



توسعه مدل پیش بینی رواناب رودخانه‌ها در بالادست سد بوکان، حوضه آبریز دریاچه ارومیه

امیررضا میدانی^۱، امیرحسین دهقانی پور^۲، مسعود تجریشی^{۱*}، محمدحسن دهقانی پور^۳

۱- دانشکده مهندسی عمران، دانشگاه صنعتی شریف

۲- دانشکده مهندسی عمران و علوم زمین، دانشگاه صنعتی دلفت

۳- گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه سمنان

tajrishy@sharif.edu

خلاصه

افزایش مصرف آب در بخش کشاورزی و خشکسالی‌های اخیر موجب کاهش تراز دریاچه ارومیه شده است. هدف این تحقیق، ارائه یک مدل پیش‌بینی پارامترهای اقلیمی برای بالادست سد بوکان به عنوان مهمترین سد مخزنی حوضه دریاچه ارومیه است. داده‌های بزرگ مقیاس پیش‌بینی آب‌وهوایی فصلی سازمان ECMWF و NCEP با استفاده از روش‌های هوش مصنوعی هیبرید و غیرهیبرید بر روی منطقه ریزمقیاس سازی شد تا در آینده به عنوان ورودی مدل هیدرولوژیکی بتواند آب ورودی به سد بوکان را پیش‌بینی نماید. نتایج نشان داد که روش هیبرید به مراتب عملکرد بهتری را نسبت به روش‌های GMDH و SVR دارد، بطوریکه مقدار میانگین معیار نش-ساتکلیف (NSE) ریزمقیاس سازی بارش ماهانه با افق پیش‌بینی یک ماهه^۱ در روش هیبرید به ترتیب برای دوره آموزش و تست برابر ۰/۵۴ و ۰/۶ بدست آمد. همچنین ریزمقیاس سازی پیش‌بینی روزانه دما با چشم انداز شش ماهه برای دوره آموزش و تست به ترتیب برابر ۰/۷۸ و ۰/۸۵ بدست آمد. نتایج نشان داد داده‌های پیش‌بینی بارش سازمان ECMWF عملکرد بهتری نسبت به NCEP در منطقه مورد نظر دارد. درنهایت، با وارد کردن داده‌های بارش و دما به مدل بارش-رواناب توسعه داده شده و مقایسه آن با رواناب مشاهداتی ورودی به سد بوکان، NSE برابر با ۰/۶۷ برای سال‌های ۲۰۲۰ و ۲۰۲۱ بدست آمد.

کلمات کلیدی: ریزمقیاس سازی، پیش‌بینی‌های فصلی، هوش مصنوعی، حوضه آبریز دریاچه ارومیه، سد بوکان

۱. مقدمه

بعضی از سازمان‌های معتبر هواشناسی نظیر مرکز پیش‌بینی‌های میان مدت اروپا^۲ و مرکز ملی پیش‌بینی محیط‌زیست^۳، داده‌های پیش‌بینی فصلی آب و هوایی تولید می‌نمایند. این پیش‌بینی‌ها براساس مدل‌های ریاضی جوی و اقیانوسی هستند که به پیش‌بینی پارامترهای آب و هوایی با استفاده از شرایط اولیه و حال حاضر جو می‌پردازد. سازمان‌های مختلف از مدل‌های مختلف پیش‌بینی شرایط جوی استفاده می‌کنند که باعث پیش‌بینی‌های متفاوت برای یک منطقه خاص می‌گردد. در این میان ECMWF از سال ۱۹۷۷ به کار پیش‌بینی مشغول بوده است و هر ۵ سال سیستم خود را آپدیت کرده است بطوریکه SEAS5 آخرین سیستم پیش‌بینی‌های فصلی این سازمان می‌باشد [1]. تحقیقات مختلفی به ارزیابی قابلیت پیش‌بینی‌های فصلی ECMWF پرداخته‌اند؛ برای نمونه، کارایی پیش‌بینی‌های بارش در هیمالیای مرکزی [2]، دما در آمریکای جنوبی [3] و بارش و دما در دانوب [4] مورد بررسی قرار گرفته است. سیستم پیش‌بینی‌های فصلی NCEP کار خود را از سال ۱۹۷۹ آغاز کرد و در سال ۲۰۱۱ دومین آپدیت سیستمی خود یعنی CFSV2 را عرضه نمود [5]. این سازمان نیز کارایی خوبی در پیش‌بینی بارش و دما [6]، [7] و پیش‌بینی خشکسالی [8] از خود نشان داده است.

