



مدیریت آب و آبیاری

دوره ۳ ■ شماره ۲ ■ پاییز و زمستان ۱۳۹۲

صفحه‌های ۲۸-۱۳

مطالعه اثر تغییر اقلیم بر جریان ورودی به مخزن سد طالقان با استفاده از روش ترکیب اطلاعات

بهنام آبابایی^{۱*}، فرهاد میرزایی^۲، تیمور سهرابی^۲

۱. دکتری مهندسی آبیاری و زهکشی گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی کرج، دانشگاه تهران، کرج - ایران.

۲. به‌ترتیب، استادیار و استاد گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی کرج، دانشگاه تهران، کرج - ایران.

تاریخ پذیرش مقاله: ۱۳۹۲/۰۹/۰۲

تاریخ وصول مقاله: ۱۳۹۲/۳/۱۸

چکیده

در تحقیق حاضر، کاربرد روش ترکیب اطلاعات در شبیه‌سازی فرایند هیدرولوژیک جریان ورودی به مخزن سد طالقان بررسی شد. دو الگوریتم ترکیب اطلاعات بر مبنای الگوریتم K نزدیک‌ترین همسایه (K-NN) پیشنهاد و ارزیابی شدند. چهار مدل شبکه عصبی مصنوعی و دو مدل همراشتین - واینر به‌عنوان مدل‌های شبیه‌ساز جریان روزانه ورودی به مخزن به‌کار گرفته شدند. مقایسه نتایج حاصل از روش ترکیب اطلاعات با مدل‌های منفرد، حاکی از افزایش دقت شبیه‌سازی در مقایسه با مدل‌های منفرد است. عملکرد هر دو الگوریتم ترکیب اطلاعات در شبیه‌سازی متوسط ماهانه جریان ورودی به مخزن یکسان بود، اما الگوریتم AL1 به مقادیر بزرگ‌تری از انحراف استاندارد ماهانه منجر شد. در نهایت، با استفاده از مدل مولد اقلیم، سری روزانه دما و بارش تحت سناریوهای تغییر اقلیم بازتولید شده و این سری‌ها، به‌عنوان ورودی مدل‌های منفرد و روش ترکیب اطلاعات استفاده شدند. نتایج نشان داد که پیش‌بینی مدل‌های منفرد در شرایط تغییر اقلیم ممکن است متفاوت بوده و گاه، تغییرات پیش‌بینی شده توسط آنها دارای جهات متناقضی باشند. به‌علاوه مشخص شد که عملکرد روش ترکیب اطلاعات با استفاده از الگوریتم AL2 توسط مدل همراشتین - واینر تأیید می‌شود و در مقایسه با الگوریتم AL1، به نتایج منطقی‌تری می‌انجامد. همچنین، با توجه به تناقض‌های مدل‌های منفرد، کاربرد این روش سبب افزایش ضریب اطمینان در مورد تغییرات پیش‌بینی شده جریان ورودی به مخزن در شرایط تغییر اقلیم می‌شود.

کلیدواژه‌ها: جریان روزانه، شبکه عصبی مصنوعی، عدم قطعیت، مدل همراشتین - واینر.

مقدمه

به منظور ترکیب اطلاعات، بسیار کارآمد خواهد بود (۴). همچنین، از ترکیب چند شبکه عصبی مصنوعی برای تحلیل فراوانی سیلاب استفاده شد (۱۹). نتایج این تحقیق نشان داد که ترکیب چند مدل شبکه عصبی مصنوعی به برآورد دقیق تر سیلاب منجر می شود و در ضمن، در مقایسه با مدل های منفرد نسبت به انتخاب مقادیر اولیه پارامترها از حساسیت کمتری برخوردار است. در مطالعه ای مشابه، مقایسه ای بین پنج راهبرد ترکیب اطلاعات انجام گرفت و روشی جدید برای ترکیب اطلاعات مبتنی بر مدل رگرسیون ناپارامتری نزدیک ترین همسایه (K-NN) پیشنهاد شد و نتیجه گیری شد که این روش جدید، نسبت به روش های قدیمی تر ترکیب اطلاعات، عملکرد بسیار بهتری دارد (۸).

در تحقیق حاضر، پس از تشریح سناریوهای تغییر اقلیم در محدوده بالادست سد طالقان، با استفاده از روش ترکیب اطلاعات و کاربرد مدل های آماری مختلف، تأثیرات آتی پدیده تغییر اقلیم در این محدوده بررسی خواهد شد.

مواد و روش ها

روش ترکیب اطلاعات

در شرایطی که برای پیش بینی یا شبیه سازی یک فرایند هیدرولوژیک از چند مدل منفرد استفاده می شود که همگی دارای پیش بینی کننده های^۴ مشابهند، شکل کلی مدل های مورد استفاده در روش DF چنین خواهد بود:

(۱)

$$[Y_i] = \begin{bmatrix} y_{i1} \\ y_{i2} \\ \dots \\ y_{im} \end{bmatrix} = \begin{bmatrix} f_1(X_i) \\ f_2(X_i) \\ \dots \\ f_m(X_i) \end{bmatrix} + \begin{bmatrix} \varepsilon_{i1} \\ \varepsilon_{i2} \\ \dots \\ \varepsilon_{im} \end{bmatrix} \quad i = 1, \dots, n$$

در این رابطه، m تعداد مدل های مورد استفاده برای

روش ترکیب اطلاعات (DF)^۱ در حال تبدیل شدن به روشی پرکاربرد در حوزه های مختلف علوم، از جمله نظارت دریایی، هشدارهای راهبردی و تشخیص های پزشکی است (۱۱). هدف اصلی روش ترکیب اطلاعات، که فرایند ترکیب یا امتزاج اطلاعات از حسگرها یا منابع اطلاعات مختلف را در بر می گیرد، فراهم آوردن راه حلی است که بر مبنای برخی معیارها دقیق باشد، یا این امکان را فراهم کند که استنتاج هایی فراتر از آنچه از طریق یک منبع اطلاعاتی (به تنهایی) قابل حصول است صورت پذیرد (۹). این روش، فرصت هایی را در زمینه مدلسازی فرایندهای مرتبط با منابع آب و هیدرولوژی فراهم آورده است. بر پایه مطالعات اخیر، کاربرد روش DF به جای یک مدل منفرد می تواند موجب بهبود دقت شبیه سازی یا پیش بینی فرایندهای هیدرولوژیک شود.

از روش های ترکیب مدل ها^۲ با مقاصد مختلف در هیدرولوژی مهندسی استفاده شده است. برای نمونه، روش ترکیب اطلاعات برای پیش بینی سطح آب رودخانه به کار گرفته شده است (۱۸). روش DF شامل تلفیق اطلاعات از حسگرها و منابع مختلف است. نتایج این تحقیق نشان داد استفاده از میانگین یا میانگین مقادیر خروجی مدل های مختلف، تأثیری بر بهبود پیش بینی ها ندارد. در حالی که استفاده از شبکه های عصبی مصنوعی سبب بهبود چشمگیر نتایج در مقایسه با مدل های منفرد شد. در مطالعه ای دیگر، شش راهبرد مختلف ترکیب اطلاعات برای پیش بینی جریان رودخانه در دو حوضه در شمال انگلستان و مرکز ولز آزمون شد و مشخص شد که استفاده از شبکه های عصبی مصنوعی (ANNs) و سازوکار احتمالاتی فازی^۳

1. Data Fusion
2. Model Fusion Approaches
3. Fuzzified probabilistic mechanism

$$Dis_{i,j} = \sqrt{\sum_{i=1}^p w_i (x_{it} - x_{jt})^2} \quad (2)$$

در این رابطه، w وزن هر یک از پیش‌بینی‌کننده‌ها در محاسبه فاصله پیش‌بینی‌کننده‌های فعلی و همسایه‌های آن است.

