

ارزیابی دو مدل تلفیقی هیدرولوژیکی - جعبه سیاه برای پیش بینی سیلاب در حوضه آبریز هلیل رود

الهه فرودی صفات^۱، محمدمهدی احمدی^{۲*}، کورش قادری^۲، سودابه گلستانی کرمانی^۳

۱. دانشجوی کارشناسی ارشد، سازه های آبی، بخش مهندسی آب، دانشگاه شهید باهنر کرمان، کرمان

۲. دانشیار بخش علوم و مهندسی آب، دانشگاه شهید باهنر کرمان، کرمان

۳. استادیار بخش علوم و مهندسی آب، دانشگاه شهید باهنر کرمان، کرمان

(تاریخ دریافت ۱۳۹۹/۰۹/۱۰، تاریخ تصویب ۱۴۰۰/۰۲/۲۲)

چکیده

پیش بینی جریان رودخانه در شرایط سیلابی یک بخش ضروری در مطالعات مهندسی رودخانه است که در صورت تخمین دقیق، کمک زیادی به اثربخشی بیشتر برنامه های مدیریتی کرده و کاهش صدمات مالی و جانی را فراهم می کند. استفاده از مدل های مناسب و افزایش دقت این مدل ها منجر به بهبود در دقت نتایج پیش بینی خواهد شد. یکی از راهکارهای موجود برای افزایش دقت مدل های موجود و معتبر بارش - رواناب، ساخت مدل تلفیقی به کمک لینک روش های هوشمند به این مدل ها است. در تحقیق حاضر، از تلفیق مدل هیدرولوژیکی WEAP 21 با مدل های جعبه سیاه ساخته شده بر اساس روش ANN و GMDH به منظور افزایش دقت مدل WEAP استفاده شد. سپس، از مدل ایجاد شده برای شبیه سازی سیلاب قسمتی از بازه رودخانه هلیل رود در استان کرمان استفاده شد. اطلاعات بارش، دبی، رطوبت، باد و دما برای رکورد موجود منهای دو سال آخر به مدل WEAP وارد شدند. بعد از واسنجی و اعتبارسنجی مدل، دو سال آخر پیش بینی شد. نتایج به دست آمده نشان داد مدل تلفیقی WEAP-ANN ($R^2=0/78$) توانست رواناب را با دقت بیشتری در مقایسه با مدل WEAP- ($R^2=0/59$) و GMDH ($R^2=0/14$) در حوضه آبریز مورد نظر تخمین بزند.

کلیدواژگان: بارش - رواناب، شبکه عصبی مصنوعی، کنترل گروهی داده ها، مدل سازی، نرم افزار WEAP.

مقدمه

پیش‌بینی بلندمدت بارش و رواناب برای مناطق خشک و نیمه‌خشک یکی از مسائل حیاتی و مهم برای مدیریت و برنامه‌ریزی منابع آب به شمار می‌رود [۱]. با در نظر گرفتن نقشه پهنه‌بندی سیل، که نشان‌دهنده احتمال و بزرگی حوادث سیل در یک منطقه است و همچنین، نقشه‌های ارزیابی خطر سیل که بیان‌کننده پیامدهای احتمالی وقوع رویداد سیل از نظر صدمه به جمعیت و دارایی‌های آسیب‌دیده و خسارت‌های اقتصادی پیش‌بینی‌شده است، می‌توان برنامه‌ریزی برای کاهش خسارت‌ها و همچنین، مدیریت کاربری اراضی در مناطق مستعد سیل را بهبود بخشید. بنابراین، برآورد دقیق رواناب ناشی از بارندگی در مناطق مستعد سیلاب ضروری است و به این منظور، ارائه ابزارهای قابل اعتماد و سریع برای پیش‌بینی سیلاب به منظور ایجاد استراتژی‌های مؤثر در مواقع اضطراری برای کاهش اثرات سیلاب مهم است [۲]. این برآورد با استفاده از مدل‌های بارش-رواناب که غالباً بر مبنای فیزیک مسئله توسعه یافته‌اند و همچنین، روش‌هایی که از تحلیل داده‌ها برای مدل‌سازی استفاده می‌کنند، صورت می‌گیرد. در تمام این روش‌ها هدف افزایش دقت در برآورد جریان و یا سیلاب است. افزایش دقت و تعیین وضعیت خطاها می‌تواند ریسک تصمیم‌گیری را کاهش دهد و در پی آن، خسارت‌های احتمالی را به حداقل برساند.

در مدل‌سازی ریاضی یک رخداد هیدرولوژیکی، عدم قطعیت اجتناب‌ناپذیر است که به عنوان ضعف این مدل‌ها محسوب می‌شود. یکی از روش‌های کاهش باقی‌مانده و بهبود عملکرد مدل‌های یادشده این است که به طور مستقیم به رفع نقص در مدل قطعی پرداخته شود (یعنی توصیف هندسی سیستم و یا معادلات فیزیکی که توصیف عملکرد سیستم را انجام می‌دهند، بهبود یابد). این روش منجر به پیچیده‌تر شدن مدل‌سازی می‌شود و لزوماً پیچیدگی مدل به دلیل محدودیت‌های داده‌ها و افزایش دشواری در برآورد پارامترهای مدل، همیشه منجر به نتیجه بهتر نمی‌شود. روش دیگر برای بهبود تخمین رخداد هیدرولوژیکی، استفاده از مدل‌های «جعبه‌سیاه» یا «Black Box» است که به خروجی از مدل هیدرولوژیکی قطعی و یا باقی‌مانده آن متصل می‌شود. اگر از یک مدل «جعبه‌سیاه» در ترکیب با مدل هیدرولوژیکی قطعی

استفاده شود، حدس زده می‌شود که پیش‌بینی نتایج نهایی سریع، دقیق و ارزان و به‌صرفه خواهد بود [۳].

با پیشرفت‌های اخیر در زمینه هوش مصنوعی و محاسبات نرم در مطالعات منابع آب، استفاده از این روش‌ها می‌تواند گزینه مناسبی برای مدل‌سازی فرایندهای هیدرولوژیکی و هیدرولیکی باشد [۴]. مزیت اصلی روش‌های هوشمند نسبت به روش‌های کلاسیک، بدون نیاز بودن به توضیح صریح مکانیزم فرایندهایی بر مبنای مفاهیم ریاضی است [۵]. از طرفی، با استفاده از روش‌های هوشمند، می‌توان عدم قطعیت‌های ذاتی موجود در متغیرها و داده‌ها را وارد مدل‌سازی کرد که کارایی این روش‌ها در برخی تحقیقات بررسی شده است. از جمله بنی‌حیب (۲۰۱۶) پیش‌بینی سیل را با استفاده از مدل متداول بارش-رواناب و مدل جعبه‌سیاه بارش-رواناب انجام داد. ایشان از دینامیک شبکه عصبی مصنوعی (DANN^۱) به عنوان نوعی مدل ابتکاری جعبه‌سیاه بارش-رواناب و از مدل HEC-HMS به عنوان نوعی مدل بارش-رواناب سنتی برای پیش‌بینی سیل استفاده کرد. در تحقیق یادشده مقایسه کارایی مدل HEC-HMS و دینامیک شبکه عصبی مصنوعی برای تعیین هشدار زمان سیل در حوضه آبخیز شهری با شیب تند انجام گرفت. نتایج به‌دست‌آمده از پژوهش آنها نشان داد با توجه به اطلاعات کمتر مورد نیاز برای پیش‌بینی سیلاب در مدل دینامیک شبکه عصبی مصنوعی (که نوعی مدل جعبه‌سیاه بارش-رواناب بود) و تخمین طولانی‌تر از زمان برای تعیین هشدار زمان سیل، تحقیقات آینده باید روی این نوع از مدل پیش‌بینی سیل صورت گیرد [۶].

