



مدیریت آب و آبیاری

دوره ۳ ■ شماره ۱ ■ بهار و تابستان ۱۳۹۲

صفحه‌های ۱۲-۱

شبیه‌سازی جریان روزانه ورودی به سد طالقان با استفاده از مدل‌های همراهتین - واینر

بهنام آبابایی*^۱، تیمور سهرابی^۲، فرهاد میرزایی اصلی^۳

۱. دکتری مهندسی آبیاری و زهکشی گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج - ایران
۲. مرکز تحقیقات و توسعه، سازمان اتکا
۳. استاد گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج - ایران
۴. استادیار گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج - ایران

تاریخ پذیرش مقاله: ۱۳۹۲/۲/۲۱

تاریخ وصول مقاله: ۱۳۹۲/۱/۲۲

چکیده

سیستم‌های همراهتین - واینر از جمله مدل‌هایی هستند که توانایی تشریح سیستم‌های دینامیک غیرخطی را دارند. این مدل‌ها، مدل‌هایی غیرخطی اند که به واسطه سادگی و مفهوم فیزیکی‌شان، در دامنه وسیعی از علوم کاربرد دارند. در این تحقیق، برای اولین بار در حوزه هیدرولوژی و مدیریت منابع آب، سه ساختار مختلف از این مدل‌ها به منظور شبیه‌سازی جریان روزانه ورودی به مخزن سد طالقان با استفاده از داده‌های روزانه دما و بارندگی به عنوان ورودی‌های مدل توسط آماره‌های R^2 ، RMSE، SRMSE، MAE، d و PEP ارزیابی شدند. به این منظور، از اطلاعات مخزن سد طالقان بین سال‌های ۱۳۸۵ تا ۱۳۹۰ استفاده شد. نتایج این ارزیابی با پیش‌پردازش اطلاعات (HW1) و بدون پیش‌پردازش اطلاعات (HW2)، با عملکرد دو مدل شبکه عصبی مصنوعی پیشخور با دو لایه مخفی (FeedF2) و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN2) مقایسه شد. نتایج نشان داد که براساس همه شاخص‌ها، عملکرد مدل‌های همراهتین - واینر از مدل‌های شبکه عصبی مصنوعی بهتر است. به ویژه، مقادیر میانگین و انحراف استاندارد ماهانه سری مشاهداتی به بهترین شکل از طریق این مدل‌ها شبیه‌سازی می‌شوند. مقدار شاخص SRMSE مدل HW1 در مراحل واسنجی و آزمون به ترتیب ۳۳ و ۳۷ درصد و برای مدل HW2 به ترتیب ۲۸ و ۴۳ درصد برآورد شد، درحالی‌که همین شاخص برای دو مدل دیگر به ترتیب ۷۱ و ۵۰ و ۵۸ و ۵۰ درصد برآورد شد.

کلیدواژه‌ها: ارزیابی، جریان رودخانه، شبکه‌های عصبی مصنوعی، مدل‌های همراهتین - واینر، مقایسه.

مقدمه

در حوزه‌های فنی و غیرفنی، شناسایی سیستم^۱ اهمیت زیادی دارد. همه سیستم‌های فیزیکی تا اندازه‌ای غیرخطی اند و طبیعتاً استفاده از مدل‌های غیرخطی برای تشریح آنها به نتایج بهتری منجر می‌شود. در حوزه هیدرولوژی آب‌های سطحی، مدل‌های آماری بسیاری در زمینه مدل‌سازی و پیش‌بینی سری غیرخطی جریان رودخانه استفاده می‌شوند. در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANNs) به‌طور گسترده بررسی شده و برای شبیه‌سازی و پیش‌بینی متغیرهای هیدرولوژیک به‌کار رفته‌اند (۱، ۲، ۳، ۵، ۸، ۱۳، ۱۴).

در کنار این مدل‌ها، به‌منظور شبیه‌سازی هرچه بهتر رفتار سیستم‌های غیرخطی در دامنه وسیعی از شرایط کاری، معمولاً یک مدل بلوک‌محور^۲ به‌کار می‌رود. سیستم‌های همراشتین و سیستم‌های واینر^۳ از جمله مدل‌هایی هستند که توانایی تشریح سیستم‌های دینامیک غیرخطی را دارند. در این مدل‌ها، زیرسیستم(های) غیرخطی استاتیک (بدون حافظه) و زیرسیستم(های) خطی دینامیک (با حافظه) در کنار یکدیگر قرار می‌گیرند. این مدل‌ها، غیرخطی‌اند و به‌واسطه سادگی و مفهوم فیزیکی‌شان، در دامنه وسیعی از علوم کاربرد دارند. رفتار استاتیک سیستم به‌طور کامل توسط بلوک‌های استاتیک غیرخطی تشریح می‌شود، درحالی‌که رفتار دینامیک سیستم توسط هر دو جزء خطی و غیرخطی مدل توصیف می‌شود. برای مثال، یک مدل واینر، از یک بلوک خطی دینامیک تشکیل شده که در امتداد آن یک بلوک غیرخطی استاتیک قرار گرفته است (۱۵، ۱۶). مدل همراشتین، در واقع شکل معکوس شده مدل واینر است که در آن، موقعیت بلوک‌های خطی و غیرخطی تعویض شده است (۶). در این تحقیق،

علاوه بر ارزیابی عملکرد دو مدل شبکه عصبی مصنوعی، کاربرد مدل‌های همراشتین- واینر در شبیه‌سازی جریان روزانه ورودی به مخزن سد طالقان ارزیابی و مقایسه می‌شود.