مقدار شبیه‌سازی شده یا پیش‌بینی شده متغیر وابسته در زمان t با استفاده از میانگین‌گیری وزنی بین متغیرهای وابسته نزدیک‌ترین همسایه‌ها محاسبه می‌شود، به نحوی که بیشترین وزن به نزدیک‌ترین همسایه اختصاص می‌یابد. معمولاً یک تابع کرنل به منظور تعیین وزن همسایه‌ها به کار می‌رود و در نهایت مقدار متغیر وابسته در زمان t از رابطه ۳ برآورد می‌شود (۱۳):

$$y_t = \frac{\sum_{i=1}^K (1/i) y_i}{\sum_{i=1}^K (1/i)} \quad (3)$$

در این رابطه، i رتبه همسایه‌ها را نشان می‌دهد و نزدیک‌ترین همسایه دارای کمترین رتبه است ($i = 1, \dots, K$) و y_i مقدار متغیر وابسته مربوط به همسایه i را نشان می‌دهد. مقادیر وزن‌ها و تعداد همسایه‌ها باید به نحوی تعیین شوند که متوسط مربع خطاها در شبیه‌سازی یا پیش‌بینی به حداقل برسد.

در این تحقیق و براساس الگوریتم مبتنی بر استفاده از رگرسیون ناپارامتری، دو الگوریتم جداگانه برای استفاده در روش ترکیب اطلاعات پیشنهاد می‌شوند. الگوریتم اول (AL1) به این شرح است:

۱. با استفاده از m مدل مورد نظر، مقدار متغیر وابسته برای تمامی N بردار پیش‌بینی‌کننده مورد نظر شبیه‌سازی می‌شود (N : طول کل دوره آماری)؛
۲. هر یک از مدل‌های مورد استفاده در بند یک برای تمامی n بردار تاریخی که برای واسنجی در نظر گرفته شده‌اند، ارزیابی می‌شوند و مقدار خطای هر مدل

شبیه‌سازی متغیر وابسته y ، تابع تبدیل بردار پیش‌بینی‌کننده‌ها به مقادیر متغیر وابسته، X بردار پیش‌بینی‌کننده‌ها، Y ماتریس برآورد مقادیر y حاصل از مدل‌های مختلف، ε خطای مدل‌ها و n تعداد داده‌های مشاهداتی است.

با استفاده از روش DF، ماتریس Y در نهایت به یک متغیر واحد y تبدیل می‌شود. برخی روش‌های مرسوم ترکیب اطلاعات عبارتند از میانگین ساده و میانگین وزنی تشخیص کارشناسی، استفاده از مدل‌های تجربی مانند شبکه‌های عصبی مصنوعی و روش تحلیل خطاها (۱۸)، (۱۹). روشی مبتنی بر استفاده از رگرسیون ناپارامتری نیز معرفی شده است که در اینجا شرح داده می‌شود (۸).

ترکیب اطلاعات با استفاده از روش نزدیک‌ترین همسایه

تخمین ناپارامتری توابع احتمال و توابع رگرسیون با استفاده از میانگین وزنی متغیرهای وابسته محلی انجام می‌پذیرد (۸). این روش، اساس روش‌های نزدیک‌ترین همسایه (K-NN)^۱ است. روش‌های نزدیک‌ترین همسایه از شباهت (همسایگی) مقادیر پیش‌بینی‌کننده‌های مشاهداتی و مقادیر مشاهداتی تاریخی به منظور دستیابی به بهترین تخمین از متغیر وابسته استفاده می‌کنند. در ابتدا، تعداد K بردار مشاهداتی که دارای حداقل فاصله در میان تمامی بردارهای مشاهداتی هستند، انتخاب می‌شوند. فاصله بین بردار پیش‌بینی‌کننده‌های فعلی (در زمان t) و بردارهای پیش‌بینی‌کننده مشاهداتی تاریخی با استفاده از توابع فاصله اقلیدسی یا ماهالونویس محاسبه می‌شود (۱۲، ۲۰). برای پیش‌بینی‌کننده‌هایی با P بعد، فاصله اقلیدسی به شرح زیر محاسبه می‌شود:

1. K-Nearest Neighbours

توسعه مدل‌های شبیه‌سازی

در این تحقیق، چهار مدل شبکه عصبی مصنوعی رگرسیون تعمیم‌یافته با ورودی‌های استاندارد شده (GRNN2)، شعاعی با ورودی‌های استاندارد شده (RB2)، پیشخور با یک لایه (FeedF1) و دو لایه (FeedF2) مخفی به همراه دو مدل همراشتین - واینر با ورودی‌های استاندارد شده (HM1) و ورودی‌های غیراستاندارد (HM2) به عنوان مدل‌های منفرد برای شبیه‌سازی متغیر وابسته (شدت جریان روزانه ورودی به مخزن) استفاده شدند. این چهار مدل براساس نتایج مقایسه‌ای جامع برای شبیه‌سازی جریان روزانه ورودی به مخزن سد طالقان انتخاب شده‌اند. تشریح ساختار و چگونگی انتخاب بهترین معماری برای این مدل‌ها خارج از دامنه اهداف این مقاله است. شرح مفصل در مورد این فرایند و تشریح ساختار مدل‌ها، در مراجع دیگر در دسترس است (۱، ۱۴). به منظور ارزیابی مدل‌های منفرد و روش DF، از شاخص‌های ضریب تعیین (R^2) و دو شاخص استاندارد شده ریشه میانگین مربع خطاها (SRMSE)^۲ و میانگین خطاهای مطلق (SMAE)^۳ بین سری مشاهداتی و سری‌های تولید شده استفاده شد که از رابطه‌های ۵ تا ۷ محاسبه می‌شوند.

در این رابطه‌ها، O و P به ترتیب مقادیر مشاهداتی و تولید شده، \bar{O} و \bar{P} میانگین مقادیر مشاهداتی و تولید شده و n تعداد داده در هر یک از سری‌هاست.

$$R^2 = \left(1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}\right) \times 100 \quad (5)$$

$$SRMSE = \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right]^{0.5} \times \frac{100}{\bar{O}} \quad (6)$$

محاسبه می‌شود (n: طول دوره واسنجی یا دوره تاریخی)؛

۳. از رابطه ۲ فاصله بین بردار پیش‌بینی‌کننده‌ها در زمان حال، $[X_t]$ ، و هر یک از پیش‌بینی‌کننده‌های تاریخی، $[X_i]$ ، محاسبه شده و K نزدیک‌ترین همسایه‌ها از بین n بردار تاریخی به نحوی تعیین می‌شود که کمترین فاصله به نزدیک‌ترین همسایه اختصاص یابد؛

۴. ماتریس $[Y]$ به شرح رابطه ۴ تشکیل می‌شود. در این رابطه، Y_{ti} نشان‌دهنده مقدار متغیر وابسته در زمان t حاصل از مدلی است که در همسایه i ام به عنوان بهترین مدل انتخاب شده است.

$$[Y] = \begin{bmatrix} Y_{t1} \\ Y_{t2} \\ \dots \\ Y_{tK} \end{bmatrix} \quad (4)$$

۵. مقدار متغیر وابسته از رابطه ۳ محاسبه می‌شود.

در این الگوریتم، در ابتدا همه مدل‌های مورد استفاده در دوره تاریخی (یا واسنجی) ارزیابی شده و بهترین مدل برای هر یک از گام‌های زمانی انتخاب می‌شود. نتایج بهترین مدل انتخاب شده در این گام در گام‌های بعدی برای محاسبه متغیر وابسته در زمان t به کار می‌رود. شکل تغییر یافته‌ای از این الگوریتم نیز ارزیابی شد. در این الگوریتم (AL2)، به جای انتخاب بهترین مدل در هر یک از گام‌های زمانی در دوره تاریخی (یا واسنجی)، نتایج حاصل از همه مدل‌ها استفاده می‌شوند. به این ترتیب که در هر گام زمانی در دوره تاریخی، براساس خطای حاصل از هر یک از m مدل مورد نظر، وزنی به مدل‌ها اختصاص می‌یابد و مقدار Y_{ti} به صورت متوسط وزنی نتایج حاصل از همه مدل‌ها محاسبه می‌شود. به این ترتیب، تنها تفاوت الگوریتم AL1 و AL2 در گام چهارم است.

1. Coefficient of Determination
2. Standardized Root Mean Square Error
3. Standardized Mean Absolute Error

استاندارد بین‌سالی متغیرهای هواشناسی برای بازتولید اطلاعات روزانه استفاده کند، تشریح سناریوهای تغییر اقلیم نیز براساس تغییرات مورد انتظار میانگین و انحراف استاندارد بین‌سالی متغیرها صورت گرفته است.