کلت (۲۰۱۷) به پیش‌بینی بارش ماهانه با تلفیق شبکه عصبی مصنوعی و تحلیل مجموعه مقادیر تکین (SSA^۲) پرداخت. او از SSA برای پیش‌پردازش سیگنال‌های ورودی خام برای ارائه داده‌های باکیفیت به شبکه عصبی مصنوعی استفاده کرد. براساس نتایج به‌دست‌آمده از پژوهش ایشان دقت پیش‌بینی بارش ماهانه مدل تلفیقی SSA-(R=۰/۸۵۸) ANN نسبت به مدل ANN^۳ (R=۰/۴۴۴) افزایش یافت [۷]. اسدی و همکاران (۲۰۱۹) با استفاده از شاخص اتصال هیدرولوژیکی و مدل شبکه عصبی مصنوعی به مدل‌سازی

1. Dynamic Artificial Neural Network
2. Singular Spectrum Analysis
3. Artificial Neural Network

به طور چشمگیری عملکرد GMDH و SVR را بهبود بخشیدند [۱۰].

عقل‌پور و ورشایان (۲۰۲۰) دو مدل تصادفی $ARMA^3$ و $ARIMA^4$ و سه مدل هوش مصنوعی (GMDH⁵, MLP⁶ and GRNN⁵) برای مدل‌سازی و پیش‌بینی جریان روزانه رودخانه زیلاکی رود در شمال ایران را ارزیابی کردند. نتایج پژوهش آنها بیانگر دقت زیاد مدل‌های هوش مصنوعی در مقایسه با مدل‌های تصادفی بود و همچنین، از بین مدل‌های هوش مصنوعی، مدل‌های GMDH و MLP بهترین عملکرد را داشتند [۱۱].

با توجه به ضرورت تخمین دقیق سیلاب‌ها برای مدیریت منابع آب و کاهش خسارت‌ها به‌ویژه در مناطق خشک و برای بهبود دقت مدل‌های بارش-رواناب و بر اساس نتایج محققان پیشین که عملکرد مناسب روش‌های هوشمند ANN و GMDH را در مدل‌سازی سیلاب نشان داد، در تحقیق حاضر به توسعه و ارزیابی دو مدل تلفیقی جعبه‌سیاه با مدل هیدرولوژیکی WAEP 21 پرداخته شد. مدل جعبه‌سیاه با استفاده از مدل‌های هوشمند ANN و GMDH ساخته شد و برای بررسی کارایی مدل‌های تلفیقی، بخشی از بازه رودخانه هلیل‌رود مدل‌سازی شد.

مواد و روش‌ها

در این تحقیق به منظور ساخت و ارائه مدل تلفیقی پیش‌بینی رواناب در حوضه آبریز هلیل‌رود، از مدل بارش-رواناب WEAP 21 استفاده شد. سپس، با اضافه کردن خروجی‌های این مدل به روش‌های ANN و GMDH به ساخت مدل‌های تلفیقی جعبه‌سیاه پرداخته شد که هر بخش در ادامه به تفکیک ارائه شده است.

مشخصات منطقه مطالعه شده

هلیل‌رود در استان کرمان با طول ۳۹۰ کیلومتر به عنوان بزرگ‌ترین رود جنوب شرق ایران شناخته شده است که زیرحوضه هامون - جازموریان است و در انتها به تالاب جازموریان می‌ریزد. با توجه به مساحت حوضه و همچنین، پرآب بودن سرشاخه‌های این رودخانه، حوضه هلیل‌رود تأثیر زیادی بر منابع آبی منطقه دارد.

بارش-رواناب پرداختند. آنها علاوه بر ورودی‌های آب‌وهوایی و هیدرولوژیکی، از سری‌های زمانی هیدروژئومورفیک و بیوفیزیکی از جمله شاخص پوشش گیاهی نرمال شده و شاخص اتصال (نوعی شاخص اتصال هیدرولوژیکی) به عنوان ورودی استفاده کردند. نتایج پژوهش آنها نشان داد ترکیب شاخص اتصال و پوشش گیاهی نرمال شده با مدل ANN، سبب بهبود عملکرد در مقایسه با مدل ANN فقط با استفاده از پارامترهای آب و هوایی می‌شود. همچنین، ورودی‌ها با شاخص اتصال در مقایسه با ورودی‌ها با شاخص پوشش گیاهی نرمال شده به بهبود بیشتر عملکرد مدل کمک می‌کنند [۸].

زبا و همکاران (۲۰۱۹) به پیش‌بینی بارش با رویکرد ترکیبی شبکه عصبی مصنوعی پرداختند. آنها عملکرد شبکه‌های عصبی مختلف را به منظور پیش‌بینی بارش مطالعه کردند و سپس، الگوریتمی برای ترکیب شبکه‌های عصبی برای پیش‌بینی بارش با روش‌های خطی و غیرخطی ارائه دادند. پس از مدل‌سازی و مقایسه نتایج، RMSE در مدل شبکه عصبی مصنوعی ۰/۰۵، در مدل شبکه‌های عصبی ترکیبی خطی ۰/۰۷ و در مدل شبکه‌های عصبی ترکیبی غیرخطی ۰/۰۱ بود. آنها نتیجه گرفتند که برای پیش‌بینی بارش توسط شبکه‌های عصبی می‌توان از یک روش قوی‌تر به نام شبکه عصبی ترکیبی غیرخطی بهره برد که منجر به کاهش خطا می‌شود [۱].

گودا و همکاران (۲۰۱۹) به پیش‌بینی بارش با استفاده از ANN مبتنی بر الگوریتم پس‌انتشار خطا در شهر بنگالور پرداختند. نتایج به‌دست‌آمده از پژوهش آنها نشان داد این مدل می‌تواند بارندگی طولانی‌مدت را با دقت زیادی (مقدار RMSE برابر با ۰/۴۴۶ و همبستگی ۰/۷۴) پیش‌بینی کند [۹].

