - \bar{F})}{\sqrt{(O - \bar{O})^2} \sqrt{(F - \bar{F})^2}}$	Capability of linear relationship between observed and forecasted data	1/-1
Normalized Root Mean Square Error	$NRMSE = \sqrt{\frac{1}{N} \sum(O - F)^2}$	The difference between observed and forecasted data	0/
Mean Absolute Error	$MAE = \frac{1}{N} \sum O - F $	The difference between observed and forecasted data	0/

Note: O and F respectively represent the observed and forecasted precipitation data; \bar{O} and \bar{F} denote observed mean forecasted men; N is total number of the precipitation records; β is the bias ratio ($\beta = \bar{F} / \bar{O}$); γ is the variability between forecasted and observed values ($\gamma = CV_F / CV_O$); CV is the coefficient of variations.

علاوه بر شاخص‌های ارائه شده در جدول فوق، از منحنی مشخصه عملکرد^۴ (ROC) برای ارزیابی توانایی تفکیک‌پذیری پیش‌بینی‌های احتمالاتی نسبت به مشاهدات بارندگی دسته‌بندی شده (برای نمونه مقادیر بارندگی بزرگ‌تر یا کوچک‌تر از یک آستانه مشخص) استفاده شده است (D'Onofrio *et al.*, 2010; Jha *et al.*, 2018). در حالت کلی، اگر مقدار بارندگی بیش‌تر از آستانه مشخص باشد، می‌توان گفت واقعه بارش رخ داده است (وقوع پدیده). در غیر این صورت، واقعه بارندگی رخ نداده است (عدم وقوع پدیده). روش تولید دیاگرام ROC بدین صورت است که اگر تعداد کل مجموعه داده N باشد، می‌توان آن را به دو زیرمجموعه وقوع و عدم وقوع به صورت O' و $O = O + O'$ تقسیم کرد (جدول ۴). براساس جدول (۴)، وقوع یا عدم وقوع پدیده مربوط به داده‌های بارش مشاهداتی و همین‌طور هشدار و عدم هشدار مربوط به بارش پیش‌بینی شده است. H تعداد دفعاتی است که پدیده رخ داده و وقوع آن پیش‌بینی شده است (یا هشدار صادر شده است). FA تعداد دفعاتی است که هشدار صادر می‌شود اما در واقعیت پدیده رخ نداده است. MA بیانگر تعداد دفعاتی که پدیده رخ می‌دهد در حالی که هشداری برای آن صادر نشده است و CN نشانگر عدم وقوع پدیده و عدم صدور هشدار می‌باشد (D'Onofrio *et al.*, 2010). براساس توضیحات مذکور، آهنگ برخورد^۵ (HR) به صورت نسبت وقایع مشاهداتی وقوع که به درستی پیش‌بینی شدند تعریف می‌شود ($HR = H/O$) و نرخ هشدار غلط^۶ (FAR) بیانگر درصد وقایع مشاهداتی عدم وقوع است که به اشتباه پیش‌بینی شدند ($FAR = FA/O'$).
بدین ترتیب منحنی ROC از ترسیم مقادیر آهنگ برخورد در برابر نرخ هشدار غلط برای جفت داده متناظر مشاهداتی-پیش‌بینی حاصل می‌شود. هرچه فاصله منحنی نسبت به خط مورب بیش‌تر باشد (منحنی بیش‌تر به سمت بالا سمت چپ دیاگرام متمایل باشد) توانایی تفکیک‌پذیری پیش‌بینی بیش‌تر است. در این پژوهش، دیاگرام ROC برای دو سطح آستانه بارش $2/5$ و 10 میلی‌متر که به ترتیب بیانگر آستانه بارش‌های کوچک و سنگین می‌باشند، ترسیم شده است (Zakeri *et al.*, 2014).

Table 4. Contingency table for ROC curve

Observed Forecasted	Occurrence	Non-occurrence	Total
Alarm	H	FA	A
No-Alarm	MA	CN	A'
Total	O	O'	N

Note: H, FA, MA, and CN relatively are hit, false alarm, miss alarm, and correct no-alarm

۳. نتایج و بحث

یکی از گام‌های اساسی برای بهبود مهارت پیش‌بینی مدل‌های عددی وضع هوا و افزایش کارایی آن‌ها، استفاده از

تکنیک‌های پس‌پردازش است. در این بخش ابتدا نتایج مربوط به تصحیح و پس‌پردازش مدل‌های پیش‌بینی عددی بارش با استفاده از مدل‌های رگرسیونی خطی و غیرخطی ارائه می‌شود و سپس قابلیت مدل GMDH جهت ترکیب بروون داد تصحیح شده هر یک از مدل‌های همادی استفاده شده، با استفاده از مجموعه شاخص‌های آماری ارزیابی خواهد شد. در انتهای بهمنظور ارزیابی میزان تأثیر کاربرد مدل‌های همادی چندگانه (ترکیبی) نسبت به پیش‌بینی‌های خام و تصحیح شده مدل‌های منفرد، نتایج حاصل با یکدیگر مقایسه می‌شود.