تشریح سناریوهای تغییر اقلیم

به‌منظور تشریح سناریوهای تغییر اقلیم (سناریوهای انتشار^۲)، اطلاعات ماهانه مدل‌های گردش عمومی^۳ (GCM) (میانگین‌های ماهانه) از بانک اطلاعات PCMDI^۴ و برای همه سناریوهای شبیه‌سازی شده و از جمله پنج سناریوی 20c3m (سناریوی قرن بیستم به‌عنوان سناریوی مبنا)، (CM, Commit, A1B, A2, B1 استخراج شد (۱۵). میانگین و انحراف استاندارد میانگین‌های ماهانه در هر یک از سناریوها و برای هر یک از دوره‌های مورد نظر محاسبه شد. این دوره، برای سناریوی مبنا شامل سال‌های ۱۹۸۰ تا ۱۹۹۹ میلادی و برای سایر سناریوها، شامل سال‌های ۲۰۴۰ تا ۲۰۶۹ میلادی است. در این تحقیق، دو نوع تغییر بررسی شد: ۱. تغییر در میانگین میانگین‌های ماهانه؛ ۲. تغییر در انحراف استاندارد میانگین‌های ماهانه (انحراف استاندارد بین‌سالی). تغییرات^۵ هر یک از این شاخص‌ها در سناریوهای تغییر اقلیم نسبت به سناریوی مبنا (سناریوی قرن بیستم) محاسبه شد. برای محاسبه تغییر در میانگین میانگین‌های ماهانه متغیر دما از تغییرات مطلق (رابطه ۸) و برای سایر متغیرها (بارندگی، رطوبت نسبی، باد و تابش خورشیدی)، از تغییرات نسبی (رابطه ۹) استفاده شد. برای محاسبه تغییر در انحراف استاندارد میانگین‌های ماهانه کلیه متغیرها نسبت به دوره مبنا نیز از رابطه ۹ استفاده شد:

$$SMAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \times \frac{100}{O} \quad (7)$$

کاربرد روش ترکیب اطلاعات

هر یک از مدل‌های شبیه‌ساز برای کل دوره آماری اجرا شدند. سپس، این دوره به دو دوره واسنجی و آزمون تقسیم شد (۸۰ + ۲۰ درصد). داده‌های دما و بارش روزانه به‌عنوان پیش‌بینی‌کننده استفاده شدند. از آنجاکه همه مدل‌های شبیه‌ساز مورد نظر از اطلاعات دما و بارش یک تا سه روز قبل نیز به‌عنوان بخشی از بردار پیش‌بینی‌کننده استفاده می‌کنند، ارزیابی دو الگوریتم مورد نظر در روش DF (AL1 و AL2) با استفاده از پیش‌بینی‌کننده‌های حاصل از ترکیب پیش‌بینی‌کننده‌های زمان حال و پیش‌بینی‌کننده‌های یک و دو گام زمانی قبلی (Lag) انجام پذیرفت. مقدار K نیز براساس ارزیابی‌های اولیه به روش سعی و خطا، بین پنج تا ۳۰ انتخاب شد. به‌منظور ارزیابی عملکرد روش‌های مذکور در ترکیب با یک مدل مولد اقلیم^۱ (WG)، ابتدا با استفاده از مدل WG که قبلاً در محدوده مطالعاتی ارزیابی شده است، ۱۰۰ سال داده روزانه دما و بارش بازتولید شد (تحت سناریوی مبنا) (۱). مدل مذکور قادر است علاوه بر بازتولید ویژگی‌های آماری سری متغیرهای هواشناسی در هر یک از ایستگاه‌های هواشناسی در محدوده مطالعاتی، همبستگی مکانی ایستگاه‌های مجاور را نیز به‌خوبی شبیه‌سازی کند. سپس، با استفاده از این داده‌ها، مدل‌های شبیه‌ساز به‌طور منفرد و در قالب روش DF اجرا شدند و ویژگی‌های آماری سری حاصل از این روش‌ها با سری تاریخی شدت جریان روزانه ورودی به مخزن مقایسه شد. از آنجاکه مدل WG مورد استفاده می‌تواند از مقادیر میانگین و انحراف

2. IPCC Emission Scenarios (SRES)

3. General Circulation Model

4. Program for Climate Model Diagnosis and Intercomparison

5. Anomalies

1. Weather Generator

$$W_j = \frac{\frac{1}{(s + H_{ij})^p}}{\sum_{j=1}^K \frac{1}{(s + H_{ij})^p}} \quad j = 1, \dots, n \quad j = 1, \dots, K \quad (10)$$

در این رابطه، W_j وزن نقطه j ، H_{ij} فاصله نقطه j از نقطه i (نقطه هدف)، s یک مقدار بسیار کوچک (در اینجا 10^{-10}) برای جلوگیری از تقسیم شدن بر صفر و P نمای وزن‌دهی است و مقدار آن معمولاً بین یک تا پنج انتخاب می‌شود (۲، ۳). هرچه مقدار P بیشتر باشد، تأثیر نقاط دورتر بر مقدار تخمینی برای نقطه هدف کمتر می‌شود. در نهایت، مقدار متغیر مورد نظر در نقطه هدف از میانگین وزنی نقاط مجاور محاسبه می‌شود. به‌منظور تعیین مقدار بهینه K و P ، از یک الگوریتم تکراری استفاده شد. این الگوریتم، از روش صحت‌سنجی متقاطع^۳ استفاده می‌کند. این کار، برای هر یک از ماه‌های سال به‌طور جداگانه انجام گرفت. پس از تعیین مقادیر بهینه K و P در روش میان‌یابی IDW ، تغییرات میانگین و انحراف استاندارد میانگین‌های ماهانه برای هر یک از ایستگاه‌های مورد مطالعه باتوجه به مختصات این ایستگاه‌ها محاسبه شد. این تغییرات عبارت بودند از تغییرات در میانگین و انحراف استاندارد میانگین‌های ماهانه متغیرهای حداقل و حداکثر دما، متوسط دما و بارندگی. سناریوهای تغییر اقلیم به پنج دسته تقسیم شدند. دسته اول شامل همه سناریوهای تغییر اقلیم است (All). دسته‌های دوم تا پنجم هر کدام تنها یک سناریوی تغییر اقلیم را شامل می‌شود (CM، A1B، A2، و B1). در هر دسته، مقدار تغییرات براساس احتمال تجمعی (صدک) ۲۵، ۵۰ و ۷۵ درصد محاسبه شد. از آنجاکه برخی متغیرها توسط بعضی از مدل‌های GCM شبیه‌سازی نشده‌اند یا برخی مدل‌های GCM بیش از یک بار اجرا شده‌اند، مجموع سناریوهای تغییر اقلیم برای متغیرهای مختلف

$$\Delta T = T_{GCM,S} - T_{GCM,B} \quad (8)$$

$$\Delta V = V_{GCM,S} / V_{GCM,B} \quad (9)$$

در این رابطه‌ها، T میانگین متغیرهای دما (حداقل، حداکثر و متوسط دما) و V میانگین دیگر متغیرها (غیر از دما) یا انحراف استاندارد کلیه متغیرها را نشان می‌دهد.

زیرنویس S نشان‌دهنده سناریوی تغییر اقلیم شبیه‌سازی‌شده توسط مدل GCM و زیرنویس B نشان‌دهنده سناریوی قرن بیستم (مبنا) شبیه‌سازی‌شده به‌وسیله همان مدل GCM است. این روش، مشابه روش عامل تغییر^۱ است (۵، ۶، ۱۰، ۱۶، ۱۷). در روش عامل تغییر، ابتدا دوره مبنا برای منطقه یا ایستگاه مورد نظر تعیین می‌شود. سپس، تغییر متغیر مورد نظر در نزدیک‌ترین گره مدل GCM به ایستگاه یا منطقه مورد نظر محاسبه می‌شود. در نهایت، این مقدار به مقادیر روزانه دوره مبنا اضافه می‌شود. تفاوت روش به‌کاررفته در این مطالعه با روش عامل تغییر در این است که در روش فعلی، علاوه بر تغییر میانگین، تغییرات انحراف استاندارد میانگین‌های ماهانه نیز بررسی می‌شود.