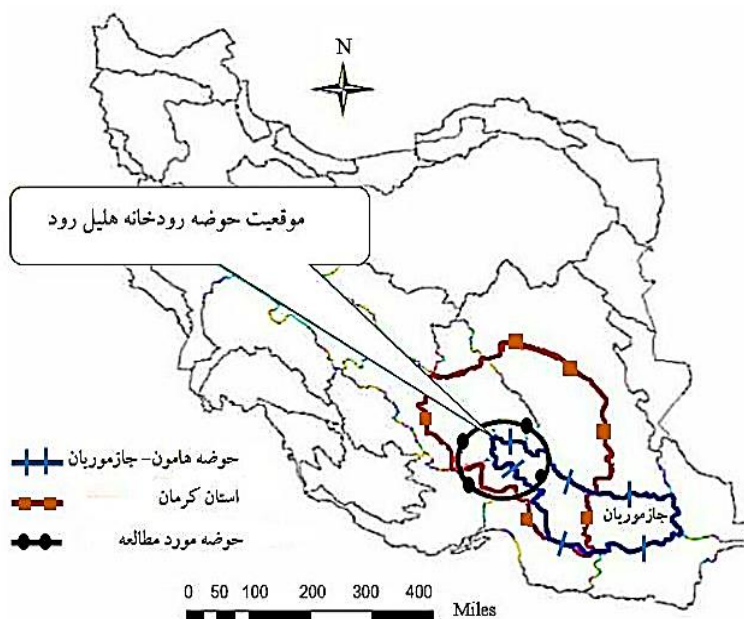
دودانگه و همکاران (۲۰۲۰) با استفاده از مدل‌های $GMDH^1$ و SVR^2 نوعی مدل اولیه حساسیت به سیل ساختند. سپس، پارامترهای مدل را با استفاده از الگوریتم ژنتیک و جست‌وجوی هماهنگی، برای به دست آوردن نقشه‌های حساسیت سیل بهینه کردند. نتایج پژوهش آنها نشان‌دهنده برتری مدل SVR ($RMSE=0/29-0/36$) نسبت به مدل $GMDH$ ($RMSE=0/0-32/39$) بود و همچنین، هر دو الگوریتم ژنتیک و جست‌وجوی هماهنگی

3. AutoRegressive Moving Average
4. AutoRegressive Integrated Moving Average
5. Generalized Regression Neural Network
6. Multi Layer Perceptron

1. Group Method of Data Handling
2. Support Vector Regression

ماهانسه از سال آبی ۱۹۹۳ تا سال ۲۰۰۷ برای دوره واسنجی، از سال ۲۰۰۷ تا سال ۲۰۱۳ برای دوره اعتبارسنجی و از سال ۲۰۱۳ تا سال ۲۰۱۵ برای پیش‌بینی در نظر گرفته شدند. دو سال آخر برای ارزیابی این مدل، در فرایند پیش‌بینی آینده بررسی شد. به دلیل اینکه ایستگاه سلطانی مساحت کوچکی از منطقه را تحت پوشش قرار می‌دهد و از طرفی، برای واسنجی مدل WEAP، باید اطلاعات حداقل دو ایستگاه شامل ایستگاه مورد نظر و ایستگاه بالادست موجود باشد و اطلاعات ایستگاه بالادست ایستگاه سلطانی در دسترس نبود، فقط از داده‌های ایستگاه کنارویی که خروجی کل حوضه مطالعه شده است، برای شبیه‌سازی‌ها و ارزیابی دقت مدل‌های ارائه شده استفاده شد.

در این پژوهش، حوضه‌ای به مساحت ۷/۳۷۱۱ کیلومتر مربع از زیرحوضه‌های حوضه آبریز رودخانه هلیل رود انتخاب شد (شکل‌های ۱ و ۲). سرشاخه‌ای از رودخانه هلیل رود که از ابتدای رودخانه سلطانی تا ایستگاه کنارویی است، به عنوان رودخانه اصلی انتخاب شد که شامل دو ایستگاه هیدرومتری سلطانی با مختصات 32° شمالی، $29^{\circ} 04'$ شمالی، $56^{\circ} 31' 55''$ شرقی و ارتفاع ۲۰۷۰ متر و ایستگاه هیدرومتری کنارویی با مختصات $28^{\circ} 51' 31''$ شمالی، $57^{\circ} 14' 23''$ شرقی و ارتفاع ۱۴۵۶ متر می‌شود که هر دو منطقه ایستگاه هواشناسی دارند (شکل ۳). اطلاعات رودخانه مطالعه شده در جدول ۱ آمده است. اطلاعات موجود برای بررسی صحت پیش‌بینی مدل به سه قسمت تقسیم شد (داده‌های استفاده شده از شرکت آب منطقه‌ای استان کرمان دریافت شد)، داده‌ها با مقیاس



شکل ۱. موقعیت حوضه آبریز هامون - جازموریان و حوضه مطالعه شده

رویکردهای یکپارچه‌ای که از اقلیم، هیدرولوژی، کاربری اراضی و اولویت‌های مدیریت آب حوضه آبریز دارد، شبیه‌سازی منطقه مطالعه شده را به بهترین شکل ممکن انجام می‌دهد؛ از این‌رو نرم‌افزاری جامع به حساب می‌آید. در تحقیق حاضر ابتدا با استفاده از نرم‌افزار WEAP 21، حوضه آبریز هلیل رود به مساحت ۷/۳۷۱۱ کیلومتر مربع طراحی شد. به این منظور، شیپ فایل‌های منطقه از جمله رودخانه‌ها، موقعیت ایستگاه‌های هیدرومتری و