۱.۳. تصحیح پیش‌بینی‌های همادی بارندگی

در این مطالعه به منظور تصحیح پیش‌بینی‌های خام هر یک از مدل‌های عددی، از مدل‌های رگرسیونی استفاده شده است. نتایج پس‌پردازش بروون داد خام مدل‌های عددی با استفاده از مدل رگرسیونی خطی در جدول (۵) و مدل رگرسیونی غیرخطی توانی (PRM) در جدول (۶) ارائه شده است. مدل‌های رگرسیونی ذکر شده بین مقادیر مشاهداتی بارندگی و متوسط اعضای همادی به صورت مجزا برای هر یک از مدل‌های NWP برآراش داده شده است. ارزیابی نتایج، براساس معیارهای نش-ساتکلیف (NSE) و میانگین قدرمطلق خطای (MAE) در هر دو مرحله آموزش و آزمون انجام شده است. مقایسه مقادیر معیارهای ارزیابی جدول‌های (۵) و (۶) نشان می‌دهد مدل‌های رگرسیونی توانی با اختلاف اندکی نسبت به مدل‌های رگرسیونی خطی، دقت بالاتری دارند. از آنجاکه همبستگی بین مقادیر مشاهداتی بارندگی با بروون داد خام مدل‌های NWP با استفاده از مدل‌های رگرسیونی توانی نسبت به مدل‌های ریاضی خطی بیشتر و میانگین خطای در مجموع بهازای مرحله آموزش و آزمون کمتر می‌باشد، از مدل‌های رگرسیونی غیرخطی برای پس‌پردازش و تصحیح کلیه اعضای همادی هر یک از مدل‌های عددی در این مطالعه استفاده شده است.

Table 5. Linear regression model and efficiency criteria for post-processing the ensemble precipitation forecasts

NWP models	Linear regression models	Evaluation metrics			
		Train		Test	
		NSE	MAE	NSE	MAE
NCEP	$P_O = -0.184 + 1.191P_r$	0.531	2.838	0.651	2.108
KMA	$P_O = -0.933 + 1.205P_r$	0.518	3.115	0.51	2.725
UKMO	$P_O = 0.038 + 0.841P_r$	0.473	2.704	0.462	2.671

Note: P_O is the observed precipitation and P_r is the raw EPFs

Table 6. Power regression model and efficiency criteria for post-processing the ensemble precipitation forecasts

NWP models	Power regression models	Evaluation metrics			
		Train		Test	
		NSE	MAE	NSE	MAE
NCEP	$P_O = 1.021 P_r^{1.059}$	0.532	2.816	0.651	2.107
KMA	$P_O = 0.485 P_r^{1.35}$	0.53	2.972	0.5	2.658
UKMO	$P_O = 1.032 P_r^{0.914}$	0.541	2.701	0.513	2.682

Note: P_O is the observed precipitation and P_r is the raw EPFs

بهمنظور ارزیابی میزان تأثیر عملیات تصحیح و پس‌پردازش مدل‌های NWP توسط مدل PRM بر بهبود مهارت پیش‌بینی این مدل‌ها، نتایج حاصل از پیش‌بینی‌های پس‌پردازش شده نسبت به داده‌های خام در جدول (۷) با یکدیگر مقایسه شده است. علاوه بر این، درصد تغییرات در بهبود نتایج به تفکیک هر یک از مدل‌ها نیز در این جدول ارائه شده است. براساس نتایج ارائه شده در این جدول، برای هر سه مدل NWP و بهازای کلیه معیارهای ارزیابی، مهارت پیش‌بینی داده‌های پس‌پردازش شده نسبت به بروون داد خام این مدل‌ها بهبود یافته است. نظر به مقادیر معیارهای ارزیابی نش-ساتکلیف و میانگین مطلق خطای درصد تغییرات آن‌ها برای مدل NCEP (به ترتیب چهار و ۱۵ درصد) و همچنین مدل UKMO

(بهترتب شش و ۲۰ درصد) می‌توان گفت پس از تصحیح داده‌ها، مدل‌های NCEP و UKMO نتایج پیش‌بینی دقیق‌تری ارائه داده‌اند. همچنین بهدلیل اینکه مدل UKMO، حداکثر درصد تغییرات در بهبود مهارت پیش‌بینی داده‌های پس‌پردازش شده نسبت به داده‌های خام بهازای معیارهای ارزیابی MAE و NRMSE (بهترتب هر یک به میزان ۱۲ درصد و ۲۰ درصد) به خود اختصاص داده است، می‌توان گفت میزان بهبود نتایج پس از تصحیح داده‌ها توسط مدل PRM، برای مدل UKMO نسبت به دیگر مدل‌ها تغییرات محسوس‌تری دارد. لازم به ذکر است بهدلیل این که پس از تصحیح برونو داد مدل‌های NWP نتایج دقیق‌تری نسبت به داده‌های خام حاصل شده است، عمل ترکیب برونو داد این مدل‌های دینامیکی توسط مدل GMDH، بر روی داده‌های تصحیح‌شده انجام شده است.