به‌منظور برطرف ساختن ناپیوستگی اطلاعات ایستگاه‌های مجاور، از روش وزن‌دهی عکس فاصله (IDW)^۲ استفاده شد. در این روش، پس از محاسبه تغییرات هر متغیر در هریک از سناریوها نسبت به سناریوی مبنا، فاصله اقلیدسی همه نقاط نسبت به نقطه هدف محاسبه شده و این نقاط، برحسب فاصله مرتب می‌شوند (از کم به زیاد). سپس، K نقطه که در کمترین فاصله نسبت به نقطه هدف قرار گرفته‌اند، برای محاسبه مقدار متغیر مورد نظر در این نقطه استفاده می‌شوند. وزن هر یک از نقاط مجاور در محاسبه مقدار متغیر در نقطه هدف از رابطه ۱۰ محاسبه می‌شود:

3. Cross-Validation
4. Run

1. Change Factor
2. Inverse distance weighting

مدل‌های HW1 و HW2 در مراحل واسنجی و اعتبارسنجی، در زمان تلفیق این مدل‌ها با مدل WG، خطای هر دو مدل به شکل چشمگیری افزایش پیدا می‌کند. عمده این خطا مربوط به ماه‌های مرطوب سال است و هر دو مدل (به‌ویژه مدل HW1) حداکثر شدت جریان را در این ماه‌ها بیشتر از مقادیر واقعی برآورد می‌کنند. خطای مدل RB2 نیز (به‌ویژه در ماه آگوست) چشمگیر است و گاهی به ارقام بسیار بزرگ و نامعقول منجر می‌شود. بهترین عملکرد در شبیه‌سازی متوسط روزانه جریان مربوط به مدل FeedF1 و ضعیف‌ترین عملکرد مربوط به مدل HW1 است. از نظر شبیه‌سازی انحراف استاندارد روزانه جریان، بهترین عملکرد مربوط به مدل HW2 بوده است، هرچند که عملکرد هیچ یک از مدل‌ها در سطح قابل قبول ارزیابی نمی‌شود.

روش DF به شکلی معنادار موجب بهبود نتایج حاصل از مدل‌های منفرد شده است (جدول‌های ۴ و ۵). بهترین عملکرد مربوط به الگوریتم AL1، مقدار K پنج و تعداد تأخیر زمانی دو است. مقدار شاخص SRMSE این مدل در برآورد میانگین روزانه شدت جریان شش و در برآورد انحراف استاندارد روزانه شدت جریان ۲۱ درصد است. الگوریتم AL2 از نظر شبیه‌سازی دقیق متوسط شدت جریان، هم‌ارز الگوریتم AL1 است. اما در شبیه‌سازی انحراف استاندارد روزانه جریان عملکرد مناسبی نداشته است. در این الگوریتم، از متوسط وزنی نتایج مدل‌های مختلف استفاده می‌شود و این متوسط‌گیری، موجب کاهش واریانس متغیر وابسته (شدت جریان) می‌شود. دلیل مهم دیگر می‌تواند طول کوتاه دوره آماری موجود برای ایستگاه بالادست مخزن باشد. کوتاه بودن دوره آماری و وقوع جریان‌ات سیلابی در ماه‌های مرطوب این دوره سبب شده واریانس جریان افزایش پیدا کند. از این‌رو می‌توان بخشی از خطای مشاهده‌شده در شبیه‌سازی انحراف استاندارد ماهانه جریان ورودی به مخزن را به این مسئله مرتبط دانست.

متفاوت است. چون در ایستگاه طالقان تنها متغیرهای بارندگی و متوسط دما اندازه‌گیری می‌شوند، سناریوهای تغییر اقلیم در این ایستگاه به این دو متغیر محدود شدند.

نتایج و بحث

ارزیابی روش ترکیب اطلاعات

نتایج شبیه‌سازی دوره اعتبارسنجی توسط هر یک از مدل‌های شبیه‌ساز در کنار نتایج حاصل از روش‌های ترکیب اطلاعات در جدول‌های ۱ و ۲ ارائه شده‌اند که بر این اساس تفاوت چشمگیری بین دو الگوریتم DF دیده نمی‌شود. هرچند که عملکرد الگوریتم AL2 به مقدار ناچیزی بهتر از الگوریتم AL1 بوده است. کمترین مقدار شاخص SRMSE در مورد الگوریتم AL1 برابر با مقدار $K = 20$ و زمان تأخیر یک است. درحالی‌که برای الگوریتم AL2، کمترین مقدار شاخص SRMSE مربوط به زمانی است که مقدار K برابر با ۱۰ انتخاب شده باشد. در مورد الگوریتم AL2، افزایش مقدار K تا حدود ۱۰، موجب کاهش جزئی خطای روش DF می‌شود، اما افزایش بیشتر این پارامتر، خطای این روش را افزایش می‌دهد.

جدول ۱. نتایج شبیه‌سازی مدل‌های منفرد در دوره آزمون

(n = ۳۷۲)

ورودی‌ها	نام مدل	R2 %	SRMSE %	SMAE %
PT	HW1	۹۵	۳۷	۲۲
PT	HW2	۹۴	۴۳	۲۴
PPT	FeedF1	۹۲	۵۰	۳۰
PPT	FeedF2	۹۳	۵۰	۳۲
PPT	RB2	۹۴	۴۶	۳۰
PPPTT	GRNN2	۹۳	۵۰	۳۰

جدول ۳ خطای مدل‌های مختلف در تلفیق با مدل WG در شبیه‌سازی میانگین ماهانه شدت جریان روزانه ورودی به مخزن را نشان می‌دهد. علی‌رغم دقت زیاد

جدول ۲. نتایج شبیه‌سازی روش DF در دورهٔ آزمون (n = ۳۷۲)

الگوریتم	Lag	K	R2 %	SRMSE %	SMAE %	الگوریتم	Lag	K	R2 %	SRMSE %	SMAE %		
AL1	۱	۵	۹۵	۴۰	۲۵	AL2	۱	۵	۹۴	۴۳	۲۵		
		۱۰	۹۵	۴۰	۲۴			۱۰	۹۵	۴۳	۲۴		
		۲۰	۹۵	۴۲	۲۴			۲۰	۹۵	۴۲	۲۴		
	۲	۳۰	۹۴	۴۶	۲۶		۲	۳۰	۹۵	۴۲	۲۴	۴۲	۲۴
		۵	۹۵	۴۲	۲۶			۵	۹۴	۴۵	۲۶	۴۵	۲۶
		۱۰	۹۵	۴۱	۲۵			۱۰	۹۴	۴۴	۲۶	۴۴	۲۶
	۳	۲۰	۹۴	۴۵	۲۶		۳	۲۰	۹۴	۴۴	۲۶	۴۴	۲۶
		۳۰	۹۲	۵۰	۲۸			۳۰	۹۴	۴۴	۲۶	۴۴	۲۶

جدول ۳. ارزیابی مدل‌های منفرد در تلفیق با مدل مولد اقلیم

انحراف استاندارد ماهانه			میانگین ماهانه			نام مدل	ورودی‌ها
SMAE %	SRMSE %	R2 %	SMAE %	SRMSE %	R2 %		
۱۳۹	۲۱۳	۹۹	۴۰	۶۴	۹۹	HW1	PT
۳۴	۴۳	۹۵	۳۴	۴۶	۹۹	HW2	PT
۵۹	۸۴	۹۹	۴	۶	۹۹	FeedF1	PPT
۵۹	۸۳	۹۹	۱۱	۱۶	۹۹	FeedF2	PPT
۲۹۰	۸۰۶	۱۸	۱۵	۲۲	۹۹	RB2	PPT
۵۳	۷۸	۹۹	۶	۸	۹۹	GRNN2	PPPTT

جدول ۴. ویژگی‌های آماری جریان روزانهٔ ورودی به مخزن حاصل از تلفیق روش DF با مدل مولد اقلیم