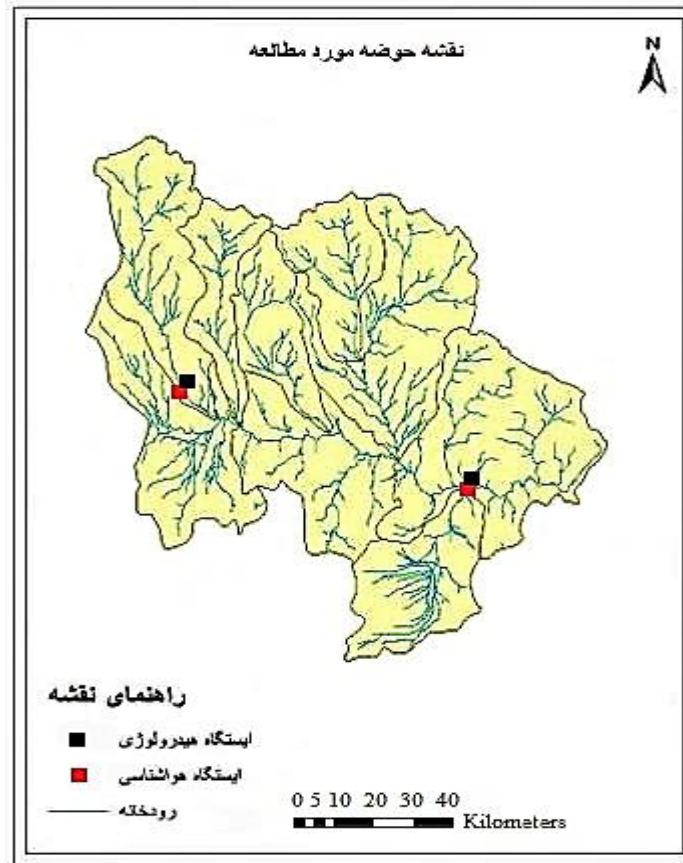
مدل WEAP

فرایند بارش - رواناب پدیده‌ای پیچیده و غیرخطی است. با توجه به مطالعات زیادی که در این زمینه انجام شده، مدل‌های شبیه‌سازی زیادی از جمله مدل WEAP¹ ارائه شده است که برای برنامه‌ریزی و مدیریت منابع آب است. این مدل توسط مؤسسه محیط زیست استکهلم آمریکا توسعه یافته است. نرم‌افزار WEAP با توجه به قابلیت‌ها و

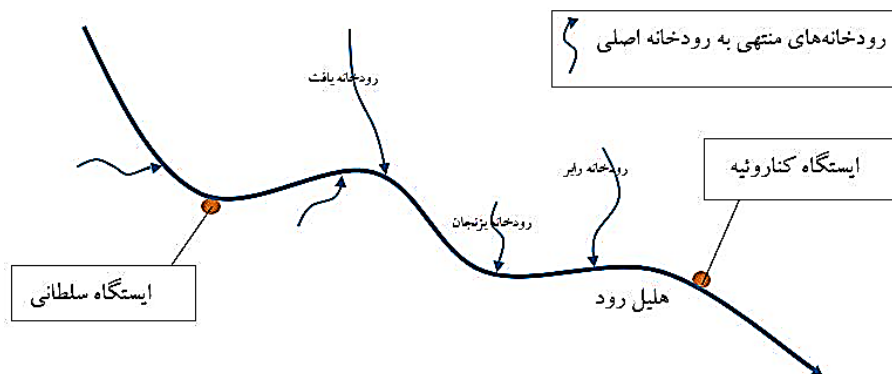
1. Water Evaluation & Planning

آبی ۱۹۹۳ تا سال ۲۰۰۷ برای دوره‌ی واسنجی، از سال ۲۰۰۷ تا سال ۲۰۱۳ برای دوره‌ی اعتبارسنجی و از سال ۲۰۱۳ تا سال ۲۰۱۵ برای پیش‌بینی در نظر گرفته شدند. دو سال آخر برای ارزیابی این مدل، در فرایند پیش‌بینی آینده استفاده شد.

ایستگاه‌های هواشناسی فراخوانی شدند (شکل ۴). سپس، اطلاعات مورد نظر مانند بارش، دبی، رطوبت، باد و دما به فرمت خاص نرم‌افزار (CSV)، تبدیل و در نرم‌افزار ثبت شدند. اطلاعات موجود برای بررسی صحت پیش‌بینی مدل به سه قسمت تقسیم شد. داده‌ها با مقیاس ماهانه از سال



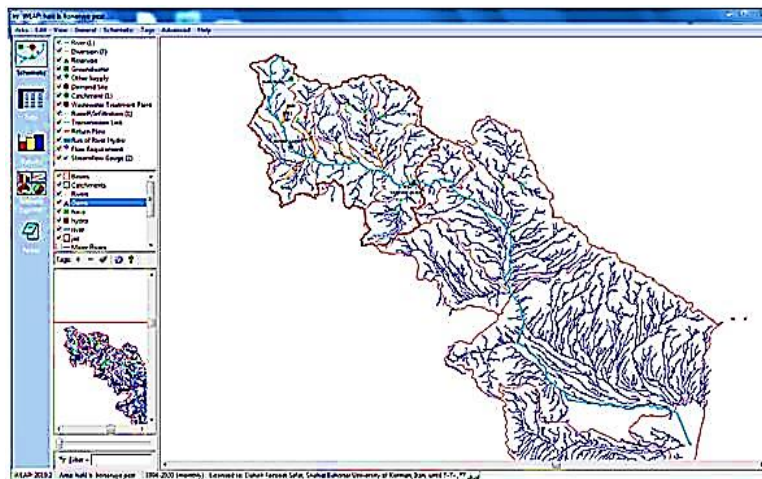
شکل ۲. موقعیت حوضه آبریز مطالعه‌شده



شکل ۳. شمای گرافیکی ساده‌شده از بازه رودخانه و ایستگاه‌ها در منطقه مطالعه‌شده

جدول ۱. اطلاعات رودخانه مطالعه شده

متوسط دبی (m^3/s)	متوسط سالانه بارندگی (mm)	حداقل دمای سالانه ($^{\circ}C$)	متوسط دمای سالانه ($^{\circ}C$)	حداکثر دمای سالانه ($^{\circ}C$)
۳/۴۲	۱۸۲/۴۲	۱۲	۲۰/۹	۲۹/۸



شکل ۴. طرح مدل ساخته شده در این تحقیق در محیط مدل WEAP برای منطقه هلیل رود

جامع است، زیرا حوضه را با دو لایه خاک بررسی می کند که این روش نسبت به روش ضرایب ساده شده احتیاج به اطلاعات گسترده تری از منطقه دارد. برای حوضه ای با نسبت های مختلف کاربری اراضی یا تیپ خاک، فرمول ریاضی برای محاسبه تغییرات ذخیره آب در لایه اول خاک بر حسب بیلان آب به صورت زیر بیان می شود [۱۲ و ۱۳].

$$Rd_j \frac{dz_{1,j}}{dt} = P_e(t) - PET(t)k_{c,j}(t) \left(\frac{5z_{1,j} - 2z_{1,j}^2}{3} \right) - P_e(t)z_{1,j}^{RRF_j} - f_j k_{s,j} z_{1,j}^2 - (1 - f_j) k_{s,j} z_{1,j}^2 \quad (1)$$

$$S_{max} \frac{dz_2}{dt} = \left(\sum_{j=1}^N (1 - f_j) k_{s,j} z_{1,j}^2 \right) - k_{s2} z_2^2 \quad (2)$$

در رابطه ۲ S_{max} : نفوذ عمقی از ذخیره لایه بالایی خاک و k_{s2} : هدایت هیدرولیکی اشباع لایه پایینی خاک (میلی متر بر زمان) است. اطلاعات منطقه مطالعه شده شامل فاکتور مقاومت جریان، هدایت هیدرولیکی لایه بالایی خاک و جهت جریان ترجیحی از قسمت PEST Calibration نرم افزار برای سال های ۱۹۹۳ تا ۲۰۰۷ واسنجی شده و سپس اعتبارسنجی شدند و پیش بینی مدل با ضرایب به دست آمده از نرم افزار انجام شد.