Table 7. Efficiency criteria for raw and corrected ensemble precipitation forecasts

Evaluation metrics	NCEP		The percentage of variations	KMA		The percentage of variations	UKMO		The percentage of variations
	Raw	Corrected-PRM		Raw	Corrected-PRM		Raw	Corrected-PRM	
NSE	0.53	0.55	+4	0.51	0.52	+2	0.51	0.54	+6
Pearson correlation	0.74	0.74	0	0.72	0.72	0	0.72	0.75	+4
NRMSE	0.82	0.8	-2	0.85	0.83	-2.3	0.81	0.71	-12
MAE	2.57	2.18	-15	2.85	2.62	-8	2.78	2.21	-20

۲.۳. ترکیب مدل‌های پیش‌بینی همادی بارندگی توسط مدل GMDH

در این پژوهش بهمنظور اعمال عدم قطعیت شرایط اولیه مدل‌های NWP و عدم قطعیت ناشی از خطای این مدل‌ها از رویکرد تلفیق داده استفاده شده است (Hagedorn *et al.*, 2005; Chen *et al.*, 2021). زمانی که برای پیش‌بینی یک متغیر اقلیمی (مانند دما، بارش و ...) مجموعه‌های از مدل‌های هواشناسی استفاده می‌شود، بهجای معرفی یک مدل منفرد هواشناسی با دقت پیش‌بینی بالاتر به عنوان مدل برتر، از ترکیب برونو داد کلیه مدل‌های هواشناسی استفاده شده بهمنظور پس‌پردازش خروجی مدل‌های هواشناسی استفاده می‌شود که به آن مدل همادی چندگانه (MME) گفته می‌شود. براساس این رویکرد، یک پیش‌بینی واحد، مشکل از ترکیب برونو داد مجموعه‌های از مدل‌های NWP حاصل می‌شود (Krishnamurti *et al.*, 2009; Hagedorn *et al.*, 2005) استفاده شده است. نتایج ترکیب پیش‌بینی‌های همادی بارندگی با استفاده از مدل GMDH برای مراحل آموزش، آزمون و در مجموع روی کل دیتا است داده‌های بارش در جدول (۸) ارائه شده است. لازم به ذکر است معیارهای ارزیابی ابتدا بهازای هر یک از اعضای بارندگی همادی به صورت مجزا محاسبه شده و سپس مقادیر میانگین کل ۲۰ عضو بارندگی در جدول (۸) ارائه شده است.

Table 8. Efficiency criteria for the combination of EPFs using GMDH model

Evaluation metrics	Train data	Test data	All data
NSE	0.68	0.65	0.68
KGE	0.75	0.68	0.73
Pearson correlation	0.82	0.83	0.82
NRMSE	0.63	0.64	0.65
MAE	2.15	2.18	2.11

نتایج ارائه شده در جدول فوق نشان می‌دهد کاربرد مدل GMDH نقش مهمی در بهبود عملکرد مدل‌های NWP برای پیش‌بینی بارندگی مشاهداتی دارد. همچنین مقایسه نتایج ارائه شده در جدول‌های (۷) و (۸) نشان می‌دهد میزان مهارت و قابلیت اعتماد پیش‌بینی‌ها توسط رویکرد ترکیب برونو داد مدل‌های NWP نسبت به پس‌پردازش هر مدل منفرد به میزان قابل ملاحظه‌ای بهبود یافته است. طوری که معیارهای نش-ساتکلیف (NSE) و جذر میانگین مربعات NWP

خطای نرمال شده (NRMSE) به طور متوسط ۲۳ درصد و ۱۱ درصد نسبت به مدل‌های رگرسیونی توانی بهبود یافتند. این نتایج در ارتباط با بهبود کیفیت پیش‌بینی مدل‌های NWP با استفاده از رویکرد ترکیب برونداد این مدل‌ها با نتایج Hagedorn *et al.*, 2005; Pakdaman *et al.*, 2022; Saedi *et al.*, 2020; pژوهش‌های قبل مطابقت دارد (Aminyavari and Saghafian., 2019). در واقع نتایج نشان می‌دهد اضافه کردن یک مدل دینامیکی از نظر عینی ضعیف، می‌تواند مهارت پیش‌بینی چند مدل را بهبود بخشد و در مجموع، میانگین خطای گروه را کاهش دهد به‌گونه‌ای که مدل‌های همادی منفرد نمی‌توانند همان میزان بهبود در مهارت پیش‌بینی را به همراه داشته باشند. لذا می‌توان انتظار داشت برای یک پیش‌بینی قابل اعتماد، کاربرد مدل‌های همادی چندگانه بهتر عمل کند.

شکل (۴) روند تغییرات سری زمانی بارش مشاهداتی و پیش‌بینی شده در کل مجموعه داده توسط مدل GMDH را نشان می‌دهد. همان‌گونه که در این شکل دیده می‌شود، پراکنده‌گی پیش‌بینی اعضای همادی به‌ازای مقادیر بارندگی سنگین (نقاط اوج) نسبت به مقادیر بارندگی‌های کوچک، بیشتر است. در واقع به‌ازای رویدادهای بارندگی سنگین، رنج عدم قطعیت پیش‌بینی‌های حاصل از مدل‌های NWP افزایش می‌یابد. به‌طور کلی، افزایش بازه عدم قطعیت پیش‌بینی‌های همادی بارندگی‌های سنگین، بر ضرورت استفاده از تکنیک‌های پس‌پردازش برونداد حاصل از مدل‌های NWP بهویژه ترکیب این مدل‌ها با یکدیگر تأکید دارد.