مواد و روش‌ها

مدل‌های همراشتین- واینر

مدل‌های همراشتین- واینر (HW)^۴، با ترکیب دو نوع سیستم همراشتین و واینر، دینامیک سیستم را با استفاده از دو بلوک غیرخطی که به‌طور سری در راستای یک بلوک خطی (دینامیک) قرار گرفته‌اند، شبیه‌سازی می‌کنند (۱۱). این ساختار (شکل ۱)، با موفقیت برای شبیه‌سازی سیستم‌های غیرخطی در علوم مختلف به‌کار گرفته شده است؛ از آن جمله، در حوزه فرایندهای شیمیایی (۴، ۶، ۹، ۱۲)، فرایندهای بیولوژیک (۱۰)، پردازش، ارتباطات و کنترل سیگنال‌ها (۷). اما تاکنون در هیدرولوژی و مدیریت منابع آب از آن استفاده نشده است. روابط زیر، ساختار عمومی یک مدل HW را تشریح می‌کنند:

$$W(t) = G(U(t)) \quad [1]$$

$$X(t) = \frac{B_{j,i}(q)}{F_{j,i}(q)} W(t) \quad [2]$$

$$Y(t) = H(X(t)) \quad [3]$$

در این روابط:


$U(t)$ و $Y(t)$ ، به‌ترتیب، ورودی‌ها و خروجی‌های سیستم را نشان می‌دهند.

G و H توابع غیرخطی که به‌ترتیب در سمت ورودی‌ها و خروجی‌های مدل قرار گرفته‌اند. برای سیستم‌های دارای چند ورودی و یا چند خروجی، این توابع به‌طور جداگانه برای هر ورودی و خروجی تعریف می‌شوند.

1. System Identification
2. Block-Oriented Model
3. Hammerstein Systems and Wiener Systems

4. Hammerstein-Wiener Models

مدیریت آب و آبیاری



شکل ۱. ساختار یک مدل HW

شبکه سیگموئیدی^۵ برای خروجی‌ها؛ (۳) مدل HW با تخمین‌گر غیرخطی شبکه سیگموئیدی برای ورودی‌ها و تخمین‌گر (غیرخطی) خطی تکه‌ای برای خروجی‌ها.

تخمین‌گر خطی تکه‌ای، از یک رابطه خطی چندتکه تشکیل شده است. در این تخمین‌گر، $y = F(x)$ از طریق میان‌یابی خطی بین نقاط انفصال^۶ تخمین زده می‌شود. رابطه^۵، شکل شبکه سیگموئیدی را نشان می‌دهد:

$$F(x) = (x - r)PL + a_1 f((x - r)Qb_1 - c_1) + \dots + a_n f((x - r)Qb_n - c_n) + d \quad [5]$$

P و Q ماتریس‌های افکتنش^۷ هستند که با تحلیل اجزای اصلی بر روی اطلاعات ورودی در مرحله آموزش تعیین می‌شوند. L جزء خطی معادله مذکور است که امکان حذف آن نیز وجود دارد. $y = F(x)$ یک مقدار اسکالر و x بردار ورودی‌ها با تعداد ابعاد m است. تابع سیگموئیدی f به شکل رابطه^۶ استفاده می‌شود:

$$f(z) = \frac{1}{e^{-z} + 1} \quad [6]$$

شبکه Wavelet، تا حدودی مشابه شبکه سیگموئیدی است، با این فرق که شکل تابع f در آن متفاوت است. رابطه^۷، شکل شبکه Wavelet را نشان می‌دهد:

$W(t)$ و $X(t)$ متغیرهای درونی سیستم که به ترتیب، ورودی و خروجی بلوک خطی را نشان می‌دهند. تعداد ابعاد متغیر W برابر با تعداد ابعاد متغیرهای ورودی (U) و تعداد ابعاد متغیر X برابر با تعداد ابعاد متغیرهای خروجی (Y) است. B و F در بلوک خطی، توابع خطی‌اند که معمولاً مشابه مدل‌های چندجمله‌ای^۱ هستند:

$$A(q)y(t) = \sum_{i=1}^{nu} \frac{B_i(q)}{F_i(q)} U_i(t - nk_i) + \frac{C(q)}{D(q)} e(t) \quad [4]$$

در این مدل‌ها، توابع چندجمله‌ای A, B, C, D شامل یک عملگر زمان (q) هستند. U_i : ورودی i ، nu : تعداد ورودی‌ها و nk_i : تأخیر زمانی مربوط به ورودی i است. برای جزئیات بیشتر در مورد این مدل‌ها، به مرجع (۱۱) مراجعه کنید.

روش تحقیق

در این تحقیق، با طراحی یک الگوریتم تصادفی تکراری^۲، عملکرد مدل‌های مختلف HW ارزیابی شد. این ارزیابی، سه ساختار مختلف مدل‌های HW را در بر می‌گرفت: (۱) مدل HW با تخمین‌گر غیرخطی شبکه^۳ Wavelet برای ورودی‌ها و تخمین‌گر (غیرخطی) خطی تکه‌ای^۴ برای خروجی‌ها؛ (۲) مدل HW با تخمین‌گر غیرخطی شبکه Wavelet برای ورودی‌ها و تخمین‌گر غیرخطی

