



Simulation and Forecasting of River Flow Using Neural Network and a Fourier Series Model

N. Rostam Afshar¹, H. Fahmi², A. R. Pireh³

Abstract

This paper shows concurrent application of The Artificial Neural Network (ANN) model with Fourier Series ARIMA Model (FSAM). The FSAM model represent spectral analysis of precipitation of Barandooz river basin in west of Lake Urmia for simulation of river flow. Neural network are applied for simulation and forecasting of Barandooz river based on FSAM forecasts in the absence of precipitation data. Because temperature is one of the independent variables in the simulation model, generation of temperature data was carried out by twelve MLP Neural networks, one for each month. The analysis and results are presented in this paper.

Keywords: River flow, Neural network, Simulation, Forecasting.

شبیه سازی و پیش بینی جریان رودخانه‌ها با استفاده از شبکه عصبی و مدل فوریه

ناصر رستم افشار^۱، هدایت فهمی^۲، علیرضا پیره^۳

چکیده

مقاله حاضر به بررسی نحوه عملکرد شبکه‌های عصبی MLP در ارتباط با خروجی مدل فوریه، FSAM، می‌پردازد. مدل FSAM که مدل شبیه ساز بارش است، تحلیل مدل‌های کلاسیک را در قلمرو فرکانس، که توسعه نظریه طیفی فرآیندهای متداول نظیر طیف الگوهای ARIMA را در درون خود دارد، ارائه می‌دهد. کاربرد همزمان شبکه‌های عصبی MLP و مدل FSAM، امکان پیش بینی جریان ماه (i) ام را در ارتباط با پیش بینی بارش همان ماه، میسر می‌سازد. بدلیل اینکه یکی از متغیرهای مستقل توابع شبیه سازی دبی، دما می‌باشد شبیه سازی دما توسط دوازده شبکه عصبی MLP برای شبیه سازی دوازده ماه سال بطور مجزا انجام گردید، تا بدین ترتیب بتوان از این شبکه‌ها برای تخمین دما در ماه‌هایی که پیش‌بینی در آنها مد نظر است و داده‌های دما موجود نمی‌باشند، استفاده کرد. این مقاله نتایج و تحلیل علمی لازم را ارائه خواهد داد.

کلمات کلیدی: جریان رودخانه، شبکه عصبی، شبیه سازی، پیش بینی.

1- Assistant Professor, Shahid Abbaspour University, Iran
2- Water Resources Management Company, Iran
3- Jamab Consulting Engineers, Tehran, Iran

۱- استادیار دانشگاه صنعت آب و برق (شهید عباس‌پور)
۲- شرکت مدیریت منابع آب ایران
۳- کارشناس گروه پژوهشی جاماب

۱- مقدمه

ارتباطات درونی شبکه عصبی توسط ماتریس وزن‌ها (w_i) برقرار می‌شود. پالس ورودی هر نرون تابعی از ماتریس وزن‌ها و اطلاعات رسیده به آن نرون (x_i) می‌باشد و از رابطه (۱) بدست می‌آید. در این رابطه θ وزن بایاس (bias) می‌باشد.

$$net = \sum_{i=1}^n w_i x_i + \theta \quad (1)$$

خروجی هر نرون با استفاده از تابع (Sigmoid) و توسط رابطه (۲) بدست می‌آید.

$$F(net) = \frac{1}{1 + \exp(-net)} \quad (2)$$

در هر الگوریتم آموزشی هدف حداقل کردن خطای شبکه است که بصورت رابطه (۳) تعریف می‌شود.

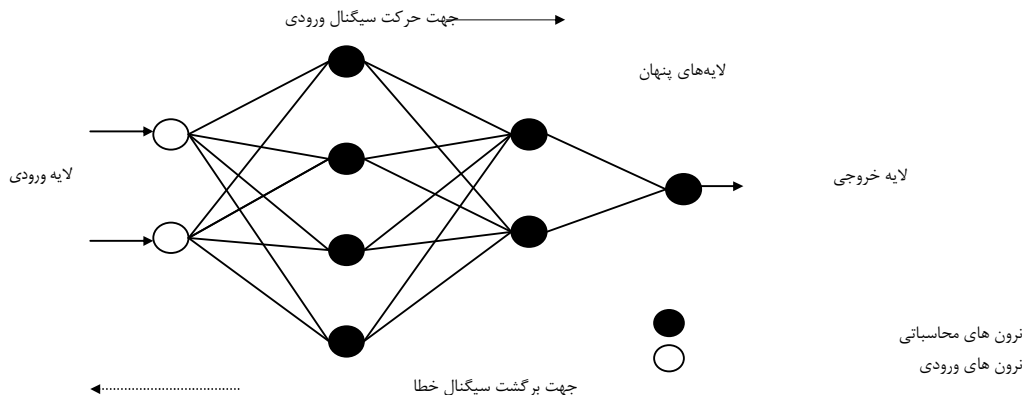
$$E = \frac{1}{PN_{output}} \sum_P \sum_{i=1}^{N_{output}} (t_i - o_i)^2 \quad (3)$$