برای ارزیابی نتایج حاصل از واسنجی، اعتبارسنجی و پیش بینی مدل WEAP 21 از شاخص های ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE)، ضریب نش-

خصوصیات هیدرولوژیکی حوضه با استفاده از مدل بارش - رواناب (مدل رطوبت خاک) بررسی شد که رفتار تبخیر- تعرق، رواناب سطحی، جریان پایه، جریان بین لایه ای و نفوذ عمقی را برای یک حوضه تعریف می کند. در این روش واسنجی مدل روی اطلاعات خاک صورت می گیرد. مدل رطوبت خاک از بین مدل های دیگر نرم افزار، مدلی کامل تر و

در رابطه ۱ $Z_{1,j} = [1, 0]$: ذخیره نسبی آب خاک (بدون بعد)؛ Rd_j : ظرفیت نگهداری آب خاک (میلی متر)؛ P_e : بارش مؤثر (میلی متر)؛ $PET(t)$: تبخیر- تعرق پتانسیل گیاه مرجع (بر حسب میلی متر بر روز، که از فرمول پنمن-مانتیث محاسبه می شود)؛ $k_{c,j}$: ضریب گیاهی؛ RRF_j : فاکتور مقاومت جریان که به پوشش گیاهی بستگی دارد؛ $P_e(t)z_{1,j}^{RRF_j}$: رواناب سطحی؛ $f_j k_{s,j} z_{1,j}^2$: جریان بین لایه ای از لایه اول خاک؛ f_j : ضریب تقسیم که به نوع پوشش زمین، خاک و توپوگرافی بستگی دارد و جریان آب را به جریان های افقی و عمودی تقسیم می کند؛ و $k_{s,j}$: هدایت هیدرولیکی اشباع لایه منطقه ریشه (میلی متر بر زمان) است.

تغییرات ذخیره آب در لایه دوم خاک ($\frac{dz_2}{dt}$) از رابطه ۲ محاسبه می شود [۱۲ و ۱۳]:

توسعه‌یافته برای بهبود پیش‌بینی جریان، تلفیق یک مدل جعبه‌سیاه به خروجی و یا باقی‌مانده‌های یک مدل استدلالی است. ساده‌ترین حالت وقتی است که از مدل در حالت شبیه‌سازی استفاده شود. یعنی تمامی ورودی‌ها و خروجی‌ها اندازه‌گیری شوند و مدل با ورودی‌های اندازه‌گیری شده اجرا شود، اما هیچ اطلاعی در مورد خروجی‌های اندازه‌گیری شده به مدل داده نشود. در این حالت، خروجی مدل استدلالی به عنوان ورودی مدل جعبه‌سیاه استفاده می‌شوند و خروجی مدل جعبه‌سیاه به عنوان یک تخمین بهبودیافته از پارامتر مورد نظر (دبی) است. حالت دیگر، استفاده از مدل در حالت به‌روزرسانی است. در این حالت، ورودی‌ها و خروجی‌های اندازه‌گیری شده به مدل جعبه‌سیاه داده می‌شوند و خروجی‌های مدل جعبه‌سیاه، تصحیحی برای خروجی‌های مدل استدلالی هستند [۳]. در تحقیق حاضر برای بهبود دقت مدل از حالت شبیه‌سازی استفاده شد (شکل ۵).

ساتکلیف (NS) و شاخص تطابق (d) به شرح زیر استفاده شد [۱۳-۱۶].

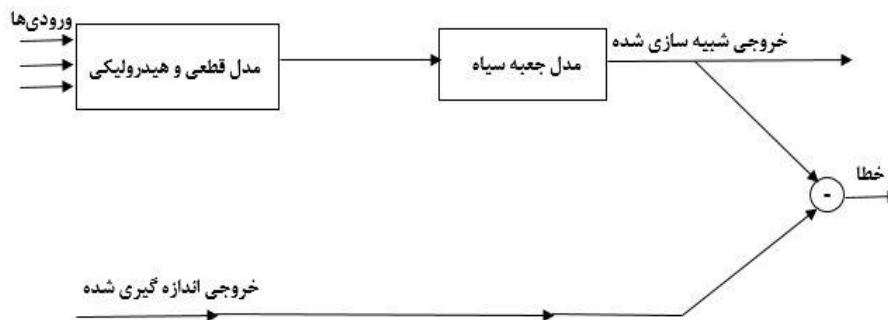
$$R^2 = \frac{\sum_{i=1}^n ((Q_{obs} - \mu)(Q_{sim} - \mu))^2}{\sum_{i=1}^n (Q_{obs} - \mu)^2 \sum_{i=1}^n (Q_{sim} - \mu)^2} \quad (۳)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{n}} \quad (۴)$$

$$NS = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{\sum_{i=1}^n (Q_{obs} - \bar{Q}_{obs})^2} \quad (۵)$$

$$d = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{\sum_{i=1}^n (|Q_{sim} - \bar{Q}_{obs}| + |Q_{obs} - \bar{Q}_{obs}|)^2} \quad (۶)$$

در روابط یادشده Q_{obs} مقدار دبی مشاهداتی، Q_{sim} مقدار دبی شبیه‌سازی شده، n تعداد کل داده‌ها و μ میانگین است. با توجه به نظر برون و یانگ (۲۰۰۶)، روش



شکل ۵. شمایی از چگونگی تلفیق مدل‌ها و ساخت مدل تلفیقی نهایی

مدل ANN

در این تحقیق برای شبیه‌سازی فرایند بارش- رواناب به طور مستقیم از جعبه‌ابزار شبکه عصبی مصنوعی نرم‌افزار MATLAB استفاده شد. ابتدا داده‌ها که در واقع خروجی مدل WEAP 21 هستند، به سه قسمت تقسیم شد: ۶۰ درصد داده‌های ورودی برای آموزش، ۲۰ درصد داده‌ها برای تست و ۲۰ درصد باقی‌مانده برای اعتبارسنجی استفاده شد. پس از فراخوانی متغیرها در نرم‌افزار MATLAB، با اجرای nntool وارد جعبه‌ابزار شبکه عصبی شده و مدل‌سازی آغاز شد. در این مدل‌سازی شبکه‌ای با خصوصیت‌های زیر ساخته شد.

پس از اتمام مدل‌سازی توسط نرم‌افزار WEAP 21، داده‌های خروجی که دبی شبیه‌سازی شده در نقطه خروجی حوضه آبریز مطالعه شده هستند، به عنوان داده ورودی به مدل‌های هوشمند ANN و GMDH وارد شد. ابتدا اطلاعات ورودی به مدل‌های هوشمند شامل دبی یکم، دوم و سوم دوره قبل با استفاده از رابطه ۷ به نرمال تبدیل شدند [۱۷].

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (۷)$$

در رابطه ۷ X_n داده نرمال شده، X داده هر سری و X_{min} و X_{max} به ترتیب کمترین و بیشترین مقدار در هر سری هستند.