1. Polynomial Models
2. Randomized iterative algorithm
3. Wavelet network nonlinearity estimator
4. Piecewise-linear

5. Sigmoid network nonlinearity estimator
6. Breakpoints
7. Projection matrices

آماري صورت مي گرفت. ۷۰ درصد اطلاعات براي واسنجي مدل و ۳۰ درصد براي اعتبارسنجي آن استفاده شد. ورودی های مدل، شامل متغیرهای بارندگی و متوسط دما در هر روز و خروجی مدل، متوسط شدت جریان روزانه ورودی به مخزن سد طالقان بود. این اطلاعات، از ایستگاه های هواشناسی و هیدرومتری سد طالقان و برای دوره فروردین ۱۳۸۵ تا اردیبهشت ۱۳۹۰ (مارس ۲۰۰۶ تا آوریل ۲۰۱۱) دریافت شدند. به منظور بررسی بیشتر، نتایج این مدل، با نتایج حاصل از دو مدل شبکه عصبی مصنوعی مقایسه شد: ۱- شبکه عصبی مصنوعی پیشخور با دو لایه مخفی و هر لایه شامل ۲۰ نورون با پیش پردازش اطلاعات ورودی (FeedF2)؛ ۲- شبکه عصبی رگرسیون تعمیم یافته با ورودی های استاندارد شده (با استفاده از مقادیر میانگین و انحراف استاندارد مربوط به هر ماه از سال در دوره واسنجی) و پارامتر گسترش ۰/۶ (GRNN2) (۱). در ارتباط با مدل FeedF2، پیش پردازش اطلاعات همانند مدل HW1 و واسنجی و اعتبارسنجی این مدل به روش توقف زودهنگام^۳ صورت پذیرفت. به نحوی که در صورت افزایش شاخص عملکرد مدل در مرحله آزمون در پنج تکرار متوالی، آموزش به پایان می رسد و از برازش بیش از اندازه مدل بر اطلاعات مرحله واسنجی جلوگیری می شود.

ارزیابی عملکرد مدل ها

به منظور ارزیابی عملکرد مدل ها در شبیه سازی ویژگی های آماری سری مشاهداتی، از شاخص های آماری ضریب تعیین (R^2)، ریشه میانگین مربع خطاها (SRMSE) و (RSME)، میانگین خطاهای مطلق (MAE)، شاخص انطباق (d) و درصد خطا در برآورد مقدار پیک (PEP)^۴ استفاده

$$F(x) = (x - r)PL + a_1 f((b_{s1}(x - r))Q - c_{s1}) + \dots + a_{sn} f((b_{sn}s(x - r))Q - c_{sn}) + a_{w1} g((b_{w1}(x - r))Q - c_{w1}) + \dots + a_{wn} w g((b_{wn}w(x - r))Q - c_{wn}) + d \quad [V]$$

پارامترها با زیرنویس s، جزء پارامترهای مقیاس دهی^۱ و با زیرنویس w، جزء پارامترهای Wavelet هستند. تابع f، یک تابع مقیاس دهی^۲ و تابع g، یک تابع Wavelet است و هر دو از انواع توابع شعاعی اند که از رابطه ۸ محاسبه می شوند (در این روابط، $\dim(x)$ ، تعداد ابعاد بردار ورودی x را نشان می دهد):

$$\begin{cases} f(x) = e^{-0.5x^x} \\ g(x) = (\dim(x) - x^x)e^{-0.5x^x} \end{cases} \quad [8]$$

پیش از شروع فرایند تکراری، مدل های HW با تعداد ترم های متفاوت آزمون شدند و بر اساس نتایج حاصل، تعداد ترم های مورد استفاده در هر شبکه (زیرنویس n در روابط ۵ و ۷)، بین ۵ تا ۷۰ در نظر گرفته شد.

بخش دیگر از ساختار مدل که باید از قبل تعیین شود، مرتبه مدل خطی و تعداد تأخیر زمانی ورودی هاست. این پارامترها عبارتند از nb، nf و nk که به ترتیب، تعداد صفرهای مدل به علاوه یک (که تعداد ورودی های مورد استفاده در مدل از گام های زمانی قبل را مشخص می کند)، تعداد قطب ها و تأخیر زمانی ورودی ها نسبت به خروجی ها هستند (۱۱). مقادیر این پارامترها در الگوریتم تکراری، به ترتیب یک تا چهار، صفر تا سه و صفر تا یک در نظر گرفته شدند. تعداد تکرارهای الگوریتم، ۲۰۰۰ تکرار در نظر گرفته شد که در هر نوبت، مقادیر پارامترهای مدل به طور تصادفی انتخاب می شد و ارزیابی عملکرد مدل در مرحله واسنجی و اعتبارسنجی از طریق شاخص های

3. Early Stopping
4. Percent Error in Peak

1. Scaling parameters
2. Scaling function

محدوده تحقیق

به منظور انتقال آب طالقان به دشت قزوین، در سال ۱۳۴۸ ساخت سد انحرافی سنگبان در طالقان و تونل انتقال آب به طول ۹ کیلومتر تا زیاران و ساخت سد انحرافی زیاران و مجموعه کانال‌های آبیاری دشت قزوین آغاز شد. در همان سال‌ها، بررسی‌هایی درباره ساخت سد مخزنی به منظور ذخیره سیلاب‌های بهاره رود طالقان نیز انجام گرفت، اما ساخت آن با توجه به شرایط کشور، تا سال ۱۳۸۱ به تعویق افتاد. در فروردین ۱۳۸۱، عملیات ساخت سد مخزنی طالقان آغاز شد و سد در سال ۱۳۸۵ به بهره‌برداری رسید. این سد مخزنی، در دره طالقان، جنوب رشته‌کوه البرز و در ۱۲۰ کیلومتری شمال غربی تهران واقع شده است. با احداث سد مخزنی طالقان، دستیابی به اهداف زیر امکان‌پذیر خواهد شد:

- کنترل و تنظیم جریان‌های سطحی رودخانه طالقان؛
- تأمین آب مورد نیاز برای کشاورزی دشت قزوین؛
- تأمین بخشی از آب مشروب شهر گسترش‌یافته تهران و آب کشاورزی دشت‌های شهریار و رباط کریم؛
- ارتقای سطح زندگی، رفاه اجتماعی، امنیت، توازن و خودکفایی اقتصادی؛
- استفاده از پتانسیل‌های برقابی به‌عنوان هدف جنبی؛
- تقویت آبخوان‌های آبرفتی دشت قزوین از طریق تغذیه مصنوعی.