در این پژوهش به‌منظور ارزیابی توانایی تفکیک‌پذیری مدل‌های NWP از منحنی مشخصه عملکرد (ROC) استفاده شده است. همان‌طور که گفته شد، منحنی ROC نمودار آهنگ برخورد را در برابر نرخ هشدار اشتباہ ترسیم می‌کند. شکل (۵) منحنی ROC را به‌ازای برونداد خام هر یک از مدل‌های منفرد NWP در مقایسه با سامانه مدل‌های همادی چندگانه توسط مدل GMDH نشان می‌دهد. این منحنی‌ها به‌ازای دو آستانه بارش ۲/۵ میلی‌متر و ۱۰ میلی‌متر که به‌ترتیب بیانگر آستانه بارش‌های کوچک و آستانه بارش‌های سنگین می‌باشند، ترسیم شده‌اند. هرچه مساحت سطح زیر منحنی نسبت به خط نیمساز بیشتر باشد، توانایی تفکیک‌پذیری مدل مربوطه بیشتر است. براساس این شکل، منحنی ROC مربوط به سامانه همادی چندگانه (MME-GMDH) در مقایسه با مدل‌های منفرد NWP به‌ازای هر دو سطح آستانه بررسی شده بالاتر قرار گرفته است که نشان می‌دهد به‌ازای مقادیر بارندگی‌های کوچک و بارندگی‌های سنگین، قدرت تفکیک‌پذیری سیستم‌های همادی چندگانه نسبت به مدل‌های منفرد بیشتر است. به‌طور کلی، عملیات پس‌پردازش و کاربست مدل‌های همادی چندگانه بر افزایش توانایی تمیز هر دو رویدادهای بارش سنگین و کوچک مؤثر است.

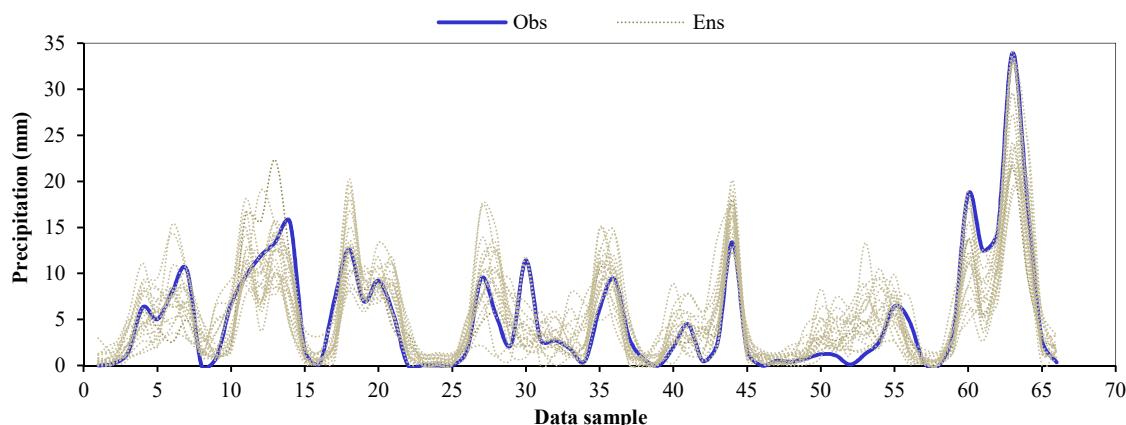


Figure 4. The variations trend of the ensemble precipitation forecasts compared to the observed precipitation for all dataset using GMDH model

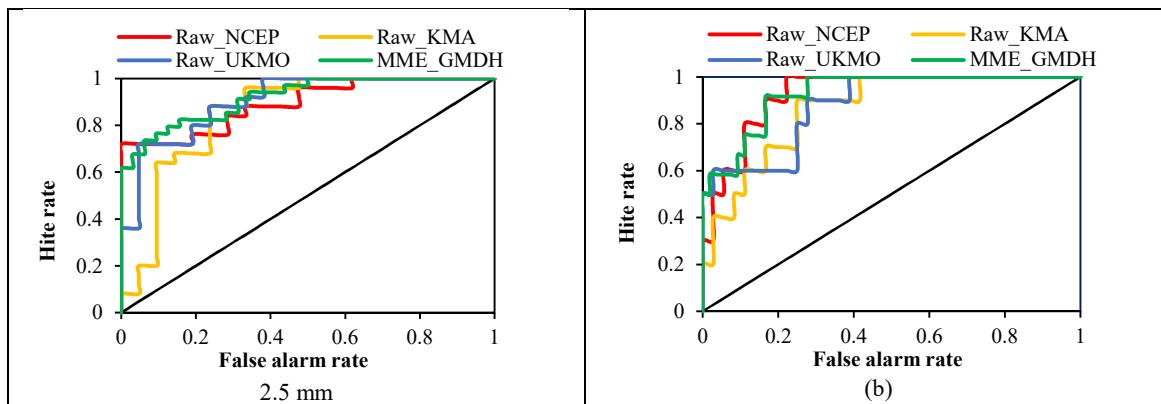


Figure 5. ROC curve for the raw forecasts compared to the multi-model ensemble precipitation forecasts. (a): 2.5 mm (b): 10 mm

به منظور ارزیابی عملکرد سیستم پیش‌بینی بارندگی همادی براساس مساحت سطح زیر منحنی ROC، از شاخص امتیاز مهارتی ROC تحت عنوان RSS^{۱۷} استفاده می‌شود (D'onofrio *et al.*, 2010; Roy and Saha, 2022). این شاخص از رابطه (۵) به دست می‌آید:

$$RSS = 2 \times (AUC - 0.5) \quad (5)$$

در این رابطه AUC مساحت سطح زیر منحنی ROC است. مقدار عددی این شاخص بین صفر تا یک متغیر است. هرچه مساحت سطح زیر منحنی ROC بیشتر باشد، مقدار این شاخص به یک نزدیک‌تر و توانایی تفکیک‌پذیری پیش‌بینی بیشتر است.