جدول ۲. خصوصیت‌های مدل ANN

الگوریتم	نوع شبکه	قانون یادگیری	تابع آموزش	تابع انتقال	لابه پنهان	تعداد نرون
Levenberg-Marquardt	FF	BP	TRAINLM	TANSIG	۱	۵

بررسی صحت مدل توسعه داده شده GMDH قبل از کاربرد مدل GMDH نوشته شده در محیط نرم افزار MATLAB، صحت کارکرد آن توسط معادله دیفرانسیلی Mackey-Glass (رابطه ۱۰) بررسی شد [۱۸-۲۰].

$$\frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx(t) \quad (10)$$

که مقادیر a و b به ترتیب $0/2$ و $0/1$ هستند. پیش‌بینی مقادیر آینده این سری زمانی، یک مسئله پایه در مدل سازی است. هدف از این مدل سازی استفاده از مقادیر گذشته این سری زمانی تا زمان t برای پیش‌بینی مقادیر این سری زمانی در گام زمانی $t+p$ است که در این تحقیق $p=6$ است. در حالی که ورودی‌ها $x(t-18)$ ، $x(t-12)$ ، $x(t-6)$ ، $x(t)$ هستند، سری زمانی Mackey-Glass برای زمان $x(t+6)$ محاسبه شد. شرایط اولیه به صورت $x(0) = 1/2$ ، $\tau=17$ و مقادیر منفی برابر با صفر در نظر گرفته شدند. از ۵۰۰ جفت داده اولیه برای آموزش و ۵۰۰ جفت داده باقی مانده برای تست استفاده شد.

نتایج و بحث

نتایج حاصل از مدل‌های تلفیقی توسعه داده شده برای ارزیابی با نتایج اجرای مدل WEAP بدون تلفیق ارزیابی شد. این نتایج به تفکیک مدل جعبه سیاه ارائه شده است.

نتایج حاصل از مدل سازی فرایند بارش - رواناب با استفاده از نرم افزار WEAP 21 در ایستگاه کناروئیه

شکل ۶ دبی شبیه سازی شده توسط نرم افزار WEAP 21 و دبی مشاهداتی را نشان می دهد با توجه به نتایج ارائه شده در شکل های ۷ و ۸ مشخص است که نرم افزار WEAP 21 توانسته است در دوره واسنجی و اعتبارسنجی، دبی رواناب را با دقت خوبی (به ترتیب $R^2=0/9912$ و $R^2=0/9558$) برآورد کند. دوره های واسنجی و اعتبارسنجی ایستگاه کناروئیه در حالت اعمال آب درون حوضه ای پراکنش بسیار خوبی در دبی های کم دارند. همچنین، در دبی های پیک نیز پراکنش ها فقط با کمی اختلاف همراه هستند. اما با

بهترین نوع داده های ورودی از بین داده های دبی و بارش و ترکیب هردوی آنها، داده های دبی یکم، دوم و سوم دوره قبل بود که داده ها به صورت ماهانه از سال آبی ۱۹۹۳ تا سال آبی ۲۰۱۵ به نرمال تبدیل شده بودند. تعداد ۱۴۴ داده برای آموزش، ۴۸ داده برای اعتبارسنجی و ۴۸ داده برای تست به مدل داده شد. در نهایت، تعداد ۲۴ داده برای شبیه سازی در نظر گرفته شد. لایه ورودی شامل ۳ نرون بود و پس از اجرای مدل با توجه به داده ها، جواب به دست آمده دارای دو لایه بود که لایه اول دربرگیرنده ۵ نرون و لایه بعدی دربرگیرنده ۱ نرون بود.

مدل GMDH

مدل GMDH در محیط MATLAB کدنویسی شد و از آن به منظور مدل سازی بارش - رواناب به طور مستقیم استفاده شد. همانند روش شبکه عصبی، از بین داده های دبی، بارش و ترکیب آنها، بهترین داده ها شامل دبی یکم، دوم و سوم دوره قبل بودند که بهترین خروجی را برای داده های استفاده شده داشتند (داده ها از سال آبی ۱۹۹۳ تا سال آبی ۲۰۱۵ و به صورت ماهانه و نرمال شده بودند). داده ها به دو بخش آموزش و تست تقسیم شدند که هر بخش شامل ۱۳۲ داده بود و اعتبارسنجی مدل قبل از ایجاد شبکه و با سری زمانی Mackey-Glass انجام شد. در این تحقیق تعداد بهترین نرون های منتخب هر لایه برای لایه بعد به صورت $X=0/4 L_1$ بود که بهترین عملکرد را داشت.


برای ارزیابی دقت مدل سازی انجام شده با روش ANN و GMDH از پارامترهای آماری ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE)، میانگین مجذور انحراف (MSD) و میانگین قدرمطلق خطا (MAE) استفاده شد [۱۴ و ۱۸].

$$MSD = \frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{n} \quad (8)$$

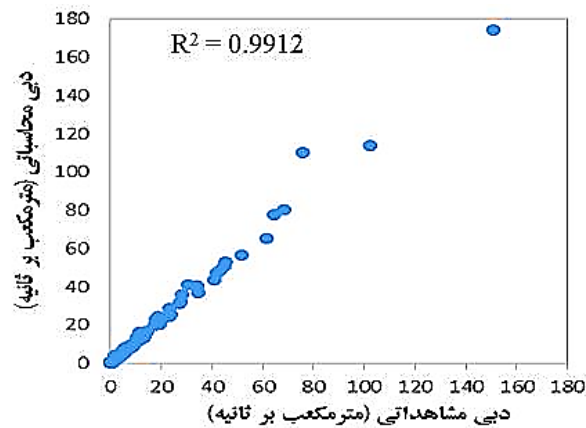
$$MAE = \frac{\sum_{i=1}^n |Q_{obs} - Q_{sim}|}{n} \quad (9)$$

در دوره اعتبارسنجی تمامی پارامترها به مدل وارد شده‌اند، اما در دوره پیش‌بینی دبی به مدل وارد نشده و از مدل خواسته شده است تا دبی را پیش‌بینی کند.