¹ 1-month lead time

² ECMWF

³ NCEP

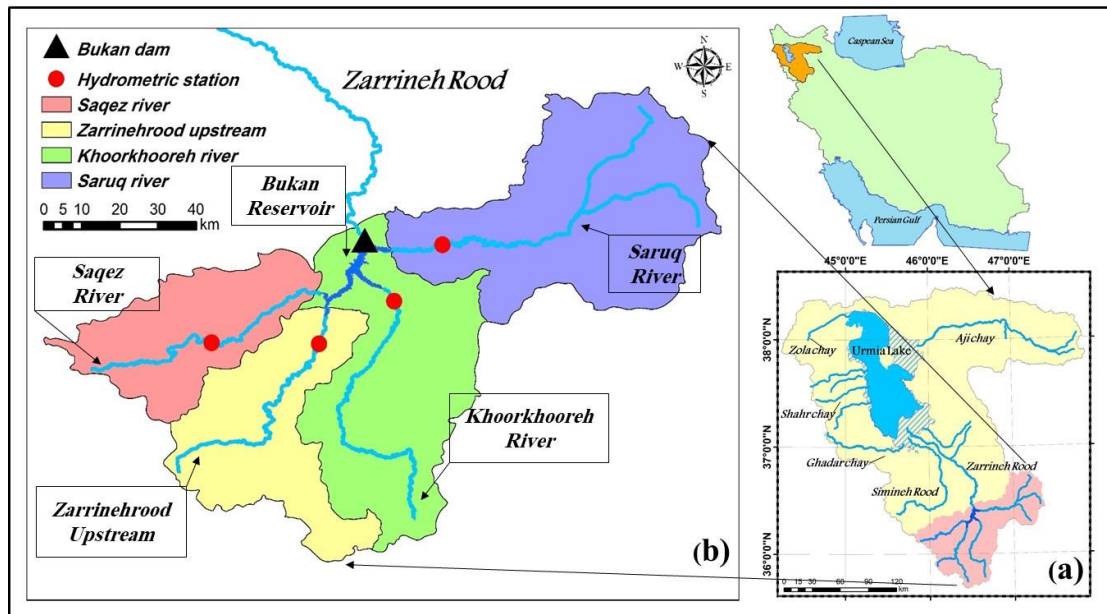


داده‌های پیش‌بینی این دو سازمان از نظر مکانی بزرگ مقیاس هستند و لازم است تا با استفاده از روش‌های ریزمقیاس سازی به داده‌هایی با مقیاس منطقه‌ای تبدیل گردند [9]. هوش مصنوعی، بخاطر قابلیتی که در محاسبه الگوهای پیچیده و رفتارهای پیش‌بینی نشده [10] و نیز قابلیت استخراج روابط غیرخطی بدون اطلاع از شکل پارامتری این روابط [11] دارد، در سال‌های اخیر مورد استفاده قرار گرفته است. برای نمونه، هوش مصنوعی در تحقیقاتی برای توسعه مدل پیش‌بینی بارش [12]، دما [13] و تبخیر [14] با استفاده از داده‌های مشاهداتی مورد استفاده قرار گرفته است. درحالی که استفاده از داده‌های مشاهداتی گذشته برای پیش‌بینی الگوی بارش موجب افزایش عدم قطعیت شده و نیازمند استفاده از رویکردهای پیچیده و مدل‌های عددی برای پیش‌بینی است [15]. همچنین مدل‌های هیبرید هوش مصنوعی برای پیش‌بینی بارش مورد استفاده قرار می‌گیرد [17]، [16]. در این بین، استفاده از روش هیبرید GMDH و SVR می‌تواند مثر و واقع‌گرا باشد. بطوریکه، قابلیت GMDH در مدل‌سازی روابط غیرخطی و استقلال SVR از ابعاد فضای ورودی به علت پیچیدگی محاسباتی مدل [18]، موجب بهبود ریزمقیاس سازی پارامترهای آب و هوایی می‌گردد. با این وجود تحقیقات بسیار کمی از هوش مصنوعی برای ریزمقیاس سازی داده‌های پیش‌بینی فصلی استفاده کرده‌اند [19].

ما در این تحقیق بر روی پیش‌بینی پارامترهای آب و هوایی در حوضه آبریز دریاچه ارومیه می‌پردازیم. دریاچه ارومیه در شمال غربی ایران، یکی از بزرگترین دریاچه‌های شور دنیاست، که در سال‌های اخیر با بحران کم آبی روبرو شده است [20]. رودخانه زرينه‌رود در جنوب این دریاچه حدود ۴۰٪ آب ورودی به آن را تامین می‌نماید [21]. سد بوکان به عنوان بزرگترین مخزن حوضه آبریز دریاچه ارومیه در بالادست زرينه‌رود قرار دارد و به عنوان یک مخزن استراتژیک در کنترل سیلاب، تامین آب شرب و تامین نیازهای کشاورزی پایین دست محسوب می‌شود. تا کنون تحقیقاتی بر روی تأثیرات بلند مدت تغییر اقلیم بر روی منابع آب در زیر حوضه آبریز زرينه‌رود انجام شده است که نشان دهنده کاهش بارش‌ها و آب ورودی به سد بوکان بوده است [22]. بر این اساس به علت کاهش بارش‌ها و افزایش مصرف کشاورزی، توسعه یک مدل پیش‌بینی بارش برای بالادست سد بوکان می‌تواند سیاست‌مداران حوضه آب را در بهینه‌سازی تخصیص آب بین نیاز زیست‌محیطی و کشاورزی حوضه آبریز دریاچه ارومیه کمک نماید. داده‌های مدل بارش و دما می‌توانند در نهایت به عنوان ورودی مدل بارش-رواناب توسعه داده شده در بالادست، رواناب ورودی به این سد را پیش‌بینی نماید [23]. مقاله حاضر برای اولین بار به پیش‌بینی پارامترهای آب و هوایی در بالادست سد بوکان با استفاده از ریزمقیاس سازی پیش‌بینی‌های فصلی آب و هوایی با استفاده از مدل هیبرید و در نهایت پیش‌بینی رواناب ورودی به این سد می‌پردازد. این مقاله در پنج قسمت ارائه گردیده است. در قسمت دوم به معرفی منطقه مورد مطالعه پرداخته می‌شود. قسمت سوم و چهارم به ترتیب به روش مورد استفاده و نتایج حاصل از این تحقیق می‌پردازد و در نهایت قسمت پنجم به نتیجه‌گیری اختصاص داده شده است.

۲. منطقه مورد مطالعه

حوضه آبریز دریاچه ارومیه با مساحتی بالغ بر ۵۱۰۰۰ کیلومتر مربع یکی از بزرگترین حوضه‌های آبریز بسته ایران و در شمال غربی آن قرار دارد. دریاچه ارومیه در مرکز این حوضه، محل زهکشی تمام آب‌های این حوضه است. رودخانه زرينه‌رود با آورد حدود ۲۰۰۰ میلیون مترمکعب حدود ۴۰٪ آب ورودی به دریاچه ارومیه را تامین می‌نماید و مهمترین رودخانه این حوضه شناخته می‌شود. سد بوکان به عنوان بزرگترین سد مخزنی این حوضه بر روی زرينه‌رود قرار دارد. میانگین بارش و دمای زیرحوضه‌های بالادست سد بوکان که در شکل ۱ نشان داده شده است به ترتیب برابر ۶۵۰ میلی‌متر و ۱۰ درجه سانتی‌گراد است. بیشتر بارش‌های برف در این زیرحوضه‌ها از اواخر آذر شروع شده و تا اواسط اسفند ماه ادامه می‌یابد و حدود ۵۳٪ این مناطق در این فصول پوشیده از برف است [24]. سد بوکان آب شرب شهرهایی نظیر تبریز، بوکان و میاندوآب را تامین می‌کند و یک مخزن استراتژیک برای تامین آب کشاورزی دشت‌های میاندوآب و صائین قلعه در پایین دست محسوب می‌شود. این دشت‌ها به ترتیب با سطح زیر کشت ۱۰۰۰۰۰ و ۱۷۰۰۰ هکتار مدرن‌ترین و بزرگترین شبکه‌های آبیاری این حوضه را داراست.