مقادیر برآورده این شاخص برای پیش‌بینی‌های همادی بارندگی، پیش و پس از پس‌پردازش توسط مدل GMDH در آستانه بارندگی ۲/۵ میلی‌متر و ۱۰ میلی‌متر در شکل (۶) نشان داده شده است. همان‌طور که در این شکل دیده می‌شود، بازای مقادیر آستانه بارندگی‌های کوچک (۲/۵ میلی‌متر)، بهترتبی قابلیت تفکیک‌پذیری مدل‌های همادی چندگانه ساخته شده توسط مدل GMDH و سپس مدل UKMO نسبت به سایر مدل‌ها بیشتر است و برای آستانه بارندگی‌های سنگین (۱۰ میلی‌متر) ابتدا قابلیت تفکیک‌پذیری مدل‌های همادی چندگانه و سپس مدل NCEP بیشتر است. بنابراین نتایج نشان می‌دهد، ترکیب برونداد مدل‌های NWP توسط مدل GMDH، توانایی شناسایی و تفکیک‌پذیری مقادیر بارندگی‌های کوچک و سنگین را توسط سامانه همادی ساخته شده افزایش داده است. این نتایج با نتیجه پژوهش Javanshiri *et al.* (2021) مشابهت دارد.

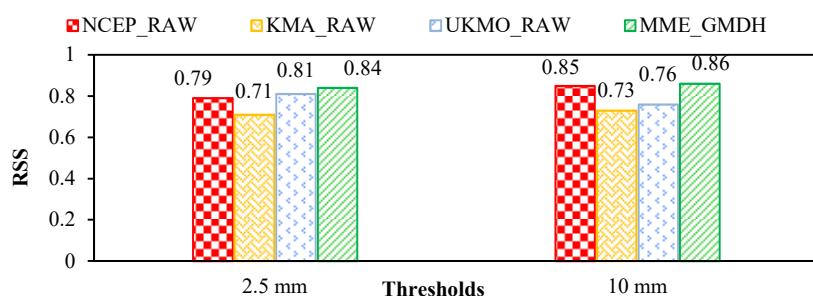


Figure 6. RSS for the raw and multi-model ensemble precipitation forecasts

بهمنظور مقایسه پراکندهای داده‌های تصحیح شده هر یک از مدل‌های NWP با استفاده از مدل رگرسیونی توانی و همین‌طور داده‌های پس‌پردازش شده توسط مدل GMDH، نسبت به پراکندهای داده‌های مشاهداتی از نمودار جعبه‌ای در شکل (۷) استفاده شده است. براساس این شکل، کلیه داده‌های بارندگی (داده‌های بارش مشاهداتی و برآورده توسط مدل‌های مذکور) دارای خمیدگی مثبت هستند. به عبارت دیگر، توزیع پراکندهای داده‌های بارش به گونه‌ای است که اکثربیت داده‌ها در ابتدای بازه قرار دارند. همچنین، میانه (محل تجمع داده‌ها) برای کلیه مدل‌های همادی منفرد و مدل همادی چندگانه بالاتر از داده‌های بارش مشاهداتی قرار گرفته است که نشانگر بیشتر برآورد داده‌های بارش برآورده شده توسط مدل‌های مذکور نسبت به داده‌های مشاهداتی می‌باشد. همان‌طور که دیده می‌شود فاصله بین میانه داده‌های مشاهداتی نسبت به مدل همادی چندگانه و مدل UKMO کمتر است. درنتیجه محل تراکم داده‌های بارش برآورده توسط دو مدل مذکور نسبت به محل تراکم داده‌های مشاهداتی، اختلاف کمتری دارد. از آنجاکه طول جعبه برای مدل همادی چندگانه نسبت به مدل UKMO تطابق بیشتری با طول جعبه داده‌های مشاهداتی دارد، می‌توان گفت پراکندهای داده‌های بارش مشاهداتی، با استفاده از مدل همادی چندگانه ساخته شده توسط مدل GMDH بیشتر پوشش داده شده است. در واقع بدلیل این که دقت پیش‌بینی مدل همادی چندگانه نسبت به سایر مدل‌ها بهتر است، تطابق محل تراکم داده‌ها (مقدار میانه) و طول جعبه برای این مدل نسبت به داده‌های مشاهداتی بیشتر است. به طور کلی، نتایج نشان می‌دهد توزیع پراکندهای بارندگی مشاهداتی با توزیع پراکندهای بارش پس‌پردازش شده توسط مدل GMDH تطابق بیشتری دارد.

در پژوهش حاضر، جهت ساخت مدل همادی چندگانه از مدل GMDH بهره گرفته شده است. توصیه می‌شود در پژوهش‌های بعدی، عملکرد این مدل با روش‌های دیگر بهمنظور پس‌پردازش بروند خام مدل‌های همادی هواشناسی مقایسه شود و از رویکرد برتر با دقت پیش‌بینی بالاتر جهت پیش‌بینی سیلان استفاده گردد. همچنین از دیگر محدودیت‌های پژوهش می‌توان به کاربرد تعداد مدل‌های هواشناسی بیشتر اشاره کرد. زیرا تحت این شرایط، ترکیب بروند داده‌های مجموعه‌ای از مدل‌ها با یکدیگر می‌تواند در ارائه نتایج دقیق‌تر مؤثر باشد.