توجه به شکل ۹، پراکنش داده‌ها در دوره پیش‌بینی ایستگاه کناروئیه با اختلاف زیادی هم در دبی‌های کم و هم در دبی‌های زیاد همراه است. شایان یادآوری است که




شکل ۶. مقایسه نتایج نرم‌افزار WEAP و دبی مشاهداتی ایستگاه کناروئیه



شکل ۷. مقایسه نتایج نرم‌افزار WEAP و دبی مشاهداتی ایستگاه کناروئیه برای دوره واسنجی



شکل ۸. مقایسه نتایج نرم‌افزار WEAP و دبی مشاهداتی ایستگاه کناروئیه برای دوره اعتبارسنجی



شکل ۹. مقایسه نتایج نرم افزار WEAP و دبی مشاهداتی ایستگاه کناروئیه برای دوره پیش بینی

جدول ۳. نتایج ارزیابی مدل WEAP در پیش بینی رواناب دوره های واسنجی، اعتبارسنجی و پیش بینی در ایستگاه کناروئیه

آمار	دوره	تعداد ماه	میانگین دبی مشاهداتی (CMS)	میانگین دبی شبیه سازی (CMS)	R ²	RMSE(m ³ /se)	NS	d
اعتبارسنجی	۷۲	۲/۴۵	۳/۲۱	۰/۹۵	۲/۱۹	۰/۷۵	۰/۹۵	
پیش بینی	۲۴	۳/۰۹	۱۷/۷۲	۰/۱۴	۲۴/۰۴	-۲/۲۷	۰/۰۷	

مدل سازی فرایند بارش - رواناب با استفاده از مدل تلفیقی WEAP-ANN در ایستگاه کناروئیه در این قسمت برای شبیه سازی رواناب در مقیاس ماهانه در نقطه خروجی حوضه مطالعه شده، از تلفیق نتایج نرم افزار 21 WEAP و مدل شبکه عصبی مصنوعی استفاده شد. به این منظور، ابتدا خروجی نرم افزار WEAP 21 به داده نرمال تبدیل شد و سپس دبی یکم، دوم و سوم دوره قبل به عنوان داده ورودی مدل شبکه عصبی در نظر گرفته شد. نتایج ارائه شده در جدول ۴ نشان می دهد دقت مدل تلفیقی به دست آمده در مقایسه با مدل WEAP به طور محسوسی افزایش یافته است.


نتایج حاصل از شبیه سازی رواناب در ایستگاه کناروئیه با استفاده از نرم افزار WEAP 21 در جدول ۳ ارائه شده است. همان طور که مشاهده می شود، مقدار R² در دوره پیش بینی برابر با ۰/۱۴ است که قابل قبول نیست. برای بهبود دقت مدل، خروجی های نرم افزار که شامل دبی محاسباتی در نقطه خروجی حوضه مطالعه شده در مجاورت ایستگاه کناروئیه است به عنوان داده ورودی به مدل های هوشمند شبکه عصبی مصنوعی و الگوریتم کنترل گروهی داده ها وارد شد که نتایج به دست آمده به شرح زیر است.

جدول ۴. نتایج ارزیابی شبیه سازی فرایند بارش - رواناب در مدل تلفیقی WEAP-ANN


درصد تقسیم بندی داده ها			معیار
آموزش	اعتبارسنجی	تست	
۶۰	۲۰	۲۰	R ²
۰/۵۹۴	۰/۸۶۵	۰/۷۸۳	RMSE (m ³ /se)
۰/۲۵۲	۰/۱۳۹	۰/۲۴۵	MSD (m ³ /se) ²
۰/۰۶۴	۰/۰۱۹	۰/۰۶	MAE (m ³ /se)
۰/۱۶۹	۰/۰۹۳	۰/۱۴۷	

استاندارد بررسی شد. نتایج صحت‌سنجی مدل توسعه‌داده‌شده GMDH توسط تابع Mackey-Glass در شکل‌های ۱۰-۱۲ و جدول ۵ ارائه شده است.


بررسی صحت کارکرد مدل GMDH توسعه‌داده‌شده در محیط نرم‌افزار MATLAB قبل از کاربرد مدل نوشته‌شده در محیط MATLAB، صحت کارکرد آن توسط تخمین یک تابع



شکل ۱۰. سری زمانی Mackey-Glass



شکل ۱۱. پیش‌بینی سری زمانی Mackey-Glass توسط مدل توسعه‌داده‌شده GMDH در مرحله آموزش



شکل ۱۲. پیش‌بینی سری زمانی Mackey-Glass توسط مدل توسعه‌داده‌شده GMDH در مرحله تست

جدول ۵. نتایج ارزیابی در پیش‌بینی سری زمانی Mackey-Glass در مرحله آموزش و تست

مرحله	معیار	R ²	RMSE(m ³ /se)	MSD(m ³ /se) ²	MAE(m ³ /se)
آموزش		۰/۹۷	۰/۰۳۹	۰/۰۰۱	۰/۰۳
تست		۰/۹۷۲	۰/۰۳۸	۰/۰۰۱	۰/۰۲۹

نتایج ارائه شده در جدول ۵ نشان می‌دهد مدل توسعه داده شده GMDH در این تحقیق دقت مناسبی دارد. مدل سازی فرایند بارش - رواناب با استفاده از مدل تلفیقی WEAP-GMDH در ایستگاه کناروئیه در این قسمت برای شبیه سازی رواناب در مقیاس ماهانه در نقطه خروجی حوضه مطالعه شده، از تلفیق نتایج نرم افزار WEAP 21 و مدل توسعه داده شده GMDH استفاده شد. خروجی نرم افزار WEAP 21 به داده نرمال تبدیل شد و سپس، دبی یکم، دوم و سوم دوره قبل به عنوان داده ورودی مدل توسعه یافته در نظر گرفته شد. نتایج ارائه شده در جدول ۶ نشان می‌دهد دقت مدل تلفیقی به دست آمده در مقایسه با مدل WEAP بهبود یافته است.

نتایج ارائه شده در جدول ۵ نشان می‌دهد مدل توسعه داده شده GMDH در این تحقیق دقت مناسبی دارد. مدل سازی فرایند بارش - رواناب با استفاده از مدل تلفیقی WEAP-GMDH در ایستگاه کناروئیه در این قسمت برای شبیه سازی رواناب در مقیاس ماهانه در نقطه خروجی حوضه مطالعه شده، از تلفیق نتایج نرم افزار WEAP 21 و مدل توسعه داده شده GMDH استفاده شد. خروجی نرم افزار WEAP 21 به داده نرمال تبدیل شد و سپس، دبی یکم، دوم و سوم دوره قبل به عنوان داده ورودی مدل توسعه یافته در نظر گرفته شد. نتایج ارائه شده در جدول ۶ نشان می‌دهد دقت مدل تلفیقی به دست آمده در مقایسه با مدل WEAP بهبود یافته است.

جدول ۶. نتایج ارزیابی شبیه سازی فرایند بارش - رواناب با استفاده از مدل تلفیقی WEAP-GMDH

درصد تقسیم بندی داده ها		معیار
تست	آموزش	
۵۰	۵۰	R ²
۰/۵۹۴	۰/۸۲۳	RMSE (m ³ /se)
۰/۰۴۹	۰/۰۷۶	MSD (m ³ /se) ²
۰/۰۰۲	۰/۰۰۶	MAE (m ³ /se)
۰/۰۲۸	۰/۰۳۱	

مقایسه شاخص های آماری به دست آمده نشان می‌دهد مدل WEAP 21 قادر به پیش بینی سیلاب با دقت قابل قبول نبوده و تلفیق این مدل با مدل های هوشمند باعث بهبود پیش بینی رواناب شد.