الگوریتم	Lag	K	میانگین m ³ /s	انحراف استاندارد m ³ /s	حداکثر m ³ /s	الگوریتم	Lag	K	میانگین m ³ /s	انحراف استاندارد m ³ /s	حداکثر m ³ /s			
مشاهداتی	-	-	۱۳/۸۳	۱۷/۰۴	۱۰۹/۵۴	مشاهداتی	-	-	۱۳/۸۳	۱۷/۰۴	۱۰۹/۵۴			
AL1	۱	۵	۱۴/۰۶	۱۵/۲۶	۱۴۴/۲۹	AL2	۱	۵	۱۳/۰۱	۱۶/۱۹	۱۸۵/۲۷			
		۱۰	۱۴/۰۱	۱۵/۹۳	۱۴۱/۷۵			۱۰	۱۲/۵۹	۱۵/۹۴	۱۸۰/۱۴			
		۲۰	۱۳/۹۲	۱۵/۱۰	۱۴۱/۱۲			۲۰	۱۲/۴۷	۱۵/۸۵	۱۷۸/۲۷			
	۲	۳۰	۱۳/۸۴	۱۵/۰۱	۱۴۰/۷۱		۲	۳۰	۱۲/۴۶	۱۵/۸۳	۱۷۷/۵۵	۳۰	۱۲/۴۶	۱۵/۸۳
		۵	۱۴/۱۵	۱۵/۳۵	۱۴۳/۸۰			۵	۱۲/۹۷	۱۶/۱۷	۱۸۴/۶۱			
		۱۰	۱۴/۰۷	۱۵/۲۵	۱۴۲/۴۱			۱۰	۱۲/۵۹	۱۵/۹۵	۱۸۰/۴۹			
	۳	۲۰	۱۳/۹۸	۱۵/۱۵	۱۴۱/۲۴		۳	۲۰	۱۲/۴۹	۱۵/۸۸	۱۷۷/۸۷	۲۰	۱۲/۴۹	۱۵/۸۸
		۳۰	۱۳/۹۱	۱۵/۰۶	۱۴۰/۷۸			۳۰	۱۲/۴۸	۱۵/۸۷	۱۷۷/۱۴			

ترکیب اطلاعات را در شبیه‌سازی متوسط و انحراف استاندارد ماهانه شدت جریان ورودی به مخزن با استفاده از الگوریتم AL2 نمایش می‌دهند. این الگوریتم در اکثر ماه‌های سال، در مقایسه با مقادیر مشاهداتی، به برآورد دست‌بالا منجر شده و خطای این الگوریتم در ماه‌های مرطوب سال بیشتر است. در مورد شبیه‌سازی انحراف استاندارد ماهانه جریان، در همه ماه‌های سال این الگوریتم به مقادیر کوچک‌تر از مقادیر مشاهداتی منجر شده و در ماه‌های مرطوب (آوریل و می)، خطای این الگوریتم چشمگیر است. کمترین خطای الگوریتم AL2 مربوط به مقدار K ۲۰ یا ۳۰ و تعداد تأخیر زمانی یک است.


شکل ۱ و ۲، به ترتیب خطای روش‌های مختلف DF در شبیه‌سازی متوسط و انحراف استاندارد ماهانه شدت جریان ورودی به مخزن با استفاده از الگوریتم AL1 را نمایش می‌دهند. روش ترکیب اطلاعات با استفاده از الگوریتم AL1 در تمامی ماه‌ها به برآورد دست‌پایین متوسط ماهانه شدت جریان منجر شده است. این خطا با ورود به ماه‌های مرطوب سال افزایش می‌یابد. در مورد شبیه‌سازی انحراف استاندارد ماهانه جریان، مهم‌ترین مسئله، برآورد دست‌پایین این مقادیر در ماه‌های مرطوب سال، به‌ویژه ماه‌های آوریل و می است. شکل ۳ و ۴ به ترتیب خطای روش‌های مختلف

جدول ۵. ارزیابی روش DF در تلفیق با مدل مولد اقلیم


انحراف استاندارد ماهانه					میانگین ماهانه					الگوریتم
SMAE %	SRMSE %	R2 %	K	Lag	SMAE %	SRMSE %	R2 %	K	Lag	
۱۹	۲۳	۹۸	۵		۴	۶	۱۰۰	۵		AL1
۱۸	۲۲	۹۸	۱۰	۱	۷	۱۰	۱۰۰	۱۰	۱	
۱۸	۲۲	۹۸	۲۰		۸	۱۱	۱۰۰	۲۰		
۱۸	۲۲	۹۸	۳۰		۸	۱۱	۱۰۰	۳۰		
۱۸	۲۱	۹۸	۵		۴	۶	۱۰۰	۵		
۱۷	۲۱	۹۸	۱۰	۲	۷	۱۰	۱۰۰	۱۰	۲	
۱۷	۲۱	۹۸	۲۰		۸	۱۱	۱۰۰	۲۰		AL2
۱۷	۲۱	۹۸	۳۰		۸	۱۱	۱۰۰	۳۰		
۴۵	۶۷	۹۸	۵		۵	۸	۱۰۰	۵		
۴۶	۶۸	۹۸	۱۰	۱	۵	۷	۱۰۰	۱۰	۱	
۴۶	۶۸	۹۸	۲۰		۴	۶	۱۰۰	۲۰		
۴۶	۶۸	۹۸	۳۰		۴	۵	۱۰۰	۳۰		
۴۵	۶۷	۹۸	۵		۶	۸	۱۰۰	۵		
۴۶	۶۸	۹۸	۱۰	۲	۵	۸	۱۰۰	۱۰	۲	
۴۶	۶۸	۹۸	۲۰		۵	۷	۱۰۰	۲۰		
۴۶	۶۸	۹۸	۳۰		۴	۶	۱۰۰	۳۰		



شکل ۱. خطای روش DF در برآورد میانگین ماهانه جریان با استفاده از الگوریتم AL1 (راست: Lag=1, چپ: Lag=2)



شکل ۲. خطای روش DF در برآورد انحراف استاندارد ماهانه جریان با استفاده از الگوریتم AL1 (راست: Lag = 1 و چپ: Lag = 2)



شکل ۳. خطای روش DF در برآورد میانگین ماهانه جریان با استفاده از الگوریتم AL2 (راست: Lag = 1 و چپ: Lag = 2)

این تغییرات تعیین شدند.


نتایج نشان می‌دهد که در مورد میانگین میانگین‌های ماهانه (با احتمال ۵۰ درصد)، حداقل و حداکثر دما در کلیه ماه‌های سال افزایش حداقل یک درجه‌ای را تجربه خواهند کرد (جدول ۶). برعکس، غیر از دو ماه ابتدای سال میلادی، در بقیه ماه‌های سال شاهد کاهش میانگین متغیر رطوبت نسبی خواهیم بود. همچنین، کاهش میانگین متغیر سرعت باد نیز در بیشتر ماه‌های سال مورد انتظار است. تابش خورشیدی تغییرات بسیار جزئی را تجربه خواهد کرد. درحالی‌که میانگین بارش به‌طور متوسط ۲ و حداکثر ۱۵ درصد (در ماه ژوئن) کاهش خواهد یافت.

سناریوهای تغییر اقلیم

در این تحقیق، ابتدا سناریوهای تغییر اقلیم (Commit, A1B, A2 و B1) در هر سلول از مدل‌های GCM برای دوره ۲۰۶۹-۲۰۴۰ نسبت به دوره مبنا (دوره ۱۹۹۹-۱۹۸۰ در سناریوی قرن بیستم، 20c3m) محاسبه شدند. سپس، با استفاده از یک الگوریتم تکراری، مقادیر بهینه پارامترهای روش IDW برای میان‌یابی سناریوهای تغییر میانگین و انحراف استاندارد ماهانه همه متغیرها برای همه ماه‌های سال و کلیه سناریوها تعیین شد. در مرحله بعد، سناریوهای تغییر اقلیم و مقادیر تغییرات هر متغیر تحت احتمال ۵۰ درصد به‌عنوان مقادیر شاخص هر سناریو و مقادیر تغییرات تحت احتمالات ۲۵ و ۷۵ درصد به‌عنوان دامنه عدم قطعیت

مدیریت آب و آبیاری

مطالعه اثر تغییر اقلیم بر جریان ورودی به مخزن سد طالقان با استفاده از روش ترکیب اطلاعات



شکل ۴. خطای روش DF در برآورد انحراف استاندارد ماهانه جریان با استفاده از الگوریتم AL2 (راست: Lag = 1 و چپ: Lag = 2)