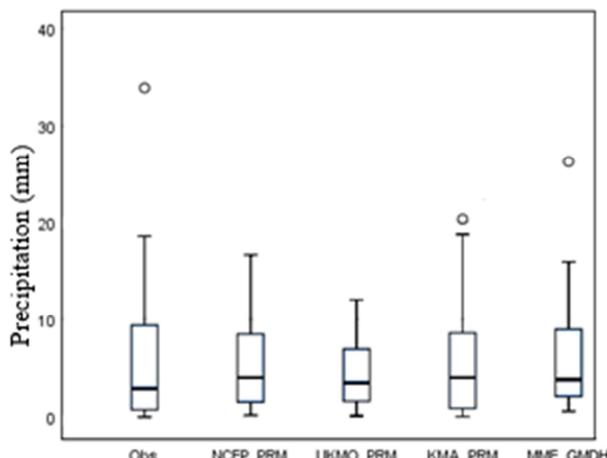


Figure 7. Box-plot of the observed precipitation compared to the posed-processed ensemble precipitation

۴. نتیجه‌گیری

بارندگی به عنوان یکی از مهم‌ترین مشخصه‌های اقلیمی، برای پیش‌بینی جریان، سیلان و دیگر فرایندهای هیدرولوژیکی

اهمیت دارد. در این مطالعه، مهارت پیش‌بینی‌های گروهی بارش برای سه مرکز هواشناسی NCEP و UKMO و KMA متناظر با شش رویداد بارش مولد سیلاب سنگین در حوضه رودخانه ذرا ارزیابی شد. بدین‌منظور، جهت پس‌پردازش و تصحیح اولیه هر مدل منفرد از مدل‌های رگرسیونی خطی و غیرخطی و برای ترکیب برونداد تصحیح شده مدل‌های دینامیکی و ساخت سامانه همادی چندگانه از مدل داده‌محور GMDH استفاده گردید.

نتایج نشان داد با پس‌پردازش پیش‌بینی‌های خام مدل‌های NWP توسط مدل رگرسیونی توانی، دقت پیش‌بینی بارش تا حدودی بهبود می‌یابد. پس از تصحیح داده‌ها توسط مدل ریاضی توانی، نتایج دقیق‌تری با استفاده از مدل‌های NCEP و UKMO به‌دست آمد. نتایج نشان داد میزان بهبود در مهارت پیش‌بینی مدل‌های دینامیکی با استفاده از ترکیب پیش‌بینی‌ها و ایجاد مدل‌های همادی چندگانه محسوس‌تر است. طوری که برای رویکرد ترکیبی معیارهای نشـ ساتکلیف (NSE) و جذر میانگین مربعات خطای نرمال‌شده (NRMSE) به‌طور متوسط ۲۳ درصد و ۱۱ درصد نسبت به مدل‌های توانی بهبود یافتند. علاوه‌بر این، ارزیابی نمودار پراکندگی بارش پیش‌بینی‌شده توسط مدل همادی چندگانه نسبت به بارش مشاهداتی نشان داد، به‌ازای مقادیر سنگین بارندگی، پراکندگی اعضای گروهی و درنتیجه رنج عدم قطعیت پیش‌بینی‌ها بیش‌تر است. همچنین نتایج مربوط به ارزیابی قدرت تفکیک‌پذیری پیش‌بینی مدل‌های همادی چندگانه نسبت به برونداد خام مدل‌های منفرد با استفاده از منحنی ROC گویای توانایی تفکیک‌پذیری بالاتر توسط مدل‌های چندگانه بود. در انتهای، نتایج این پژوهش بیانگر اهمیت پس‌پردازش پیش‌بینی‌های عددی بارش قبل از ورود به مدل‌های هیدرولوژیکی برای پیش‌بینی و هشدار سیلاب، پیش‌بینی جریان ورودی به سد، تخصیص بهینه آب و به‌طور کلی مدیریت منابع آب است.

۵. پی‌نوشت‌ها

1. Numerical Weather Prediction (NWP)
2. Ensemble Precipitation Forecasts (EPFs)
3. THORPEX Interactive Grand Global Ensemble (TIGGE)
4. National Centers for Environmental Prediction (NCEP)
5. European Centre for Medium-Range Weather Forecasts (ECMWF)
6. United Kingdom Meteorological Office (UKMO)
7. Korean Meteorological Agency (KMA)
8. Non-homogeneous Gaussian regression
9. North American Multi Model Ensemble (NMME)
10. Group Method of Data Handling (GMDH)
11. Inverse Distance Weighted (IDW)
12. Power Regression Model (PRM)
13. Self-selection thresholds
14. Relative Operating Characteristic (ROC)
15. Hit Rate (HR)
16. False Alarm Rate (FAR)
17. ROC Skill Score (RSS)

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندها وجود ندارد.