شکل ۱- جانمایی حوضه آبریز دریاچه ارومیه (a)، سد بوکان و رودخانه‌های منتهی به آن (b) [23]

۳. روش شناسی

۳.۱. پیش‌بینی‌های ECMWF

ECMWF یک سازمان غیردولتی اروپایی است که بوسیله ۳۲ کشور اروپایی حمایت می‌گردد. پیش‌بینی‌های فصلی اطلاعاتی در مورد شرایط آب و هوایی فصل‌های آینده می‌دهد و برای بخش‌های مثل مدیریت منابع آب، کشاورزی، سلامت و انرژی مفید است [15]. در این تحقیق از SEAS5 که آخرین نسل از سیستم ECMWF است استفاده شده است. داده‌های میانگین گروه^۱ ماهانه و روزانه پیش‌بینی‌های فصلی به ترتیب تحت عنوان Seasonal forecast daily and sub-daily data on the و Seasonal forecast monthly statistics on the single level مورد استفاده قرار گرفته است [25], [26]. این داده‌های جهانی در مقیاس ۱ درجه می‌باشد. برای داشتن پیش‌بینی‌های دقیق تر بارش، از داده‌های پیش‌بینی با افق پیش‌بینی یک ماهه برای ریزمقیاس سازی استفاده شد. همچنین داده‌های دمایی در مقیاس روزانه و افق پیش‌بینی شش ماهه مورد استفاده قرار گرفت زیرا دما عدم قطعیت کمتری نسبت به بارش دارد.

۳.۲. پیش‌بینی‌های NCEP

NCEP تحت رهبری اداره ملی اقیانوسی و جوی^۲ و آژانس های تابعه آن اداره می‌شود. دومین نسخه از سیستم پیش‌بینی آب و هوایی (CFSV2) این سازمان از سال ۲۰۱۱ عملیاتی شده است. این نسخه به علت بهبودهایی در شرایط اولیه و درک مدل نسبت به نسخه اولیه آن، عملکرد به مراتب بهتری را دارد. داده‌های استفاده شده برای این تحقیق تحت عنوان CFSv2 operational forecasts time series برای داده‌های بارش و دما می‌باشد. همانند ECMWF، داده‌های بارش و دما به ترتیب با افق پیش‌بینی یک ماهه و شش ماهه مورد استفاده قرار گرفته است.

۳.۳. روش‌های هوش مصنوعی برای ریزمقیاس سازی پارامترهای آب و هوایی

مدل‌های هواشناسی استفاده شده در این تحقیق بزرگ مقیاس و جهانی اند و به منظور کاهش خطا لازم است به داده‌هایی با مقیاس کوچکتر در حد منطقه تبدیل شوند. ریزمقیاس سازی داده‌های پیش‌بینی براساس مقیاس نقطه‌ای ایستگاه‌های سینوپتیک منطقه انجام شده است. برای این کار سه روش هوش مصنوعی بکار گرفته شد که در ادامه توضیحات بیشتری داده خواهد شد.

هر روش شامل پارامترهایی است که به وسیله به حداقل رساندن اختلاف داده‌های خام پیش‌بینی و مشاهداتی دما و بارش تخمین زده می‌شود

(رابطه ۱).

¹ Ensemble mean

² National Oceanic and Atmospheric Administration (NOAA)

$$NSE = 1 - \frac{\sum_{i=1}^n (V_o^i - V_{est}^i)^2}{\sum_{i=1}^n (V_o^i - \bar{V}_o)^2} \quad (1)$$

که در آن V_o^i و V_{est}^i به ترتیب داده مشاهداتی و ریزمقیاس سازی شده آب و هوایی است. همچنین نسبت بین داده‌های آموزش به تست برابر ۷۰ به ۳۰ در نظر گرفته شده. در ادامه در مورد روش‌های ریزمقیاس سازی بیشتر توضیح داده می‌شود.

۳.۳.۱ روش GMDH^۱

این روش براساس یک شبکه چند لایه است بطوریکه هر لایه بصورت یک تابع خطی از داده‌های ورودی عمل می‌نماید [27]. داده‌های ورودی تعداد نورون‌ها را مشخص می‌نماید. به عنوان نمونه، اگر تعداد داده‌های ورودی برابر با k باشد، در این صورت تعداد نورون‌ها در هر لایه برابر با $m = \binom{k}{2}$ خواهد بود. هدف اصلی این روش تعریف تابعی است که اختلاف بین داده‌های مشاهداتی و ریزمقیاس سازی شده را کاهش دهد. در این روش از یک رابطه چند مرتبه‌ای درجه بالا (رابطه ۲) برای تعیین همبستگی بین داده‌های پیش‌بینی خام و مشاهداتی استفاده می‌شود.

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j \quad (2)$$

که در آن a_0, a_i, a_{ij} ضرایب متغیرهای موجود در چند جمله‌ای است که با استفاده از روش حداقل مربعات بدست می‌آید. x_i, x_j, x_k داده‌های ورودی هستند که به صورت دو به دو در نورون‌ها ترکیب می‌شوند. n تعداد متغیرها در هر ترکیب می‌باشد ($n=2$). به بیانی دیگر، رابطه ۲ در هر نورونی بکار گرفته شده و خروجی آن براساس داده‌های ورودی محاسبه می‌شود. سپس مقدار NSE بین خروجی مدل و داده‌های هر نورون محاسبه و نورون‌هایی که مقدار NSE کمتری دارند مرحله به مرحله حذف می‌شوند [28]. نورون‌های انتخاب شده در هر لایه، به لایه بعدی وارد می‌شوند. این رویه ادامه می‌یابد تا در نهایت یک نورون باقی بماند و ضرایب a_0, a_i, a_{ij} محاسبه گردد.