در این رابطه P تعداد الگوهای آموزشی، N تعداد نرون‌های خروجی، o_i مقدار مشاهده شده نرون i ام، t_i مقدار محاسبه شده نرون i ام توسط شبکه می‌باشند. برای آموزش کلیه شبکه‌های طراحی شده از روش (Levenberg-Marquardt) استفاده گردید. سرعت آموزش در این الگوریتم بسیار بالا بوده و جهت آموزش گروهی شبکه‌های عصبی (Batch Training) مناسب می‌باشد (Nguyen et al., 1999). ضریب کاهش نرخ یادگیری در این تحقیق برابر ۱/۰۵ مدنظر گرفته شده است (Howard et al., 2001).

بررسی رفتار رودخانه‌ها، که تحت تاثیر رفتار پدیده‌های متفاوت هیدرولیکی و هیدرولوژیکی می‌باشد، در حوزه علم تحلیل سیستم‌های دینامیکی، با درجه غیر خطی بالا مطرح می‌شود. در این راستا ظهور تئوری‌های توانمند مانند، الگوریتم‌های فازی، شبکه‌های عصبی، تئوری فضای حالت،... تحولی عظیم در تحلیل رفتار سیستم‌های دینامیک و علوم مختلف مهندسی آب ایجاد کرده است. شبکه‌های عصبی مدل‌های ریاضی انعطاف پذیری هستند که قادرند با توجه به خصوصیت غیر خطی، بین ورودی‌ها و خروجی‌ها، در شبیه‌سازی جریان رودخانه‌ها بطور موثری بکار گرفته شوند (Nguyen et al., 1999). در این راستا بکارگیری مدل Fourier Series ARIMA Model (FSAM) جهت پیش بینی بارش، در کنار شبکه‌های عصبی، متخصصین فن را قادر خواهد ساخت توسط بارش بهنگام ماهانه، جریان ماهانه رودخانه را پیش‌بینی کنند. مقاله حاضر عملکرد شبکه‌های عصبی MLP در استفاده از خروجی مدل FSAM و نیز دمای شبیه سازی شده توسط این شبکه‌های عصبی را مورد تحلیل و بررسی قرار می‌دهد.

۲- مبانی ساختار شبکه‌های عصبی مصنوعی MLP

شبکه‌های عصبی مصنوعی چند لایه پیشخور که عموماً شبکه‌های عصبی چند لایه پرسپترون (MLP) Multy Layer Perceptron نامیده می‌شوند، نوعی از شبکه‌های عصبی هستند که ساختار آنها با قانون پس انتشار خطا تکمیل می‌شود. هر نرون در شبکه MLP دو محاسبه انجام می‌دهد، اول سیگنال تابعی و دوم تخمین لحظه‌ای گرادیان منحنی خطا نسبت به پارامترهایی که ورودی نرون را به خود نرون وصل می‌کند. این گرادیان‌ها جهت پخش سیگنال خطا در شبکه مورد نیاز می‌باشند [منهاج، ۱۳۷۹]. در شکل (۱) نمایش قراردادی شبکه MLP با ساختار (۱-۲-۴-۲) ارائه شده است.



شکل ۱- نمایش قراردادی ساختار شبکه MLP با ساختار (۱-۲-۴-۲) (Kuo et al., 1993)

۳- ساختار ریاضی مدل FSAM

تحلیل طیفی مدل‌های کلاسیک روشی جانشین برای مطالعه تجزیه ناپارامتری داده‌های بارش از طریق مؤلفه‌های فرکانس می‌باشد. این روش تحلیلی از توابع طیفی استفاده می‌کند (نیرومند، ۱۳۷۶). با توجه به اینکه تغییرات ماهانه بارش، از یک الگوی کم و بیش متناوب پیروی می‌نماید، الگوی برازش بصورت رابطه (۴) بیان می‌شود (افشار و همکاران، ۱۳۷۶):

$$X_{n,t} = \mu_t + \delta_t \xi_{n,t} \quad (4)$$

در این رابطه مقادیر μ_t و δ_t ضرایب میانگین و انحراف معیار سری هارمونیک می‌باشند که از روابط (۵) و (۷) محاسبه می‌شوند و $\xi_{n,t}$ عدد تصادفی استاندارد شده می‌باشد.