۷. منابع

- Adnan, R. M., Liang, Z., Parmar, K. S., Soni, K., & Kisi, O. (2021). Modeling monthly streamflow in mountainous basin by MARS, GMDH-NN and DENFIS using hydroclimatic data. *Neural Computing and Applications*, 33(7), 2853-2871.
- Aminyavari, S., & Saghfian, B. (2019). Probabilistic streamflow forecast based on spatial post-processing of TIGGE precipitation forecasts. *Stochastic Environmental Research and Risk Assessment*, 33(11), 1939-1950.
- Aminyavari, S., Saghfian, B., & Sharifi, E. (2019). Assessment of precipitation estimation from the NWP models and satellite products for the spring 2019 severe floods in Iran. *Remote Sensing*, 11(23), 2741.
- Chang, F. J., & Hwang, Y. Y. (1999). A self-organization algorithm for real-time flood forecast. *Hydrological processes*, 13(2), 123-138.
- Chen, C. H., Chung, K. S., Yang, S. C., Chen, L. H., Lin, P. L., & Torn, R. D. (2021). Sensitivity of forecast uncertainty to different microphysics schemes within a convection-allowing ensemble during SoWMEX-IOP8. *Monthly Weather Review*, 149(12), 4145-4166.
- Chen, M., Huang, Y., Li, Z., Larico, A. J. M., Xue, M., Hong, Y., ... & Morales, I. Y. (2022). Cross-Examining Precipitation Products by Rain Gauge, Remote Sensing, and WRF Simulations over a South American Region across the Pacific Coast and Andes. *Atmosphere*, 13(10), 1666.
- D'onofrio, A., Boulanger, J. P., & Segura, E. C. (2010). CHAC: a weather pattern classification system for regional climate downscaling of daily precipitation. *Climatic Change*, 98(3), 405-427.
- Du, Y., Wang, Q. J., Wu, W., & Yang, Q. (2022). Power transformation of variables for post-processing precipitation forecasts: regionally versus locally optimized parameter values. *Journal of Hydrology*, 127912.
- Fallah Kalaki, M., Delavar, M., & Farokhnia, A. (2020). Continuous and probabilistic Assessment of Long-term Precipitation Forecast of North American Multi Model Ensemble (Case Study: Karkheh Dam Basin). *Iran-Water Resources Research*, 16(1), 59-71. (In Persian)
- Gilewski, P. (2022). Application of Global Environmental Multiscale (GEM) Numerical Weather Prediction (NWP) Model for Hydrological Modeling in Mountainous Environment. *Atmosphere*, 13(9), 1348.
- Hagedorn, R., Doblas-Reyes, F. J., & Palmer, T. N. (2005). The rationale behind the success of multi-model ensembles in seasonal forecasting-I. Basic concept. *Tellus A: Dynamic Meteorology and Oceanography*, 57(3), 219-233.
- Hapuarachchi, H. A. P., Wang, Q. J., & Pagano, T. C. (2011). A review of advances in flash flood forecasting. *Hydrological processes*, 25(18), 2771-2784.
- Jahanara, A. A., & Khodashenas, S. R. (2019). Prediction of ground water table using NF-GMDH based evolutionary algorithms. *KSCE Journal of Civil Engineering*, 23(12), 5235-5243.
- Jain, S.K., Mani, P., Jain, S.K., Prakash, P., Singh, V.P., Tullos, D., Kumar, S., Agarwal, S.P. and Dimri, A.P., (2018). A Brief review of flood forecasting techniques and their applications. *International Journal of River Basin Management*, 16(3), 329-344.
- Javanshiri, Z., Fathi, M., & Mohammadi, S. A. (2021). Comparison of the BMA and EMOS statistical methods for probabilistic quantitative precipitation forecasting. *Meteorological Applications*, 28(1), e1974.
- Jha, S. K., Shrestha, D. L., Stadnyk, T. A., & Coulibaly, P. (2018). Evaluation of ensemble precipitation forecasts generated through post-processing in a Canadian catchment. *Hydrology and Earth System Sciences*, 22(3), 1957-1969.
- Kardan Moghaddam, H., Ghordoyee Milan, S., Kayhomayoon, Z., & Arya Azar, N. (2021). The prediction of aquifer groundwater level based on spatial clustering approach using machine learning. *Environmental Monitoring and Assessment*, 193(4), 1-20.