به منظور تعیین داده‌های ورودی به مدل ریزمقیاس سازی بارش در ابتدا صرفاً داده پیش‌بینی بارش و دما مورد استفاده قرار گرفت؛ ولی نتایج گویای عدم وابستگی زیاد نتایج ریزمقیاس سازی بارش به داده دما بود. سپس داده بارشی در زمان t و $t-1$ به عنوان ورودی مدل وارد شدند که نتایج تا حد بسیار زیادی بهبود داده شد. با بررسی بیشتر نتیجه گردید که داده ورودی شماره ماه نیز می‌تواند نتایج را تا حد زیادی بهبود بخشد زیرا مثلاً برخی از ماه‌های کم بارش تابستان که معمولاً بارش‌های بسیار کمی دارند گاهی به علت رگبار بارش زیادی در آن ثبت می‌شود. در این صورت مدل ممکن است آن را با یک ماه پر بارش در زمستان اشتباه بگیرد. افزودن شماره ماه موجب بهبود درک مدل و کاهش خطاهای این چنینی می‌شود. در نهایت، داده‌های ورودی به مدل GMDH شامل داده‌های بارش در گام زمانی t ، بارش در گام زمانی $t-1$ ، شماره ماه و بارش مشاهداتی گام زمانی t می‌باشد ($k=4$). برای ریزمقیاس سازی دما از داده‌های خام پیش‌بینی و داده‌های مشاهداتی در گام زمانی t به عنوان ورودی مدل استفاده شده است ($k=2$).

۳.۳.۲ روش SVR^۲


هدف اصلی SVR برآورد بهترین مقدار حاشیه‌ای \mathcal{E} برای به حداقل رساندن خطا در داخل یک محدوده نظیر آنچه در شکل ۲ مشاهده می‌شود، است. به علت غیرخطی بودن مسئله در تحقیق حاضر، با کمک SVR، رابطه ۳ بدست می‌آید.

$$f(x_i) = w\phi(x_i) + b \quad (3)$$

در آن $\phi(x)$ ترم غیرخطی مسئله، w و b به ترتیب وزن و عرض از مبدا تابع رگرسیون است.

¹ Group method of data handling

² Support vector regression



شکل ۲- نحوه عملکرد SVR برای داشتن بهترین تقریب ϵ به جهت کاهش خطا در یک محدوده خاص

در شکل ۲، خط مستقیم، صفحه‌ای است که با در نظر گرفتن یک محدوده خطای قابل قبول برازش می‌شود. خط چین در این شکل، مرزها را در فاصله‌ای نشان می‌دهد تا یک حاشیه بین به عنوان مثال، داده‌های خام پیش‌بینی بارش ایجاد شود. در واقع، ϵ کیفیت بهینه‌سازی را نشان می‌دهد و انحراف بین داده‌های گنج مشاهده شده و داده‌های پیش‌بینی کاهش یافته را بیان می‌کند. با کمک تابع به حداقل رساندن ریسک (معادله ۴)، معادله ۳ در ابعاد بالاتر برای داده‌های پیش‌بینی خام حل و جداسازی خطی میسر می‌شود.

$$R(w, \zeta, \zeta^*) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \zeta_i + \zeta_i^* \quad (4)$$

$$\text{subject to: } \begin{cases} y_i - (w \phi(x_i) + b_i) \leq \epsilon + \zeta_i \\ (w \phi(x_i) + b_i) - y_i \leq \epsilon + \zeta_i^* \\ \zeta_i^*, \zeta_i \geq 0 \end{cases}$$

که در آن x و y به ترتیب داده‌های پیش‌بینی خام و ریزمقیاس شده هستند. در معادلات فوق، با توجه به داده‌های آموزشی نمونه (x_i, y_i) ، x_i بردار ورودی n بُعدی برای متغیرهای مختلف مذکور در روش GMDH و y_i خروجی مطلوب یک بُعدی در نقطه i است؛ همچنین $x_i \in R^n$ ، $y_i \in R^n$ هستند. ζ_i^* ، ζ_i متغیرهای کمکی اندازه‌گیری خطاها هستند که برای هر متغیری که خارج از ϵ و به ترتیب در پایین و بالا می‌افتد، استفاده می‌شوند. $w \in R^n$ و $b \in R^n$ به ترتیب ثابت‌هایی برای نشان دادن انحراف و عامل وزنی و C یک ثابت تنظیم برای متعادل نمودن کمینه و بیشینه خطا است. m سازه داده پیش‌بینی خام و $f(x)$ هدف مدل شده است که داده پیش‌بینی ریزمقیاس شده را بر اساس داده مشاهده‌ای محاسبه می‌کند [18]. همچنین $\phi(x)$ یک تابع انتقال غیرخطی برای نگاشت داده پیش‌بینی خام در فضایی با ابعاد بالاتر است. با استفاده از روش تابع لاگرانژ، رگرسیون غیرخطی به رابطه ۵ تبدیل می‌شود، جایی که از تابع کرنل برای تبدیل داده به فضایی با ابعاد بالاتر استفاده می‌شود (برای جزئیات بیشتر تر راجع به لاگرانژ و تبدیلات کرنل، رجوع شود به [29]، [30]).

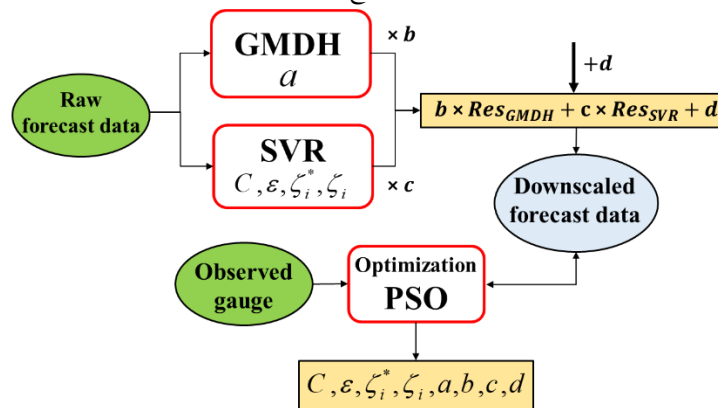
$$f(x) = \sum_{i=1}^m (\alpha_i + \alpha_i^*) k(x, x_i) + b \quad (5)$$

در معادله فوق، $k(x, x_i) = (\phi(x), \phi(x_i))$ تابع کرنل است که یک نوع گاوسی از معادله کرنل در این مطالعه استفاده شده است و α_i ، α_i^* ضرایب لاگرانژ هستند. تابع NSE (رابطه ۱) برای بهینه کردن پارامترهای مدل شامل ϵ ، C و پارامترهای تابع کرنل بین پیش‌بینی ریزمقیاس شده و داده‌های مشاهداتی استفاده می‌شود.