جدول ۶. سناریوهای تغییر میانگین در ایستگاه سد طالقان با احتمال ۵۰ درصد

سناریو	ماه	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
All	متوسط دما	۱/۲۳	۱/۳۱	۱/۵۳	۱/۷۰	۲/۰۴	۲/۱۷	۲/۲۸	۲/۴۲	۲/۲۰	۱/۹۱	۱/۷۲	۱/۲۴
	بارندگی	۱/۰۵	۱/۰۳	۰/۹۴	۰/۹۳	۰/۸۸	۰/۸۴	۰/۹۱	۰/۹۱	۰/۹۱	۱/۰۷	۰/۹۹	۱/۱۱
Commit	متوسط دما	۰/۲۶	۰/۴۳	۰/۳۷	۰/۲۵	۰/۷۰	۰/۶۷	۰/۷۱	۰/۷۳	۰/۷۴	۰/۵۶	۰/۴۷	۰/۱۲
	بارندگی	۱/۱۰	۱/۰۴	۰/۹۸	۱/۰۴	۰/۹۴	۱/۰۵	۱/۱۴	۰/۹۱	۱/۱۶	۱/۰۷	۱/۰۰	۱/۰۹
A1B	متوسط دما	۱/۵۴	۱/۷۳	۲/۰۴	۲/۳۰	۲/۶۲	۲/۶۵	۲/۸۹	۲/۸۸	۲/۵۴	۲/۳۷	۲/۱۵	۱/۶۰
	بارندگی	۱/۰۶	۱/۰۰	۰/۹۳	۰/۸۷	۰/۷۸	۰/۷۶	۰/۷۸	۰/۸۹	۰/۹۴	۰/۹۵	۱/۰۰	۱/۱۲
A2	متوسط دما	۱/۴۹	۱/۶۵	۱/۸۰	۲/۱۱	۲/۳۵	۲/۵۶	۲/۸۴	۲/۸۱	۲/۵۶	۲/۳۰	۲/۱۰	۱/۶۸
	بارندگی	۱/۰۵	۱/۰۶	۰/۹۱	۰/۹۰	۰/۹۳	۰/۷۹	۰/۹۴	۰/۹۷	۱/۰۹	۱/۰۷	۱/۰۶	۱/۱۴
B1	متوسط دما	۱/۱۰	۱/۲۳	۱/۳۸	۱/۵۳	۱/۸۱	۲/۱۳	۲/۰۴	۲/۱۱	۲/۰۲	۱/۸۰	۱/۵۰	۱/۰۹
	بارندگی	۱/۰۵	۱/۰۳	۰/۹۵	۰/۹۵	۰/۹۲	۰/۸۹	۰/۸۹	۰/۹۳	۱/۲۷	۰/۹۸	۱/۰۳	۱/۱۱

جدول ۷. سناریوهای تغییر انحراف استاندارد در ایستگاه سد طالقان با احتمال ۵۰ درصد

سناریو	ماه	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
All	متوسط دما	۱/۰۲	۱/۰۶	۱/۰۲	۱/۰۴	۱/۰۵	۱/۰۳	۱/۰۰	۱/۰۳	۱/۰۴	۱/۰۷	۱/۰۷	۱/۰۸
	بارندگی	۱/۰۷	۱/۰۶	۰/۹۷	۱/۰۰	۰/۹۵	۱/۰۰	۱/۰۴	۱/۰۰	۱/۲۰	۱/۱۲	۱/۰۸	۱/۱۸
Commit	متوسط دما	۱/۰۶	۱/۰۸	۰/۹۷	۰/۹۸	۱/۰۲	۱/۰۰	۱/۰۴	۰/۹۹	۱/۰۱	۱/۰۳	۱/۰۹	۱/۰۹
	بارندگی	۱/۰۹	۱/۰۱	۰/۹۷	۱/۰۲	۰/۹۵	۱/۱۰	۱/۱۷	۱/۱۴	۱/۲۰	۱/۱۷	۱/۰۳	۱/۱۳
A1B	متوسط دما	۱/۰۴	۱/۰۷	۱/۰۲	۱/۰۷	۱/۱۰	۱/۰۴	۱/۰۲	۱/۰۶	۱/۰۴	۱/۱۰	۱/۰۷	۱/۰۸
	بارندگی	۱/۰۵	۱/۰۷	۰/۹۷	۰/۹۸	۰/۹۳	۰/۹۷	۰/۹۴	۰/۹۰	۱/۱۰	۱/۰۵	۱/۱۴	۱/۱۵
A2	متوسط دما	۱/۰۳	۱/۰۴	۱/۰۳	۱/۰۵	۱/۰۷	۱/۰۳	۰/۹۹	۱/۱۴	۱/۰۷	۱/۱۷	۱/۱۰	۱/۱۰
	بارندگی	۱/۱۱	۱/۰۹	۰/۹۷	۱/۰۰	۱/۰۳	۰/۸۸	۱/۰۹	۱/۴۲	۱/۲۰	۱/۱۵	۱/۱۰	۱/۲۸
B1	متوسط دما	۰/۹۸	۱/۰۱	۱/۰۴	۱/۰۲	۰/۹۹	۱/۰۴	۰/۹۹	۰/۹۸	۱/۰۶	۱/۰۴	۱/۰۳	۱/۰۸
	بارندگی	۱/۰۶	۱/۰۷	۱/۰۴	۱/۰۳	۰/۹۴	۱/۰۷	۱/۱۰	۰/۹۹	۱/۳۰	۱/۱۲	۱/۰۹	۱/۱۸

منطقی منجر نشده است، به نحوی که میانگین روزانه شدت جریان ورودی به مخزن را بیش از چهاربرابر متوسط دوره مبنای برآورد کرده است. برخلاف این مدل، مدل HW2 که از ورودی‌های غیراستاندارد استفاده می‌کند، به نتایجی هم‌ارز الگوریتم AL2 منجر شده است، هرچند که این مدل، انحراف استاندارد روزانه سری مشاهداتی را بیشتر از الگوریتم AL2 پیش‌بینی کرده است. در بین مدل‌های شبکه عصبی مصنوعی، تنها مدل FeedF1 کاهش جزئی متوسط روزانه جریان را تحت سناریوهای تغییر اقلیم پیش‌بینی کرده است و سایر مدل‌های شبکه عصبی مصنوعی، افزایش شدت جریان را پیش‌بینی کرده‌اند. هر دو الگوریتم DF کاهش متوسط شدت جریان را پیش‌بینی کرده‌اند، اما این کاهش در الگوریتم AL1 بسیار بیشتر از الگوریتم AL2 است و تا حدی غیرواقعی به نظر می‌رسد. از آنجاکه مدل HW2 در مرحله واسنجی در بین مدل‌های آزمون شده بهترین عملکرد را دارد و در این مرحله نیز، تغییرات پیش‌بینی شده توسط این مدل با تغییرات پیش‌بینی شده توسط الگوریتم AL2 هم‌استاست، می‌توان نتیجه گرفت که نتایج روش ترکیب اطلاعات با استفاده از الگوریتم AL2 از اعتمادپذیری بیشتری نسبت به سایر روش‌ها برخوردار است. این الگوریتم، برای سناریوهای اقلیمی A1B، A2، B1 و CM به ترتیب کاهش متوسط روزانه شدت جریان به مقدار $1/4$ ، $1/72$ ، $1/14$ و $1/22$ متر مکعب در ثانیه را پیش‌بینی می‌کند.

شکل 5 و 6، متوسط و انحراف استاندارد ماهانه شدت جریان ورودی به مخزن سد طالقان را بر مبنای شبیه‌سازی دو مدل AL1-L2-K5 (Lag=2 و K=5) و AL2-L1-K20 (Lag=1 و K=20) تحت سناریوهای تغییر اقلیم نمایش می‌دهند. الگوریتم AL1 برای همه سناریوها و در تمامی ماه‌های سال، کاهش متوسط شدت جریان را پیش‌بینی می‌کند. در حالی که الگوریتم AL2 برای ماه اکتبر، افزایش

در مورد تغییرات انحراف استاندارد میانگین‌های ماهانه، دو متغیر حداقل و حداکثر دما در بیشتر ماه‌های سال (به‌ویژه ماه‌های مرطوب) شاهد افزایش انحراف استاندارد بین‌سالی خواهند بود (جدول 7). این افزایش برای متغیر حداکثر دما تا حدودی بیشتر از حداقل دماست. در مورد متغیر رطوبت نسبی، روند به نسبت مشابهی (با مقادیر کمتر) قابل تشخیص است. تغییرات انحراف استاندارد بارندگی چندان زیاد نیست و حداکثر به پنج درصد محدود می‌شود. در بیشتر ماه‌های سال، انحراف استاندارد میانگین‌های ماهانه بارندگی افزایش پیدا خواهند کرد. نتایج این بخش از تحقیق نشان می‌دهد که دامنه عدم قطعیت در نتایج مدل‌های GCM تا چه حد گسترده است و بی‌توجهی به این مسئله ممکن است نتایج نهایی مطالعات ارزیابی اثر تغییر اقلیم بر منابع آب و عملکرد محصولات کشاورزی را تحت تأثیر قرار دهد.