- Krishnamurti, T. N., Sagadevan, A. D., Chakraborty, A., Mishra, A. K., & Simon, A. (2009). Improving multimodel weather forecast of monsoon rain over China using FSU superensemble. *Advances in Atmospheric Sciences*, 26(5), 813-839.
- Liguori, S., Rico-Ramirez, M. A., Schellart, A. N. A., & Saul, A. J. (2012). Using probabilistic radar rainfall nowcasts and NWP forecasts for flow prediction in urban catchments. *Atmospheric Research*, 103, 80-95.
- Liu, Y. Y., Li, L., Liu, Y. S., Chan, P. W., Zhang, W. H., & Zhang, L. (2021). Estimation of precipitation induced by tropical cyclones based on machine-learning-enhanced analogue identification of numerical prediction. *Meteorological Applications*, 28(2), e1978.
- Maddah, M. A., Akhoond-Ali, A. M., Ahmadi, F., Ghafarian, P., & Rusin, I. N. (2021). Forecastability of a heavy precipitation event at different lead-times using WRF model: the case study in Karkheh River basin. *Acta Geophysica*, 69(5), 1979-1995.
- Malekmohammadi, B., Zahraie, B. and Kerachian, R., 2010. A real-time operation optimization model for flood management in river-reservoir systems. *Natural hazards*, 53(3), 459-482.
- Manzanas, R., Gutiérrez, J. M., Bhend, J., Hemri, S., Doblas-Reyes, F. J., Torralba, V., ... & Brookshaw, A. (2019). Bias adjustment and ensemble recalibration methods for seasonal forecasting: a comprehensive intercomparison using the C3S dataset. *Climate Dynamics*, 53(3), 1287-1305.
- Medina, H., Tian, D., Marin, F. R., & Chirico, G. B. (2019). Comparing GEFS, ECMWF, and post-processing methods for ensemble precipitation forecasts over Brazil. *Journal of Hydrometeorology*, 20(4), 773-790.
- Mehri, Y., Soltani, J., & Khashehchi, M. (2019). Predicting the coefficient of discharge for piano key side weirs using GMDH and DGMDH techniques. *Flow Measurement and Instrumentation*, 65, 1-6.
- Osman, M., Coelho, C. A., & Vera, C. S. (2021). Calibration and combination of seasonal precipitation forecasts over South America using Ensemble Regression. *Climate Dynamics*, 57(9), 2889-2904.
- Pakdaman, M., Babaeian, I., & Bouwer, L. M. (2022). Improved Monthly and Seasonal Multi-Model Ensemble Precipitation Forecasts in Southwest Asia Using Machine Learning Algorithms. *Water*, 14(17), 2632.
- Roy, J., & Saha, S. (2022). Ensemble hybrid machine learning methods for gully erosion susceptibility mapping: K-fold cross validation approach. *Artificial Intelligence in Geosciences*, 3, 28-45.
- Saedi, A., Saghafian, B., Moazami, S., & Aminyavari, S. (2020). Performance evaluation of sub-daily ensemble precipitation forecasts. *Meteorological Applications*, 27(1), e1872.
- Safari, M. J. S., Ebtehaj, I., Bonakdari, H., & Es-haghi, M. S. (2019). Sediment transport modeling in rigid boundary open channels using generalize structure of group method of data handling. *Journal of Hydrology*, 577, 123951.
- Samadi, A., Sadrolashrafi, S. S., & Kholghi, M. K. (2019). Development and testing of a rainfall-runoff model for flood simulation in dry mountain catchments: A case study for the Dez River Basin. *Physics and Chemistry of the Earth, Parts A/B/C*, 109, 9-25.
- Shaghaghi, S., Bonakdari, H., Gholami, A., Ebtehaj, I., & Zeinolabedini, M. (2017). Comparative analysis of GMDH neural network based on genetic algorithm and particle swarm optimization in stable channel design. *Applied Mathematics and Computation*, 313, 271-286.
- Sikder, M. S., & Hossain, F. (2018). Sensitivity of initial-condition and cloud microphysics to the forecasting of monsoon rainfall in South Asia. *Meteorological Applications*, 25(4), 493-509.
- Tanhapour, M., Hlavčová, K., Soltani, J., Liová, A., Malekmohammadi, B. (2022). Sensitivity analysis and assessment of the performance of the HBV hydrological model for simulating reservoir inflow hydrograph. In: Proceeding of 16th annual international scientific conference, 1-3 June, Banská Štiavnica, Slovakia, 115-124.

- Tao, Y., Duan, Q., Ye, A., Gong, W., Di, Z., Xiao, M., & Hsu, K. (2014). An evaluation of post-processed TIGGE multimodel ensemble precipitation forecast in the Huai river basin. *Journal of hydrology*, 519, 2890-2905.
- Theocharides, S., Makrides, G., Livera, A., Theristis, M., Kaimakis, P., & Georgiou, G. E. (2020). Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing. *Applied Energy*, 268, 115023.
- Verkade, J. S., Brown, J. D., Reggiani, P., & Weerts, A. H. (2013). Post-processing ECMWF precipitation and temperature ensemble reforecasts for operational hydrologic forecasting at various spatial scales. *Journal of Hydrology*, 501, 73-91.
- Walton, R., Binns, A., Bonakdari, H., Ebtehaj, I. and Gharabaghi, B., (2019). Estimating 2-year flood flows using the generalized structure of the Group Method of Data Handling. *Journal of Hydrology*, 575, 671-689
- Wang, H., Hu, Y., Guo, Y., Wu, Z., & Yan, D. (2022). Urban flood forecasting based on the coupling of numerical weather model and stormwater model: A case study of Zhengzhou city. *Journal of Hydrology: Regional Studies*, 39, 100985.
- Wei, X., Sun, X., Sun, J., Yin, J., Sun, J., & Liu, C. (2022). A Comparative Study of Multi-Model Ensemble Forecasting Accuracy between Equal-and Variant-Weight Techniques. *Atmosphere*, 13(4), 526.
- Wu, W., Emerton, R., Duan, Q., Wood, A.W., Wetterhall, F. and Robertson, D.E., (2020). Ensemble flood forecasting: Current status and future opportunities. *Wiley Interdisciplinary Reviews: Water*, 7(3), 1432.
- Zakeri, Z., azadi, M., & sahraeiany, F. (2014). Verification of WRF forecasts for precipitation over Iran in the period Feb-May 2009. *Nivar*, 38(87-86), 3-10. (In Persian)