مقایسه شاخص های آماری به دست آمده نشان می‌دهد مدل WEAP 21 قادر به پیش بینی سیلاب با دقت قابل قبول نبوده و تلفیق این مدل با مدل های هوشمند باعث بهبود پیش بینی رواناب شد.

نتیجه گیری

در این مطالعه از مدل هیدرولوژیکی WEAP 21 برای شبیه سازی فرایند بارش - رواناب در بخشی از حوضه آبریز هلیل رود که از ایستگاه سلطانی شروع و به ایستگاه کناروئیه ختم می‌شود، استفاده شد. نتایج به دست آمده نشان داد مدل WEAP 21 به رغم دقت مناسب در تخمین دبی در دوره واسنجی (R²=۰/۹۹۱۲) و اعتبارسنجی (R²=۰/۹۵۵۸) نتوانست تخمین مناسبی از این پارامتر در دوره پیش بینی (R²=۰/۱۴) داشته باشد. از این رو، برای بهبود دقت مدل، از تلفیق نتایج این مدل با مدل های هوشمند شبکه عصبی مصنوعی (ANN) و الگوریتم کنترل گروهی داده ها (GMDH) استفاده شد. شبکه عصبی مصنوعی FF با تابع انتقال TANSIG و تابع آموزش TRAINLM که دارای یک لایه پنهان و تعداد ۵ نرون بود، ساخته شد. کد نوشته شده الگوریتم کنترل گروهی داده ها توسط معادله دیفرانسیلی Mackey-Glass ارزیابی شد. مقایسه نتایج حاصل از ارزیابی مقادیر دبی سیلاب پیش بینی شده با مدل های یاد شده نشان داد دقت هر دو مدل در مقایسه با مدل WEAP افزایش یافته و مدل WEAP-ANN (R²=۰/۷۸) عملکرد بهتری در مقایسه با سایر مدل ها داشته است.

در این مطالعه همان طور که گفته شد، برای مقایسه مدل های شبیه سازی از مقادیر شاخص های آماری استفاده شده است؛ اما فقط در دامنه قابل قبول بودن نتایج، شرط لازم و کافی برای انتخاب یک مدل نیست. بنابراین، برای انتخاب بهترین مدل شبیه سازی فرایندهایی مانند سیلاب در یک منطقه، با تکیه بر یک مدل نمی توان تصمیم گیری انجام داد و از این نظر پیشنهاد می شود مقایسه چندین مدل برای شبیه سازی در یک منطقه صورت گیرد.

منابع

- [1]. Zabbah I, Roshani AR, Khafage A. Prediction of monthly rainfall using artificial neural network mixture approach, Case Study: Torbat-e Heydariyeh. *Journal of the Earth and Space Physics*. 2019;44(4):115-126.
- [2]. Dottori F, Salamon P, Bianchi A, Alfieri L, Hirpa FA, Feyen L. Development and evaluation of a framework for global flood hazard mapping. *Advances in Water Resources*. 2016;94: 87-102.
- [3]. Bruen M, Yang J. Combined hydraulic and black-box models for flood forecasting in urban drainage systems. *Journal of Hydrologic Engineering*. 2006;11(6):589-596.
- [4]. Bisht DCS, Raju MM, Joshi MC. ANN based river stage-discharge modeling for Godavari River, India. *Comput Model New Technol*. 2010;14(3):48-62.
- [5]. Shadmani M, Marofi S, Mohammadi K, Sabziparvar AA. Regional flood discharge modeling in Hamedan province using Artificial Neural Network. *Journal of Water and Soil Conservation*. 2011;18(4):21-42.
- [6]. Banihabib M E. Performance of conceptual and black-box models in flood warning systems. *Cogent engineering*. 2016;3(1):1-13.
- [7]. Kalteh AA. Enhanced Monthly Precipitation Forecasting Using Artificial Neural Network and Singular Spectrum Analysis Conjunction Models. *Indian National Academy of Engineering*. 2017;2 :73-81.
- [8]. Asadi H, Shahedi K, Jarihani B, Sidle R.C. Rainfall-Runoff Modelling Using Hydrological Connectivity Index and Artificial Neural Network Approach. *Water*. 2019;11, 212:1-20.
- [9]. Gouda KC, R L, Kumari P, Sharma M, Nair AD. An Approach for Rainfall Prediction using Soft Computing. *International Journal of Engineering Trends and Technology*. 2019;67(3):158-164.
- [10]. Dodangeh E, Panahi M, Rezaie F, Lee S, Tien Bui D, Lee CW, Pradhan B. Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search. *Journal of Hydrology*. 2020;1-14.
- [11]. Aghelpour P, Varshavian V. Evaluation of stochastic and artificial intelligence models in modeling and predicting of river daily flow time series. *Stochastic Environmental Research and Risk Assessment*. 2020;34(1):33-50.
- [12]. Stockholm Environment Institute (SEI). (2016); Water evaluation and planning system, WEAP. Stockholm Environment Institute, Boston, USA, from <http://www.weap21.org>
- [13]. Ahmadaali J, Barani GA, Qaderi K, Hessari B. Analysis of the Effects of Water Management Strategies and Climate Change on the Environmental and Agricultural Sustainability of Urmia Lake Basin, Iran. *Water*. 2018;10(160):1-21.
- [14]. Poonia V, Lal Tiwari H. Rainfall-runoff modeling for the Hoshangabad Basin of Narmada River using artificial neural network. *Arabian Journal of Geosciences*. 2020;13(944):1-10.
- [15]. Ashrafzadeh A, Kişi O, Aghelpour P, Biazar SM, Askarizad Masouleh M. Comparative Study of Time Series Models, Support Vector Machines, and GMDH in Forecasting Long-Term Evapotranspiration Rates in Northern Iran. *J. Irrig. Drain Eng*. 2020;146(6):1-10.
- [16]. Tian J, Liu J, Wang Y, Wang W, Li C, Hu C. A coupled atmospheric-hydrologic modeling system with variable grid sizes for rainfall-runoff simulation in semi-humid and semi-arid watersheds: how does the coupling scale affects the results. *Hydrol. Earth Syst. Sci*. 2020;24: 3933-3949.
- [17]. Bahrami H, Emamgholi Zadeh S. Prediction of suspended sediment distribution of Karoon River using artificial neural network. *Journal of Marine Science and Technology*. 2018;17(2):27-35. [Persian]
- [18]. Zhongda T, Shujiang L, Yanhong W, Yi S. A prediction method based on wavelet transform and multiple models fusion for chaotic time series. *Chaos. Solitons and Fractals*. 2017;98: 158-172.
- [19]. Molaie Zadeh SF, Moradi M H. Nervous chaotic fuzzy sets and systems. *Computational intelligence in electrical engineering*. 2014;5(1):41-56. [Persian]
- [20]. Zhu L, Wang Y, Fan Q. MODWT-ARMA model for time series prediction. *Applied Mathematical Modelling*. 2014;38: 1859-1865.