پیش‌پردازش اطلاعات

به منظور آماده‌سازی اطلاعات برای معرفی به مدل‌ها، سری زمانی جریان ورودی به مخزن سد (از مارس ۲۰۰۶ تا آوریل ۲۰۱۱) به دو بخش تقسیم شد: ۷۰ درصد برای واسنجی، ۳۰ درصد برای آزمون. حذف جزء دوره‌ای (فصلی) از سری زمانی، به‌ویژه در مدلسازی‌های آماری

شد. شاخص‌های MAE، RMSE و PEP از روابط زیر محاسبه می‌شوند. در این روابط، O و P به ترتیب مقادیر مشاهداتی و مصنوعی، \bar{O} و \bar{P} میانگین مقادیر مشاهداتی و مصنوعی و n تعداد داده در هر یک از سری‌ها هستند. معیار انتخاب بهترین مدل‌ها، حداقل مقدار SRMSE (m^3/sec) در دوره صحت‌سنجی و حداقل مقدار SRMSE در کل دوره آماری است. در مرحله مقایسه ماهانه، از شاخص PEP به منظور ارزیابی عملکرد مدل‌های مختلف در شبیه‌سازی جریان‌های بیک و از شاخص RMSE به منظور برآورد خطای مدل‌ها در هر ماه بهره گرفته شد.

$$R^2 = \left(1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}\right) \times 100 \quad [9]$$

$$RMSE = \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right]^{0.5} \quad [10]$$

$$SRMSE = \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right]^{0.5} \times \frac{100}{\bar{O}} \quad [11]$$

$$SMAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \times \frac{100}{\bar{O}} \quad [12]$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad [13]$$

$$PEP = \frac{\text{Max}(P_i) - \text{Max}(O_i)}{\text{Max}(O_i)} \times 100 \quad [14]$$

$$d = \left(1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2}\right) \times 100 \quad [15]$$


شدت جریان ورودی به مخزن است. در این مدل، مقدار nb برای هر دو متغیر ورودی برابر با ۴، nf برابر با ۲ و nk برابر با صفر است. این شکل نشان می‌دهد که مدل HW انتخابی، توانایی زیادی در شبیه‌سازی جریان‌های پیک رودخانه داشته است. به‌نحوی که حتی جریان‌های پیک ابتدای سال ۲۰۰۷ نیز به‌خوبی توسط این مدل شبیه‌سازی شده‌اند. شکل ۳ نتایج شبیه‌سازی شبکه عصبی مصنوعی FeedF2 و شکل ۴ نتایج مدل GRNN2 را نشان می‌دهند. به‌منظور مقایسه بیشتر، ارزیابی عملکرد مدل HW بدون پیش‌پردازش اطلاعات نیز صورت گرفت (مدل HW2). شکل ۵ عملکرد این مدل را در شبیه‌سازی جریان ورودی به مخزن نمایش می‌دهد. معیار انتخاب بهترین مدل HW2، کمترین مقدار شاخص SRMSE برای کل دوره آماری بود. بهترین مدل HW2 یک مدل HW از نوع ۳ است که دارای ۲۵ ترم سیگموئیدی برای متغیر بارندگی، ۲۱ ترم سیگموئیدی برای متغیر متوسط دما و ۶۳ ترم خطی تکه‌ای برای متغیر خروجی شدت جریان ورودی به مخزن است. در این مدل، مقدار nb برای هر دو متغیر ورودی برابر با ۲، nf برابر با ۳ و nk برابر با صفر است.

خطی، توصیه شده است. در این تحقیق، این جزء با این هدف حذف شد که امکان استفاده از یک مدل HW (HW1) برای همه ماه‌های سال وجود داشته باشد (به‌جای واسنجی یک مدل برای هر ماه یا هر فصل). بنابراین، سری زمانی جریان روزانه ورودی به مخزن سد با استفاده از مقادیر میانگین و انحراف استاندارد مربوط به هر ماه از سال (در دوره واسنجی) استاندارد شد. پس از این مرحله و به‌منظور حذف همبستگی متغیرهای ورودی، تحلیل اجزای اصلی (PCA) بر روی ورودی‌ها صورت گرفت (۱۱). عملکرد مدل HW بدون پیش‌پردازش اطلاعات ورودی ارزیابی شد (مدل HW2).

نتایج و بحث


شبیه‌سازی سری مشاهداتی در دوره‌های واسنجی و آزمون

شکل ۲ نتایج شبیه‌سازی کل دوره آماری بهترین مدل HW1 (با پیش‌پردازش اطلاعات) را که از طریق الگوریتم تصادفی انتخاب شده است، نشان می‌دهد. این مدل، یک مدل HW از نوع ۳ است که دارای ۴۵ ترم سیگموئیدی برای متغیر بارندگی، ۴۰ ترم سیگموئیدی برای متغیر بارندگی، ۴۰ ترم سیگموئیدی برای متغیر خروجی متوسط دما و ۴۸ ترم خطی تکه‌ای برای متغیر خروجی