۳.۳.۲ روش هیبرید (SVR-GMDH)

در این مطالعه، علاوه بر روش‌های گفته شده، از رویکرد هیبریدی مبتنی بر GMDH و SVR استفاده شده است (شکل ۳). در این روش، داده‌های پیش‌بینی خام بارش برای ریزمقیاس سازی با هر دو روش GMDH و SVR استفاده می‌شوند و سپس مقادیر ریزمقیاس سازی شده هیبرید به عنوان یک

ترکیب خطی از خروجی‌های GMDH و SVR برآورد شده تولید می‌شود. ضرایب a ، c و d از ترکیب خطی و ضرایب هر یک از روش‌های منفرد مشترکاً با بهینه‌سازی ازدحام ذرات (PSO) و با استفاده از رابطه ۱ به عنوان تابع هدف بهینه می‌شوند.



شکل ۳- رویکرد هیبریدی GMDH-SVR برای ریزمقیاس‌سازی داده‌های بارش

۴. نتایج

۴.۱. مدل پیش‌بینی پارامترهای آب و هوایی

برای حصول درک بهتر از عملکرد و کارایی روش‌های ذکر شده مبتنی بر هوش مصنوعی در ریزمقیاس‌سازی پیش‌بینی‌های آب و هوایی، کارایی هر روش جداگانه مورد آزمایش قرار گرفت. جدول ۱ نشان‌دهنده نتایج NSE پیش‌بینی‌های بارش ریزمقیاس‌سازی شده برای ایستگاه‌های سینوپتیک تکاب و سقز است. نتایج بهینه‌سازی نشان می‌دهد که روش هیبرید بهره‌وری به مراتب بالاتری از SVR و GMDH برای داده‌های ECMWF و NCEP دارد. در این مورد، مقادیر NSE از روش هیبرید، تقریباً دو برابر مقادیر متعلق به روش‌های غیرهیبرید است. هم‌چنین نتایج، عملکرد بهتر پیش‌بینی‌های بارش ماهیانه ECMWF برای هر دو ایستگاه و دوره‌های تست و آموزش داده‌ها را نشان می‌دهد. در بین تمامی سه روش بهینه‌سازی، نتایج بهینه‌سازی ECMWF بسیار بهتر از NCEP هستند. یک دلیل، تفاوت رویکرد آن‌ها در پیش‌بینی شرایط آب‌وهوایی است. NCEP از یک مدل هیدرواستاتیک ترکیب شده با تخمین تقریبی توپوگرافی استفاده می‌کند. در طرف دیگر، ECMWF از مدل غیر هیدرواستاتیک استفاده می‌کند و با دقت بیش‌تری تاثیرات توپوگرافی را بر پیش‌بینی آب‌وهوایی توجیه می‌نماید [31]، [32]. بنابراین ECMWF عملکرد بهتری در نواحی کوهستانی دارد [33].

جدول ۱ - مقادیر NSE بارش ریزمقیاس‌سازی شده با افق پیش‌بینی یک ماهه

ECMWF			NCEP				
SVR	GMDH	SVR-GMDH (Hybrid)	SVR	GMDH	SVR-GMDH (Hybrid)		
0.27	0.16	0.54	0.24	0.18	0.33	دوره آموزش	ایستگاه تکاب
0.34	0.27	0.61	0.27	0.18	0.39	دوره تست	ایستگاه تکاب
0.22	0.24	0.53	0.16	0.11	0.37	دوره آموزش	ایستگاه سقز
0.37	0.54	0.62	0.28	0.31	0.41	دوره تست	ایستگاه سقز

برای مقایسه تاثیر زمان تقدم پیش‌بینی بر دقت پیش‌بینی ریزمقیاس‌سازی شده، روش هیبرید برای پیش‌بینی‌های با زمان تقدم ۱ و ۳ ماهه اعمال شد که نتایج این مقایسه در جدول ۲ ارائه شده است. بر این اساس روش هیبرید اختلاف نسبتاً قابل قبولی را رقم زده و NSE را تا بیش از ۰٫۶ برای دوره تست و زمان تقدم یک ماهه ارتقاء داده است. اختلاف جزئی می‌تواند ناشی از یکسان بودن شرایط اولیه هر دو تقدم زمانی در ابتدای هر ماه باشد. دوره تست، NSE بیش‌تری از دوره آموزشی دارد. زیرا دوره تست که در اواخر سری زمانی می‌باشد از بروزرسانی جدید ECMWF به نسل SEAS5 در سال ۲۰۱۷ بهره برده است، که شامل بهبود رزولوشن و سایر ویژگی‌های ارتقاء یافته است. نتایج مدل توسعه داده شده می‌تواند به عنوان ورودی مدل بارش-رواناب توسعه داده شده برای این منطقه به منظور پیش‌بینی رواناب ورودی به سد بوکان مورد استفاده قرار گیرد [23].