شبیه‌سازی شدت جریان ورودی به مخزن تحت سناریوهای تغییر اقلیم

به منظور بازتولید سری روزانه جریان ورودی به مخزن سد طالقان تحت سناریوهای تغییر اقلیم (CM, B1, A2, A1B) با استفاده از مدل WG، 100 سال اطلاعات روزانه دما و بارش تولید شد. این اطلاعات، در اختیار مدل‌های شبیه‌سازی قرار گرفت و سری 100 ساله جریان ورودی به مخزن توسط هر مدل شبیه‌سازی شد. جدول 8، میانگین و انحراف استاندارد جریان روزانه ورودی به مخزن سد طالقان را تحت سناریوهای تغییر اقلیم و برای همه مدل‌های منفرد و الگوریتم‌های DF نشان می‌دهد. همان‌طور که دیده می‌شود، مدل‌های همراشتین - واینر با ورودی‌های استاندارد شده (HW1)، با وجود دقت زیاد در مرحله واسنجی و اعتبارسنجی، در این مرحله به نتایج

مطالعه اثر تغییر اقلیم بر جریان ورودی به مخزن سد طالقان با استفاده از روش ترکیب اطلاعات

ماهانه شدت جریان ورودی به مخزن تحت سناریوهای اقلیمی A1B، A2، B1 و CM به مقدار ۳۹، ۴۱، ۲۲ و ۱۲ درصد (AL1) و ۹، ۱۰، ۶ و ۵ درصد (AL2) برآورد شده است. این دو الگوریتم، به ترتیب و به طور متوسط، کاهش ۲۸/۳ و ۷/۴ درصدی متوسط ماهانه شدت جریان ورودی به مخزن را تحت کلیه سناریوهای تغییر اقلیم پیش بینی می کنند.

متوسط شدت جریان را پیش بینی کرده است. الگوریتم AL1 بیشترین کاهش متوسط ماهانه شدت جریان تحت سناریوهای اقلیمی A1B، A2، B1 و CM را به ترتیب به مقدار ۵۲، ۵۵، ۳۶ و ۲۴ درصد برای ماه نوامبر پیش بینی کرده است. این مقادیر توسط الگوریتم AL2 به ترتیب به مقدار ۱۸ (نوامبر)، ۲۰ (جولای)، ۱۴ (نوامبر) و ۱۴ درصد (نوامبر) پیش بینی شده اند. به طور متوسط، کاهش میانگین

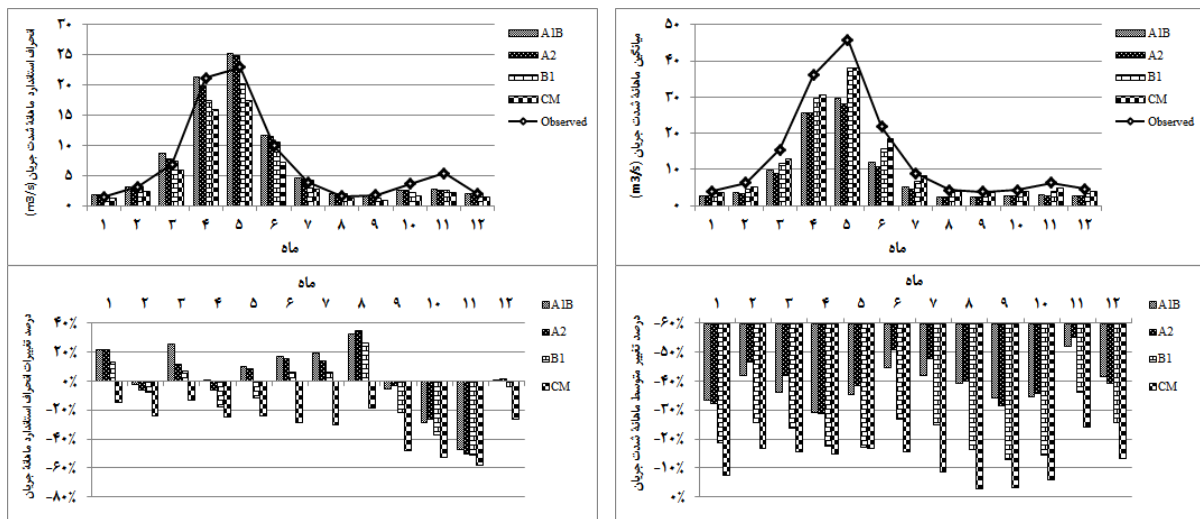
جدول ۸. میانگین و انحراف استاندارد جریان روزانه ورودی به مخزن تحت سناریوهای تغییر اقلیم

سناریو	نام مدل	میانگین m ³ /s	انحراف استاندارد m ³ /s	سناریو	نام مدل	میانگین m ³ /s	انحراف استاندارد m ³ /s
	مشاهداتی	۱۳/۸۳	۱۷/۰۴		مشاهداتی	۱۳/۸۳	۱۷/۰۴
A1B	HW ₁	۶۷/۹۷	۹۲/۲۳	A2	HW1	۶۵/۴۷	۸۴/۹۳
	HW ₂	۱۲/۴۷	۱۶/۰۴		HW2	۱۱/۴۵	۱۴/۲۵
	FeedF ₁	۱۳/۷۷	۱۴/۳۲		FeedF1	۱۳/۷۰	۱۴/۱۹
	FeedF ₂	۱۵/۱۷	۱۵/۹۶		FeedF2	۱۵/۱۰	۱۵/۸۱
	RB ₂	۱۵/۹۰	۶۵/۹۲		RB2	۱۷/۵۸	۲۱۷/۹۱
	GRNN ₂	۱۵/۱۹	۱۵/۶۸		GRNN2	۱۵/۱۶	۱۵/۵۷
	AL ₁ -L ₂ -K ₅	۸/۵۵	۱۴/۰۳		AL1-L2-K5	۸/۱۸	۱۳/۵۶
	AL ₂ -L ₁ -K ₂₀	۱۲/۴۳	۱۳/۷۵		AL2-L1-K20	۱۲/۱۱	۱۳/۳۲
سناریو	نام مدل	میانگین m ³ /s	انحراف استاندارد m ³ /s	سناریو	نام مدل	میانگین m ³ /s	انحراف استاندارد m ³ /s
	مشاهداتی	۱۳/۸۳	۱۷/۰۴		مشاهداتی	۱۳/۸۳	۱۷/۰۴
B1	HW ₁	۳۱/۸۳	۴۹/۳۹	CM	HW1	۱۸/۷۴	۳۳/۹۱
	HW ₂	۱۱/۷۷	۱۴/۲۲		HW2	۱۱/۶۰	۱۳/۵۴
	FeedF ₁	۱۳/۶۲	۱۴/۱۴		FeedF1	۱۳/۴۸	۱۴/۰۳
	FeedF ₂	۱۴/۹۳	۱۵/۵۶		FeedF2	۱۴/۶۰	۱۵/۰۸
	RB ₂	۱۷/۷۸	۲۴۱/۴۶		RB2	۱۵/۲۵	۸۸/۲۶
	GRNN ₂	۱۴/۸۴	۱۵/۳۵		GRNN2	۱۴/۲۷	۱۴/۷۹
	AL ₁ -L ₂ -K ₅	۱۰/۷۱	۱۴/۲۵		AL1-L2-K5	۱۱/۵۶	۱۳/۵۱
	AL ₂ -L ₁ -K ₂₀	۱۲/۶۹	۱۳/۶۱		AL2-L1-K20	۱۲/۶۱	۱۳/۲۳