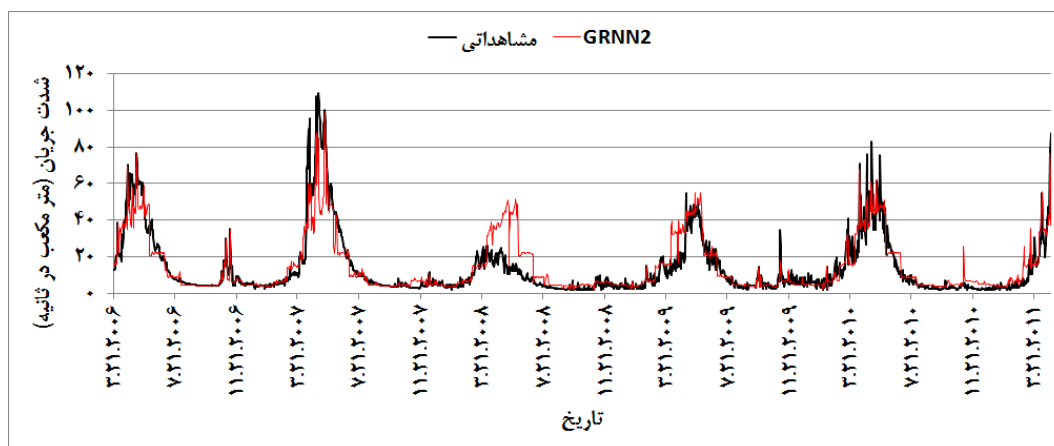


شکل ۲. نتایج شبیه‌سازی بهترین مدل HW1 در کل دوره آماری

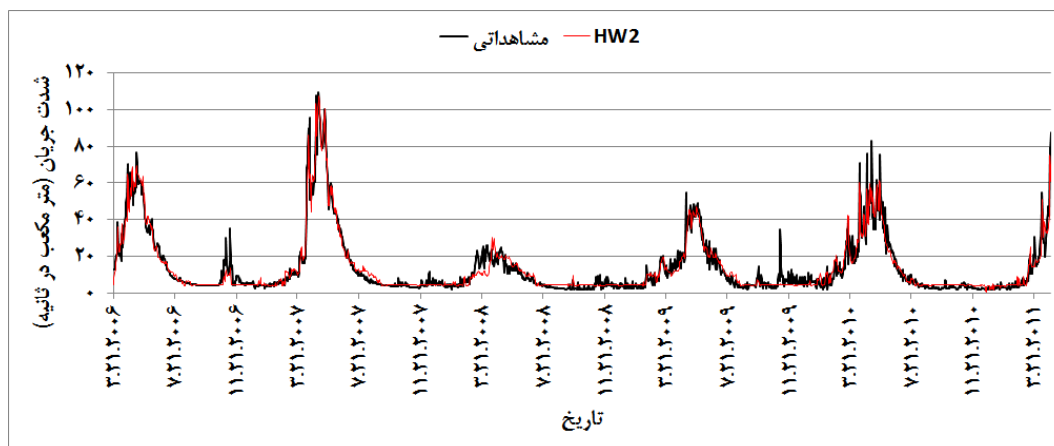
شبیه‌سازی جریان روزانه ورودی به سد طالقان با استفاده از مدل‌های همراشتین - واینر



شکل ۳. نتایج شبیه‌سازی مدل FeedF2 در کل دوره آماری



شکل ۴. نتایج شبیه‌سازی مدل GRNN2 در کل دوره آماری



شکل ۵. نتایج شبیه‌سازی بهترین مدل HW2 در کل دوره آماری

مدیریت آب و آبیاری

دوره ۳ ■ شماره ۱ ■ بهار و تابستان ۱۳۹۲

HW و مدل‌های شبکه عصبی مصنوعی را نشان می‌دهد. همچنین مشخص می‌شود که این مدل، توانایی بسیار زیادی در شبیه‌سازی مقادیر میانگین و انحراف استاندارد سری مشاهداتی داشته است. این توانایی، هم در مرحله واسنجی و هم در مرحله آزمون قابل تشخیص است.

شبیه‌سازی سری مشاهداتی در هریک از ماه‌های سال

جدول ۳ نتایج شاخص‌های عملکرد بهترین مدل‌های HW را در کنار دو مدل شبکه عصبی مصنوعی برای هریک از ماه‌های سال نشان می‌دهد. در این جدول، مقادیر منفی شاخص PEP نشان‌دهنده برآورد پایین دست جریان‌های پیک و مقادیر مثبت، نشان‌دهنده برآورد بالادست این جریان‌ها در هر ماه است. مقدار شاخص RMSE و R^2 در تمامی ماه‌ها، بیانگر عملکرد بهتر مدل‌های HW در مقایسه با دو مدل دیگر است. در ماه مارس و ماه‌های ژوئن تا دسامبر، مدل GRNN2 در شبیه‌سازی جریان‌های پیک نسبت به مدل HW1 موفق‌تر بوده است. از نظر تمامی شاخص‌های عملکرد، مدل FeedF2 پایین‌ترین سطح عملکرد را در بین این چهار مدل دارد.

جدول ۱ شاخص‌های آماری عملکرد بهترین مدل HW را در مقایسه با شاخص‌های عملکرد دو مدل شبکه عصبی مصنوعی نشان می‌دهد. علائم P و T به ترتیب تأخیرهای زمانی بارش و دما را نشان می‌دهند (بین صفر تا سه روز). برای نمونه، PPPTT نشان‌دهنده بردار ورودی‌هایی شامل بارش از دو روز قبل تا روز فعلی و دما از روز قبل تا روز فعلی است. به طور مشخص، مدل HW2 با مقدار شاخص SRMSE ۲۸ درصد در دوره واسنجی، در مقایسه با مدل‌های شبکه عصبی مصنوعی عملکرد بسیار بهتری داشته است. در دوره آزمون نیز، خطای مدل HW1 برابر با ۳۷ درصد و خطای مدل HW2 برابر با ۴۳ درصد بود که در مقایسه با هر دو مدل شبکه عصبی مصنوعی، کمتر و شاخص d دوره آزمون این مدل از مدل‌های دیگر بیشتر است. مقدار شاخص PEP برای شبیه‌سازی کل دوره آماری توسط مدل HW1 در حدود ۷ درصد، برای مدل HW2 حدود ۱- درصد، برای مدل FeedF2 حدود ۱۹- و برای مدل GRNN2 حدود ۱۰- درصد است که از این حیث نیز عملکرد مدل‌های HW بهتر از دیگر مدل‌ها بوده است.