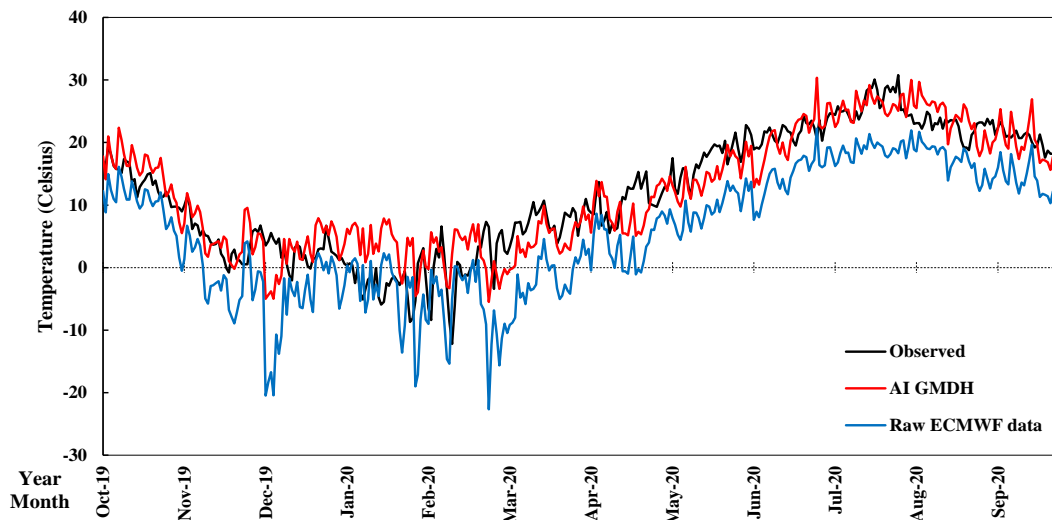
جدول ۲- نتایج NSE ریزمقیاس سازی بارش با افق پیش بینی یک ماهه و سه ماهه داده های ECMWF

SVR-GMDH		دوره آموزش	ایستگاه
افق پیش بینی یک ماهه	افق پیش بینی سه ماهه		
0.54	0.53	دوره آموزش	ایستگاه کتاب
0.61	0.55	دوره تست	ایستگاه کتاب
0.53	0.50	دوره آموزش	ایستگاه سقز
0.62	0.52	دوره تست	ایستگاه سقز

جدول ۳ نشان دهنده نتایج ریزمقیاس سازی دمای روزانه است که نشان می دهد نتایج NCEP و ECMWF مشابه یکدیگر هستند. دمای ریزمقیاس شده با روش GMDH قابل قبول است زیرا دما مثل بارش یک پدیده تصادفی نیست و به نظر می رسد هیچ مزیت چشمگیری در بکارگیری یک روش پیچیده تر هیبریدی برای ریزمقیاس سازی آن وجود ندارد. سری های زمانی پیش بینی متناظر در شکل ۴ نشان می دهد روش ریزمقیاس سازی GMDH قادر به کاهش اختلاف بین داده های پیش بینی خام و مشاهداتی بوده و عملکرد خوبی از خود نشان داده است.

جدول ۳- نتایج NSE داده های روزانه دما با افق پیش بینی شش ماهه

GMDH		دوره آموزش	ایستگاه
ECMWF	NCEP		
0.81	0.86	دوره آموزش	ایستگاه کتاب
0.86	0.84	دوره تست	ایستگاه کتاب
0.76	0.83	دوره آموزش	ایستگاه سقز
0.84	0.81	دوره تست	ایستگاه سقز




شکل ۴- مقایسه داده های خام و ریزمقیاس سازی شده ECMWF با داده های مشاهداتی بارش در ایستگاه سقز

۲.۴. پیش بینی رواناب ورودی به سد

به منظور پیش بینی رواناب ورودی به سد، خروجی های بارش و دمای مدل پیش بینی آب و هوایی برای شبیه سازی مدل هیدرولوژیکی بارش-رواناب توسعه داده شده توسط میدانی و همکاران، مورد استفاده قرار گرفت [23]. شکل ۵ مقدار آب ورودی روزانه پیش بینی شده و مشاهده شده به مخزن سد بوکان

در سال‌های آبی ۲۰۲۰ و ۲۰۲۱ را نشان می‌دهد. بر این اساس، مدل پیش‌بینی رواناب، پیش‌بینی‌های دقیقی را در ماه‌های خشک و مرطوب انجام داده است؛ بطوریکه مقدار کل NSE برای دو سال متوالی برابر ۰/۶۷ بدست آمد. همچنین پیش‌بینی در ماه‌های مرطوب عملکرد بهتری دارد. این بازه زمانی از این جهت حائز اهمیت است که در این زمان احتمال وقوع سیلاب وجود دارد و به دلیل قرار گرفتن در فصول غیر کشاورزی، با مدیریت بهینه مخزن سد می‌توان آب مازاد را برای رفع نیازهای زیست‌محیطی دریاچه ارومیه تخصیص داد. این بازه زمانی بهترین فصول برای رهاسازی آب به دریاچه ارومیه می‌باشد زیرا به علت عدم کشت محصولات کشاورزی، حجم آب با کمترین استفاده توسط کشاورزان و انحراف به زمین‌های کشاورزی، می‌تواند وارد دریاچه شود. بدون وجود پیش‌بینی‌های دقیق و واقعی، وزرات نیرو تمایلی برای رهاسازی آب در فصول غیر کشاورزی ندارد و رهاسازی آب به سمت دریاچه را تا فصل بهار و کسب اطمینان از حصول رواناب کافی برای سد به تاخیر می‌اندازد؛ در حالی که در صورت رهاسازی آب به سمت دریاچه در فصول بهار و تابستان حجم زیادی از آب به مصرف کشاورزان رسیده و بخش بسیار کمی نیز تبخیر می‌شود و عملاً نیاز زیست‌محیطی دریاچه ارومیه تامین نمی‌شود. مدل همچنین توانست روزهای بیشینه ورودی آب در ۱۸ مارس و ۸ آوریل ۲۰۲۰ را بخوبی پیش‌بینی کند. پیش‌بینی این روزها از دو منظر ضروری است؛ اولاً می‌تواند منجر به مدیریت بهتر سیلاب و در نتیجه کاهش خسارت‌ها در پایین دست شود. دوماً، پیش‌بینی حجم آب ورودی به مخزن می‌تواند به برنامه ریزی بهینه کشت کمک نماید تا در صورت بروز خشکسالی، خسارت مالی به کشاورزان کمتر وارد شود.