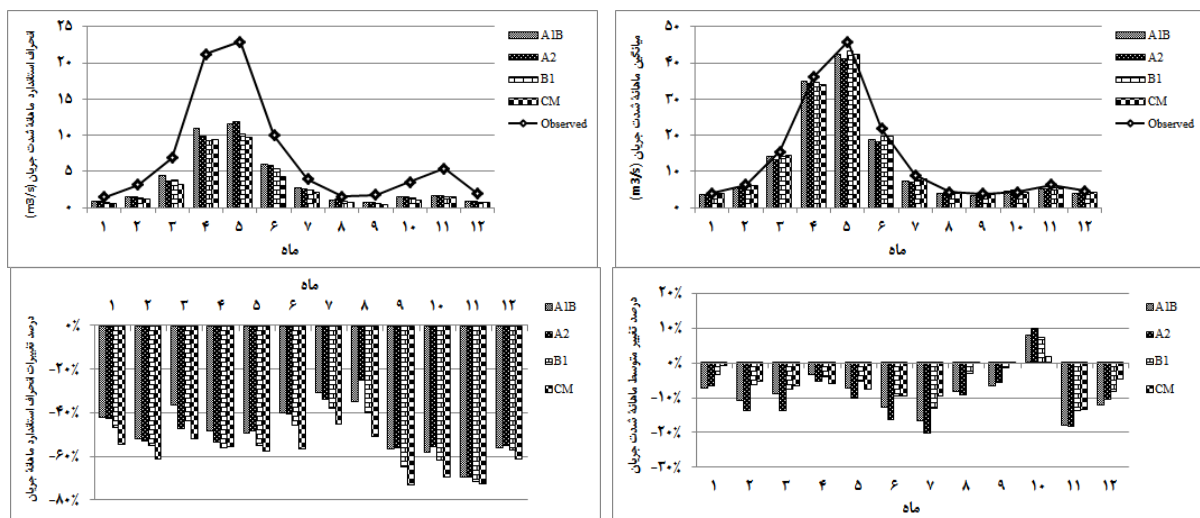
نتیجه گیری

مرحله واسنجی و اعتبارسنجی، تلفیق این مدل‌ها با مدل مولد اقلیم ممکن است به نتایج غیرقابل انتظاری منجر شود. این مسئله به‌ویژه در مورد مدل‌های همراه‌ترین - واینر چشمگیر است. مقایسه نتایج حاصل از روش ترکیب اطلاعات با مدل‌های منفرد، حاکی از افزایش دقت شبیه‌سازی در مقایسه با مدل‌های منفرد است. عملکرد هر دو الگوریتم ترکیب اطلاعات در شبیه‌سازی متوسط ماهانه جریان ورودی به مخزن یکسان بود، اما الگوریتم AL1 به مقادیر بزرگ‌تری از انحراف استاندارد ماهانه منجر شد.

در این تحقیق، کاربرد روش ترکیب اطلاعات در شبیه‌سازی فرایند هیدرولوژیک جریان ورودی به مخزن سد طالقان بررسی شد. دو الگوریتم ترکیب اطلاعات بر مبنای الگوریتم K نزدیک‌ترین همسایه (K-NN) پیشنهاد شده و ارزیابی شدند. چهار مدل شبکه عصبی مصنوعی و دو مدل همراه‌ترین - واینر به‌عنوان مدل‌های شبیه‌ساز جریان روزانه ورودی به مخزن استفاده شدند. نتایج این تحقیق نشان داد که با وجود دقت زیاد برخی مدل‌ها در



شکل ۵. مقدار و درصد تغییر میانگین و انحراف استاندارد ماهانه جریان تحت سناریوهای تغییر اقلیم: مدل AL1-L2-K5



شکل ۶. مقدار و درصد تغییر میانگین و انحراف استاندارد ماهانه جریان تحت سناریوهای تغییر اقلیم: مدل AL2-L1-20

مدیریت آب و آبیاری

دوره ۳ ■ شماره ۲ ■ پاییز و زمستان ۱۳۹۲

- contrasting catchments. *Hydrology and Earth System Sciences*. 6(4): 655-670.
5. Arnell NW (2003a) Effects of climate change on river flows and groundwater recharge using the UKCIP02 scenarios. Report to UK Water Industry Research Limited. University of Southampton.
 6. Arnell NW (2003b) Relative effects of multi-decadal climatic variability and changes in the mean and variability of climate due to global warming: future stream flows in Britain. *Hydrology*. 270: 19-213 .
 7. Arnell NW and Reynard NS (1996) The effects of climate change due to global warming on river flows in Great Britain. *Hydrology*. 183: 397-424.
 8. Azmi M, Araghinejad S and Kholghi M (2010). Multi-model data fusion for hydrological forecasting using K-nearest neighbor method. *Iranian Journal of Science and Technology, Transaction B, Engineering*. 34(B1): 81-92.
 9. Dasarathy BV (1997) Sensor fusion on potential exploitation-innovative architectures and illustrative applications. *Proceedings of the IEEE*. 85: 24-38.
 10. Diaz-Nieto J and Wilby RL (2005). The impact of climate change on low flows in the River Thames UK: A comparison of statistical downscaling and change factor. *Climatic Change*. 69(2-3): 245-268.
 11. Hall DL (1992) Mathematical techniques in multisensory data fusion. Artech House, Boston, MA.
- در نهایت، با استفاده از مدل مولد اقلیم، سری روزانه دما و بارش تحت سناریوهای تغییر اقلیم بازتولید شد و این سری‌ها، به عنوان ورودی مدل‌های منفرد و روش ترکیب اطلاعات به کار رفت. نتایج نشان داد که پیش‌بینی مدل‌های منفرد در شرایط تغییر اقلیم می‌تواند متفاوت و گاه تغییرات پیش‌بینی شده توسط آنها دارای جهات متناقضی باشند. همچنین مشخص شد که عملکرد روش ترکیب اطلاعات با استفاده از الگوریتم AL2 توسط مدل HW2 تأیید شده و در مقایسه با الگوریتم AL1، به نتایج منطقی‌تری منجر می‌شود. همچنین، با توجه به تناقض‌های موجود در میان مدل‌ها منفرد، کاربرد این روش سبب افزایش ضریب اطمینان در ارتباط با تغییرات پیش‌بینی شده جریان ورودی به مخزن در شرایط تغییر اقلیم می‌شود.
- ### منابع
۱. آبابایی ب (۱۳۹۱) توسعه و کاربرد سامانه پشتیبان برنامه‌ریزی برای ارزیابی راهکارهای مدیریت منابع آب و خاک جهت سازگاری با تغییر اقلیم. رساله دکتری آبیاری و زهکشی، دانشگاه تهران. ۳۲۷ صفحه.
 ۲. مساح بوانی ع. و مرید س (۱۳۸۴a) اثرات تغییر اقلیم بر جریان رودخانه زاینده‌رود اصفهان. علوم و فنون کشاورزی و منابع طبیعی. ۹(۴): ۲۷-۱۷.
 ۳. مساح بوانی ع. و مرید س (۱۳۸۴b) اثرات تغییر اقلیم بر منابع آب و تولید محصولات کشاورزی مطالعه موردی: حوضه زاینده‌رود اصفهان. تحقیقات منابع آب ایران. ۱(۱): ۴۷-۴۰.
 4. Abrahart RJ and See L (2002) Multi-model data fusion for river flow forecasting: an evaluation of six alternative methods based on two

12. Karlsson M and Yakowitz S (1987) Nearest - neighbor methods for nonparametric rainfall-runoff forecasting. Water Resources Research. 23(7): 1300-1308.
13. Lall U and Sharma A (1996) A nearest neighbor bootstrap for resampling hydrologic time series. Water Resources Research. 32(3): 679-694.
14. MATLAB (2008) User's guide. The MathWorks Inc, 3 Apple Hill Drive Natick, MA.
15. Nakicenovic N, Alcamo J, Davis G, de Vries B, Fenhann J, Gaffin S, Gregory K, Grübler A, Jung TY, Kram T, La Rovere EL, Michaelis L, Mori S, Morita T, Pepper Pitcher W H, Price L, Raihi K, Roehrl A, Rogner H, Sankovski A, Schlesinger M, Shukla P, Smith S, Swart R, van Rooijen S, Victor N and Dadi Z (2000) Emissions Scenarios. A Special Report of Working Group III of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, UK and New York, USA, 599 pp.
16. Pilling CG and Jones JAA (1999) High resolution climate change scenarios: implications for British runoff. Hydrological Processes. 13: 2877-2895.
17. Prudhomme C, Reynard N and Crooks S (2002) Downscaling of global climate models for flood frequency analysis: where are we now? Hydrological Processes. 16: 1137-1150.
18. See L and Abrahart RJ (2001) Multi-model data fusion for hydrological forecasting. Computers and Geosciences. 27: 987-994.
19. Shu, C and Burn DH (2004) Artificial neural network ensembles and their application in pooled flood frequency analysis. Water Resources Research. 40(9): W09301.
20. Yates D, Gangopadhyas S, Rajagopalan B and Strzepek K (2003) A technique for generating regional climate scenarios using a nearest neighbor algorithm. Water Resources Research. 39(7): 1199-1207.