جدول ۲ مقادیر میانگین و انحراف استاندارد سری مشاهداتی و سری‌های مصنوعی حاصل از بهترین مدل‌های

جدول ۱. مقایسه شاخص‌های عملکرد بهترین مدل HW با مدل‌های شبکه عصبی مصنوعی

d	SRMSE%				R ² %				Neurons / Spread	تابع آموزش	نام مدل	ورودی‌ها
	All	Test	Valid	Train	All	Test	Valid	Train				
۰/۹۷	%۳۴	%۳۷	---	%۳۳	%۹۶	%۹۵	---	%۹۷	۱ ۴۵-۴۰-۴۸	---	HW1	PT
۰/۹۷	%۲۹	%۴۳	---	%۲۸	%۹۷	%۹۴	---	%۹۷	۱ ۲۵-۲۱-۶۳	---	HW2	PT
۰/۹۶	%۶۸	%۵۰	%۵۷	%۷۱	%۸۴	%۹۳	%۸۶	%۸۲	۲۰	LM	FeedF2	PPT
۰/۹۶	%۶۰	%۵۰	%۵۸	%۵۸	%۸۸	%۹۳	%۸۷	%۸۷	۰/۶	---	GRNN2	PPPTT

۱. منظور، تعداد ترم‌های مورد استفاده در مدل است (به ابتدای بخش نتایج و بحث مراجعه کنید).

شبیه‌سازی جریان روزانه ورودی به سد طالقان با استفاده از مدل‌های همراشتین - واینر

جدول ۲. مقادیر میانگین و انحراف استاندارد سری مشاهداتی و سری مصنوعی

میانگین (متر مکعب در ثانیه)								نام مدل
تمام دوره		آزمون		اعتبارسنجی		واسنجی		
۱۴/۲۹	۱۳/۸۴	۱۳/۳۱	۱۳/۳۵	---	---	۱۴/۷۶	۱۴/۰۳	HW1
۱۳/۸۴	۱۳/۸۴	۱۳/۲۲	۱۳/۳۵	---	---	۱۴/۱۵	۱۴/۰۳	HW2
۱۵/۰۳	۱۳/۸۴	۱۵/۰۲	۱۳/۲۳	۱۵/۲۴	۱۴/۰۲	۱۵/۰۴	۱۳/۹۹	FeedF2
۱۴/۷۶	۱۳/۸۴	۱۴/۸۵	۱۳/۱۴	---	---	۱۴/۶۸	۱۴/۰۳	GRNN2

انحراف استاندارد (متر مکعب در ثانیه)								نام مدل
تمام دوره		آزمون		اعتبارسنجی		واسنجی		
۱۷/۰۲	۱۷/۰۴	۱۶/۱۱	۱۶/۹۳	---	---	۱۷/۹۱	۱۷/۷۸	HW1
۱۶/۵۴	۱۷/۰۴	۱۴/۷۸	۱۶/۹۳	---	---	۱۷/۸۵	۱۷/۷۸	HW2
۱۵/۳۷	۱۷/۰۵	۱۵/۲۱	۱۶/۹۱	۱۵/۴۵	۱۲/۶۰	۱۵/۴۱	۱۷/۰۸	FeedF2
۱۵/۳۸	۱۷/۰۵	۱۵/۲۴	۱۶/۸۴	---	---	۱۵/۱۶	۱۶/۳۲	GRNN2

استاندارد روزانه سری جریان ورودی به مخزن برای مدل‌های HW1، HW2، FeedF2 و GRNN2 به ترتیب برابر است با ۱/۲۵، ۱/۲، ۴/۳۱ و ۳/۵۷ متر مکعب در ثانیه. از این مقادیر نیز می‌توان نتیجه گرفت که مدل همراشتین- واینر در شبیه‌سازی مقادیر متوسط روزانه و انحراف استاندارد روزانه سری جریان ورودی به مخزن سد طالقان، نسبت به دو مدل دیگر خطای کمتری دارد. به ویژه، خطای این مدل در شبیه‌سازی مقادیر انحراف استاندارد روزانه نسبت به دو مدل شبکه عصبی مصنوعی بسیار کمتر است. در تمامی ماه‌های سال، مقدار انحراف استاندارد شبیه‌سازی شده توسط مدل‌های HW کمتر از مقادیر مشاهداتی است و عملکرد دو مدل HW در شبیه‌سازی انحراف استاندارد روزانه سری مشاهداتی در یک سطح است. با این تفاوت که مدل HW1 در شبیه‌سازی انحراف استاندارد ماه‌های کم‌آب‌تر (سپتامبر تا دسامبر) عملکرد بهتری دارد، در حالی که مدل HW2 در ماه‌های پرآب‌تر (ژانویه تا آگوست) خطای کمتری دارد.

شکل ۶ مقادیر شبیه‌سازی شده بهترین مدل‌های HW و دو مدل شبکه عصبی مورد مقایسه را در برابر مقادیر مشاهداتی و خط ۱:۱ نشان می‌دهد. همان‌طور که مشاهده می‌شود، مدل HW هم در شبیه‌سازی جریان‌های پایه و هم در شبیه‌سازی جریان‌های پیک (به‌طور کلی) از دو مدل دیگر عملکرد بهتری دارد. نقاط مربوط به شبیه‌سازی مدل HW در فاصله کمتری نسبت به خط ۱:۱ قرار گرفته‌اند که به معنی خطای کمتر این مدل است.