شکل ۵- سری زمانی روزانه جریان مشاهداتی و پیش‌بینی شده ورودی به مخزن بوکان با افق پیش‌بینی ۱ ماهه در ابتدای هر ماه

۵. نتیجه‌گیری

در این تحقیق، مدل پیش‌بینی پارامترهای آب و هوایی در بالادست سد بوکان در حوضه آبریز دریاچه ارومیه توسعه داده شده است. مدل پیش‌بینی با استفاده از روش هوش مصنوعی GMDH، SVR و هیبرید به ریزمقیاس‌سازی پیش‌بینی‌های خام پارامترهای بارش و دما دو سازمان ECMWF و NCEP در مقیاس ماهانه و روزانه می‌پردازد. به منظور تخمین پارامترهای روش هیبرید از روش بهینه‌سازی PSO کمک گرفته شد تا به بهینه‌سازی پارامترها با استفاده از تابع هدف NSE بین داده‌های مشاهداتی و داده‌های ریزمقیاس‌سازی شده پردازد. نتایج نشان داد به علت عدم قطعیت در بارش، پیش‌بینی این پارامتر نیازمند استفاده از روشی پیچیده‌تر و هیبریدی است و نمی‌توان آن را با روش‌های ساده هوش مصنوعی، ریزمقیاس‌سازی نمود. در حالی که روش GMDH به تنهایی قادر به ریزمقیاس‌سازی دما در مقیاس روزانه است؛ زیرا این پارامتر عدم قطعیت کمتری نسبت به بارش دارد. نتایج NSE برای ریزمقیاس‌سازی بارش ماهانه با افق پیش‌بینی یک ماهه در روش هیبرید برای داده‌های ECMWF برای دوره آموزش و تست به ترتیب برابر ۰/۵۴ و ۰/۶ بدست آمد. همچنین ریزمقیاس‌سازی پیش‌بینی روزانه دما با افق پیش‌بینی شش ماهه برای دوره آموزش و تست داده‌های ECMWF به



ترتیب برابر ۰/۷۸ و ۰/۸۵ و برای داده‌های NCEP به ترتیب ۰/۸۵ و ۰/۸۳ بدست آمد. نتایج بدست آمده نشان داد که داده‌های ECMWF عملکرد بهتری در پیش‌بینی پارامتر بارش در مناطق کوهستانی و شرایط یکسان را داراست. در نهایت داده‌های پیش‌بینی پارامترهای آب و هوایی به مدل بارش-رواناب توسعه داده شده وارد شد تا رواناب ورودی به سد را برای دو سال متوالی ۲۰۲۰ و ۲۰۲۱ پیش‌بینی نماید. نتایج حاکی از قابلیت خوب مدل در پیش‌بینی این دو سال با NSE برابر با ۰/۶۷ است. این کار موجب تخصیص بهینه منابع آب توسط بهره‌برداران سد و سیاست‌گذاران آب در حوضه آبریز دریاچه ارومیه می‌شود تا در نهایت با اتخاذ تصمیم‌های درست موجب افزایش آب ورودی به دریاچه ارومیه و احیای کامل این دریاچه شود. رویکرد این تحقیق را می‌توان نه تنها در سایر مناطق دیگر این حوضه آبریز بلکه در سایر حوضه‌های آبی کشور پیاده نمود.

۶. مراجع

- [1] S. J. Johnson *et al.*, "SEAS5 : the new ECMWF seasonal forecast system," pp. 1087–1117, 2019.
- [2] Y. Chen *et al.*, "Spatial performance of multiple reanalysis precipitation datasets on the southern slope of central Himalaya," *Atmos. Res.*, vol. 250, no. September 2020, p. 105365, 2021, doi: 10.1016/j.atmosres.2020.105365.
- [3] S. Gubler *et al.*, "Assessment of ECMWF SEAS5 seasonal forecast performance over South America," *Weather Forecast.*, vol. 35, no. 2, pp. 561–584, 2020, doi: 10.1175/WAF-D-19-0106.1.
- [4] N. Voisin, F. Pappenberger, D. P. Lettenmaier, R. Buizza, and J. C. Schaake, "Application of a medium-range global hydrologic probabilistic forecast scheme to the Ohio River basin," *Weather Forecast.*, vol. 26, no. 4, pp. 425–446, 2011, doi: 10.1175/WAF-D-10-05032.1.
- [5] S. Saha *et al.*, "The NCEP climate forecast system version 2," *J. Clim.*, vol. 27, no. 6, pp. 2185–2208, 2014, doi: 10.1175/JCLI-D-12-00823.1.
- [6] T. Phan-Van, T. Nguyen-Xuan, H. Van Nguyen, P. Laux, H. Pham-Thanh, and T. Ngo-Duc, "Evaluation of the NCEP Climate Forecast System and its downscaling for seasonal rainfall prediction over Vietnam," *Weather Forecast.*, vol. 33, no. 3, pp. 615–640, 2018, doi: 10.1175/WAF-D-17-0098.1.
- [7] X. Yuan, E. F. Wood, J. K. Roundy, and M. Pan, "CFSv2-Based Seasonal Hydroclimatic Forecasts over the Conterminous United States," *J. Clim.*, vol. 26, no. 13, pp. 4828–4847, Jul. 2013, doi: 10.1175/JCLI-D-12-00683.1.
- [8] Y. Lang, L. Luo, A. Ye, and Q. Duan, "Do CFSv2 Seasonal Forecasts Help Improve the Forecast of Meteorological Drought," pp. 1–14, 2020, doi: 10.3390/w12072010.
- [9] J. Siegmund, J. Bliefert, P. Laux, and H. Kunstmann, "Toward a seasonal precipitation prediction system for West Africa: Performance of CFSv2 and high-resolution dynamical downscaling," *J. Geophys. Res.*, vol. 120, no. 15, pp. 7316–7339, 2015, doi: 10.1002/2014JD022692.
- [10] E. N. Benderskaya, "Nonlinear Trends in Modern Artificial Intelligence: A New Perspective," pp. 113–124, 2013, doi: 10.1007/978-3-642-34422-0_8.
- [11] M. C. Valverde Ramírez, N. J. Ferreira, and H. F. de Campos Velho, "Linear and nonlinear statistical downscaling for rainfall forecasting over southeastern Brazil," *Weather Forecast.*, vol. 21, no. 6, pp. 969–989, 2006, doi: 10.1175/WAF981.1.
- [12] O. Kisi and M. Cimen, "Precipitation forecasting by using wavelet-support vector machine conjunction model," *Eng. Appl. Artif. Intell.*, vol. 25, no. 4, pp. 783–792, 2012, doi: 10.1016/j.engappai.2011.11.003.
- [13] R. F. Chevalier, G. Hoogenboom, R. W. McClendon, and J. A. Paz, "Support vector regression with reduced training sets for air temperature prediction: A comparison with artificial neural networks," *Neural Comput. Appl.*, vol. 20, no. 1, pp. 151–159, 2011, doi: 10.1007/s00521-010-0363-y.
- [14] M. H. Dehghanipour, H. Karami, H. Ghazvinian, Z. Kalantari, and A. H. Dehghanipour, "Two Comprehensive and Practical Methods for Simulating Pan Evaporation under Different Climatic Conditions in Iran," *Water*, vol. 13, no. 20, p. 2814, Oct. 2021, doi: 10.3390/w13202814.
- [15] ECMWF, "IFS DOCUMENTATION – Cy38r1, PART III : DYNAMICS AND NUMERICAL PROCEDURES Table of contents," Shinfield Park, Reading, RG2 9AX, England, 2013.
- [16] P. Algorithms, J. Du, Y. Liu, Y. Yu, and W. Yan, "A Prediction of Precipitation Data Based on Support Vector Machine and Particle Swarm Optimization," 2017, doi: 10.3390/a10020057.
- [17] A. D. Mehr, V. Nourani, and V. K. K. M. A. Ghorbani, "A hybrid support vector regression – firefly model for monthly rainfall forecasting," *Int. J. Environ. Sci. Technol.*, no. 0123456789, 2018, doi: 10.1007/s13762-018-1674-2.