شکل ۷ مقادیر متوسط روزانه و شکل ۸ مقادیر انحراف استاندارد جریان روزانه ورودی به مخزن برای هر یک از ماه‌های سال را نشان می‌دهد. مدل HW در اکثر ماه‌ها، مقادیر متوسط جریان ورودی به مخزن را بهتر از دو مدل دیگر برآورد کرده است. مقدار شاخص MAE برای شبیه‌سازی متوسط‌های روزانه از طریق مدل HW1 برابر با ۰/۶۱ متر مکعب در ثانیه و برای مدل HW2 برابر با ۰/۹۲ است. در حالی که این مقدار برای مدل‌های FeedF2 و GRNN2 به ترتیب ۱/۱۶ و ۰/۸۹ متر مکعب در ثانیه برآورد شده است. این شاخص برای شبیه‌سازی مقادیر انحراف

مدیریت آب و آبیاری

دوره ۳ ■ شماره ۱ ■ بهار و تابستان ۱۳۹۲

جدول ۳. مقایسه عملکرد مدل‌های مختلف در هر یک از ماه‌های سال

ماه	GRNN2			FeedF2			HW2			HW1		
	PEP%	RMSE	R ² %	PEP%	RMSE	R ² %	PEP%	RMSE	R ² %	PEP%	RMSE	R ² %
Jan	-۲۶/۴	۱/۴۱	۳۳/۹	-۳۴/۲	۱/۴۹	۲۱/۲	۱۲/۳	۱/۷۷	۱۹/۶	-۱۵/۱	۱/۰۷	۷۰/۹
Feb	-۱۶/۳	۲/۷۷	۵۰/۸	-۴۸/۰	۳/۲۲	۱۴/۸	۴/۳	۲/۸۹	۷۰/۷	-۴/۲	۲/۳۷	۶۸/۹
Mar	-۶/۴	۶/۰۴	۵۱/۴	-۲۹/۸	۶/۵۷	۳۵/۰	۳/۱	۵/۲۶	۷۱/۸	-۱۴/۷	۴/۵۹	۷۴/۹
Apr	-۱۸/۴	۱۵/۵۷	۷۳/۳	-۳۱/۲	۱۸/۴۹	۵۳/۶	-۳/۹	۷/۷۸	۹۳/۱۸	-۴/۱	۱۰/۲۰	۸۸/۴
May	-۹/۵	۱۹/۵۷	۵۴/۸	-۱۹/۱	۲۱/۵۰	۳۶/۶	-۱/۷۶	۵/۶۱	۹۷/۵	۷/۰	۸/۹۷	۹۳/۵
Jun	-۲/۸	۹/۲۷	۳۷/۱	-۱۹/۴	۹/۵۲	۳۶/۵	۵/۴	۳/۳۹	۹۴/۲	-۱۷/۷	۴/۷۲	۸۸/۲
Jul	-۰/۷	۳/۴۹	۴۶/۲	-۲۷/۷	۳/۹۳	۱۹/۶	-۱/۷	۲/۱۷	۸۸/۹	-۲۰/۹	۲/۶۲	۷۵/۳
Aug	-۰/۱	۱/۳۲	۵۴/۶	-۱۸/۲	۱/۵۹	۲۵/۴	۵۰/۵	۲/۲۲	۷۳/۷	۴/۰	۰/۹۸	۷۸/۰
Sep	-۰/۲	۱/۱۰	۷۹/۹	-۴۹/۱	۱/۷۲	۳۰/۱	-۳۴/۹	۱/۸۰	۳۱/۳	-۱۳/۳	۱/۰۱	۸۲/۹
Oct	۰/۰	۱/۶۰	۹۱/۸	-۶۲/۵	۲/۸۲	۷۰/۸	-۵۹/۵	۲/۷۰	۸۸/۴	-۱۲/۱	۱/۲۶	۹۳/۶
Nov	۰/۰	۳/۹۲	۷۱/۰	-۵۲/۴	۴/۸۴	۴۶/۵	-۶۰/۸	۴/۹۰	۶۳/۶	-۱۳/۷	۳/۰۱	۸۳/۵
Dec	-۵/۸	۱/۸۶	۳۴/۲	-۳۲/۶	۲/۱۵	۲/۷	-۴۹/۸	۱/۸۵	۳۹/۸	-۳۴/۳	۱/۳۵	۷۲/۷