- [18] E. Dodangeh, M. Panahi, F. Rezaie, S. Lee, and D. Tien, "Novel hybrid intelligence models for flood-susceptibility prediction : Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search," *J. Hydrol.*, vol. 590, no. May, p. 125423, 2020, doi: 10.1016/j.jhydrol.2020.125423.
- [19] L. Sun and Y. Lan, "Statistical downscaling of daily temperature and precipitation over China using deep learning neural models: Localization and comparison with other methods," *Int. J. Climatol.*, vol. 41, no. 2, pp. 1128–1147, 2021, doi: 10.1002/joc.6769.
- [20] A. H. Dehghanipour, D. Moshir Panahi, H. Mousavi, Z. Kalantari, and M. Tajrishy, "Effects of Water Level Decline in Lake Urmia, Iran, on Local Climate Conditions," *Water*, vol. 12, no. 8, p. 2153, Jul. 2020, doi: 10.3390/w12082153.
- [21] M. Ghaehri, M. H. Baghal-Vayjooee, and J. Naziri, "Lake Urmia, Iran: A summary review," *Int. J. Salt Lake Res.*, vol. 8, no. 1, pp. 19–22, 1999, doi: 10.1007/bf02442134.
- [22] A. B. Dariane and E. Pouryafar, "Quantifying and projection of the relative impacts of climate change and direct human activities on streamflow fluctuations," *Clim. Change*, vol. 165, no. 1, p. 34, 2021, doi: 10.1007/s10584-021-03060-w.
- [23] A. Meydani, A. Dehghanipour, and M. Tajrishy, "Development of a Daily Rainfall-Runoff Model to Simulate the Bukan Reservoir Inflow and Quantify the Effects of Severe Historical Drought Using WEAP Model and MultiObjective Calibration," *Iran-Water Resour. Res.*, vol. 17, no. 3, pp. 149–164, 2021, [Online]. Available: http://iwrr.sinaweb.net/article_137713.html.
- [24] Ministry of Energy, "Implementing solutions to reduce the agricultural water consumption of the Zarrinehrood and Siminehrood sub-basin by 40% (In Persian)," 2016.
- [25] ECMWF, "Seasonal forecast monthly statistics on single levels," 2021. <https://cds.climate.copernicus.eu/cdsapp#!/dataset/10.24381/cds.68dd14c3?tab=overview> (accessed Jun. 14, 2018).
- [26] ECMWF, "Seasonal forecast daily and subdaily data on single levels," 2021. <https://cds.climate.copernicus.eu/cdsapp#!/dataset/10.24381/cds.181d637e?tab=overview> (accessed Jun. 14, 2018).
- [27] A. G. Ivakhnenko and A. A. Zholnarskij, "Estimating the coefficients of polynomials in parametric GMDH algorithms by the improved instrumental variables method," *J. Autom. Inf. Sci.*, vol. 25, Jan. 1992.
- [28] N. Nariman-zadeh, A. Darvizeh, M. Darvizeh, and H. Gharababaei, "Modelling of explosive cutting process of plates using GMDH-type neural network and singular value decomposition," *J. Mater. Process. Technol.*, vol. 128, no. 1–3, pp. 80–87, 2002, doi: 10.1016/S0924-0136(02)00264-9.
- [29] J. Geng, W. Gan, J. Xu, R. Yang, and S. Wang, "Support vector machine regression (SVR)-based nonlinear modeling of radiometric transforming relation for the coarse-resolution data-referenced relative radiometric normalization (RRN)," *Geo-Spatial Inf. Sci.*, vol. 23, no. 3, pp. 237–247, 2020, doi: 10.1080/10095020.2020.1785958.
- [30] B. Yaghoubi, S. A. Hosseini, and S. Nazif, "Monthly prediction of streamflow using data-driven models," 2019.
- [31] R. Owens and T. Hewson, "ECMWF Forecast User Guide," 2018. doi: 10.21957/m1cs7h.
- [32] S. Saha *et al.*, "The NCEP climate forecast system reanalysis," *Bull. Am. Meteorol. Soc.*, vol. 91, no. 8, pp. 1015–1057, 2010, doi: 10.1175/2010BAMS3001.1.
- [33] S. Sodoudi, A. Noorian, M. Geb, and E. Reimer, "Daily precipitation forecast of ECMWF verified over Iran," *Theor. Appl. Climatol.*, vol. 99, no. 1–2, pp. 39–51, 2010, doi: 10.1007/s00704-009-0118-9.