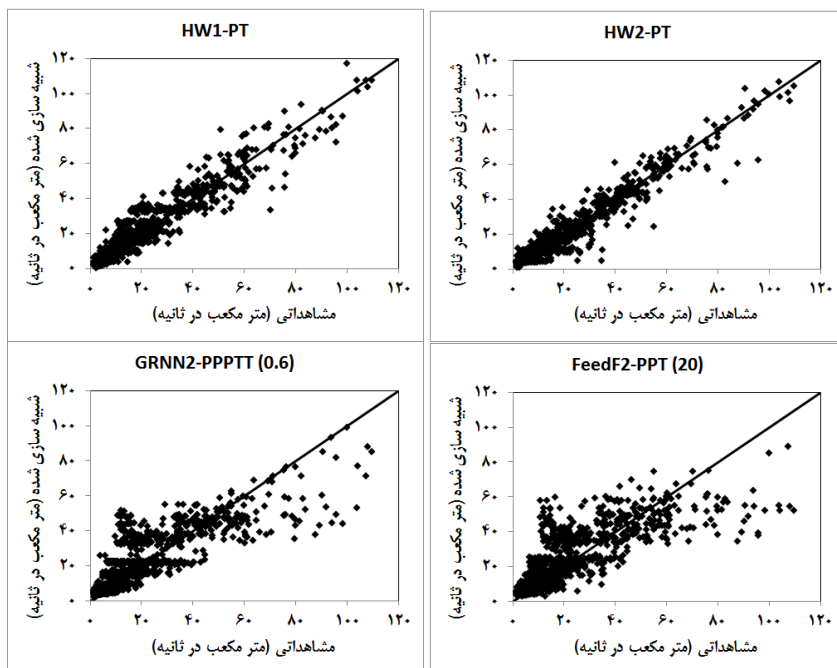
جمع بندی

عملکرد بهتری داشته است. این مدل قادر است طبیعت غیرخطی فرایند بارش - رواناب را به خوبی بازسازی کرده و مقادیر میانگین و انحراف استاندارد ماهانه سری مشاهداتی را با دقت بیشتری نسبت به مدل‌های شبکه عصبی مصنوعی شبیه‌سازی کند. به این ترتیب، می‌توان این مدل‌ها را که تاکنون در حوزه هیدرولوژی و تحقیقات منابع آب استفاده نشده‌اند، به عنوان ابزاری کارآمد در مدل‌سازی جریان رودخانه معرفی کرد. بنابراین، از این ابزار می‌توان به عنوان جایگزینی مناسب برای مدل‌های سری زمانی و شبکه‌های عصبی مصنوعی در تحقیقات ارزیابی تأثیر تغییر اقلیم بر کمیت و کیفیت منابع آب استفاده کرد. با این حال، ارزیابی بیشتر ویژگی‌های این مدل‌های آماری باید مدنظر قرار گیرد.


در این تحقیق، عملکرد مدل‌های مختلف همراشتین - واینر (HW) با سه ساختار مختلف و پارامترهای متفاوت با پیش‌پردازش و بدون پیش‌پردازش اطلاعات در شبیه‌سازی جریان روزانه ورودی به مخزن سد طالقان ارزیابی شد. مدل HW با توابع غیرخطی سیگموئیدی در سمت ورودی‌ها و تابع (غیرخطی) خطی تکه‌ای در سمت خروجی‌ها به عنوان بهترین مدل انتخاب شد. سپس، عملکرد این مدل در شبیه‌سازی کل دوره آماری و به تفکیک در دوره‌های واسنجی و آزمون با دو مدل شبکه عصبی مصنوعی پیشخور با دو لایه مخفی و شبکه عصبی مصنوعی رگرسیون تعمیم‌یافته با ورودی‌های استاندارد شده مقایسه شد. نتایج این تحقیق نشان داد که مدل‌های همراشتین - واینر در تمام موارد نسبت به دو مدل دیگر

مدیریت آب و آبیاری


شبیه‌سازی جریان روزانه ورودی به سد طالقان با استفاده از مدل‌های همراشتین - واینر



شکل ۶. مقادیر روزانه شبیه‌سازی شده توسط مدل‌های مختلف در برابر مقادیر مشاهداتی



شکل ۷. متوسط شدت جریان روزانه در هر یک از ماه‌های سال



شکل ۸. انحراف استاندارد شدت جریان روزانه در هر یک از ماه‌های سال

مدیریت آب و آبیاری

دوره ۳ ■ شماره ۱ ■ بهار و تابستان ۱۳۹۲

Reference

1. Ababaei B, Sohrabi TM, Mirzaei F, Araghinejad S and Ahmadizadeh M (2012) Suitability of different neural networks in daily reservoir inflow simulation. The First International Conference on Dams & Hydropower in Iran-Tehran. Feb. 8-9, 2012.
2. Ahmed JA, Sarmah AK (2007) Artificial neural network model for synthetic streamflow generation. *Water Resources Management* 21(6): 1015-1029.
3. Altunkaynak A (2007) Forecasting surface water level fluctuations of Lake Van by artificial neural networks. *Water Resources Management* 21(2): 399-408.
4. Celka P, Bershad NJ and Vesin JM (2000) Fluctuation analysis of stochastic gradient identification of polynomial Wiener systems. 2000. *IEEE Transactions on Signal Processing*. 48(6): 1820-1825.
5. Coulibaly P, Anctil F, Bobée B (2001) Multivariate reservoir inflow forecasting using temporal neural networks. *Journal of Hydrologic Engineering, ASCE*. 6(5): 367-376.
6. Eskinat E, Johnson SH and Luybean WL (1991) Use of Hammerstein models in identification of nonlinear systems. *AICHE Journal*. 37(2): 255-268.
7. Fruzzetti K, Palazoglu A and McDonald K (1997) Nonlinear model predictive control using Hammerstein models. *Journal of Process Control*, 7(1): 31-41.
8. Hsu KL, Gupta HV, Sorooshian S (1995) Artificial neural network modeling of rainfall-rainoff process. *Water Resources Research*. 31(10): 2517-2530
9. Kalafatis AD, Wang L and Cluett WR (1995) Identification of Wiener-type nonlinear systems. *International Journal of Control*. 66(6): 923-941.
10. Korenberg M (1978) Identification of biological cascades of linear and static nonlinear systems. *Proceedings of the 16th Midwest Symposium on Circuit Theory*, 2.1-2.9.
11. MATLAB (2008) System identification toolbox user's guide. The MathWorks Inc, 3 Apple Hill Drive Natick, MA.
12. Pearson RK and Potmann M (2000) Gray box identification of block-oriented nonlinear models. *Journal of Process Control*. 10: 301-315.
13. Razavi S, and Araghinejad S (2009) Reservoir inflow modeling using temporal neural networks with forgetting factor approach. *Water Resource Manage*. 23(1): 39-55.
14. Razavi S, Karamouz M (2007) Adaptive neural networks for flood routing in river systems. *Water International* 32 (3): 360-375.
15. Wigren T (1993) Recursive prediction error identification using the nonlinear Wiener model. *Automatica*, 29(4): 1011-1025.
16. Wigren T (1994) Convergence analysis of recursive identification algorithms based on the nonlinear Wiener model. *IEEE Transactions on Automatic Control*, 39(11): 2191-2206