$$\mu_t = m_x + \sum_{j=1}^{\omega} \left(A_j \cos \frac{2\pi j}{\omega} t + B_j \sin \frac{2\pi j}{\omega} t \right) \quad (5)$$

در اینجا ω دوره تناوب بوده و ضرایب A_j, B_j از روابط (۶) محاسبه می‌شوند.

$$A_j = \frac{2}{\omega} \sum_{t=1}^{\omega} m_t \cos \frac{2\pi j}{\omega} t \quad (6)$$

$$B_j = \frac{2}{\omega} \sum_{t=1}^{\omega} m_t \sin \frac{2\pi j}{\omega} t$$

در این رابطه m_t میانگین داده‌ها در یک دوره زمانی مشخص (سال) در طول دوران آماری، m_x میانگین کلی داده‌ها و δ_t ضریب انحراف معیار سری هارمونیک می‌باشد که از رابطه (۷) محاسبه می‌شود.

$$\delta_t = S_t + \sum_{j=1}^{\omega} \left(A'_j \cos \frac{2\pi j}{\omega} t + B'_j \sin \frac{2\pi j}{\omega} t \right) \quad (7)$$

ضرایب A'_j, B'_j از روابط واقع در (۸) بدست می‌آیند.

$$A'_j = \frac{2}{\omega} \sum_{t=1}^{\omega} S_t \cos \frac{2\pi j}{\omega} t \quad (8)$$

$$B'_j = \frac{2}{\omega} \sum_{t=1}^{\omega} S_t \sin \frac{2\pi j}{\omega} t$$

در این رابطه S_t انحراف معیار داده‌ها در یک دوره زمانی مشخص (سال) در طول دوره آماری می‌باشند که پس از تبدیل باقیمانده داده‌ها به باقیمانده استاندارد \mathcal{E}_t ، از رابطه (۹) جهت پیش‌بینی استفاده می‌گردد.

$$x_t = \mu_t + \delta_t \mathcal{E}_t \quad (9)$$

ساختار ریاضی حاضر با جزئیات آماری وسیع آن در قالب یک مدل کامپیوتری به اجرا درآمده است.

۴- کاربرد عملی مدل

در این مقاله جریان ماهانه رودخانه باراندوزچای در غرب دریاچه ارومیه در ایستگاه بابارود (ایستگاه خروجی حوزه) به مدت ۱۰ سال مابین (سال‌های ۱۳۷۷-۱۳۶۷) جهت آموزش، و به مدت ۲ سال مابین (سال‌های ۷۹-۷۷)، جهت صحت‌یابی شبکه‌ها (این سال‌ها درون داده‌های آموزشی نبوده و علاوه بر آن جهت مطمئن شدن از اینکه شبکه طراحی شده توالی زمانی را نیز آموخته است و همچنین با توجه به پدیده ذوب زودرس برف‌ها در سال‌های اخیر (افشار و همکاران، ۱۳۷۶)، وابستگی جریان رودخانه‌ها به بارش‌هایی از قبیل باران، که تأثیرات بهنگام بر روی جریان رودخانه‌ها می‌گذارد، از آماری که به بهترین نحو این اهداف را برآورد می‌کند، استفاده شده است) و نیز سال آبی ۱۳۸۰-۱۳۷۹ جهت پیش‌بینی مورد بررسی قرار گرفت. نمودار مقادیر اندازه گیری شده جریان ماهانه رودخانه، دما و بارش متوسط ماهانه در سال‌های مورد نظر جهت آموزش شبکه در شکل (۲) آورده شده است. نمودارها در نرم افزار MATLAB رسم شده‌اند. در این تحقیق، براساس تست همبستگی بین داده‌های دبی در تأخیرهای زمانی یک ماهه و دوماهه جریان رودخانه در ماه (i) ام به صورت توابع (۱) تا (۶) مد نظر قرار گرفت.

(۱۰)

$$Q(i) = F(Q(i-2), Q(i-1), R(i-1), T(i-1), T(i), R(i)) \quad (11)$$

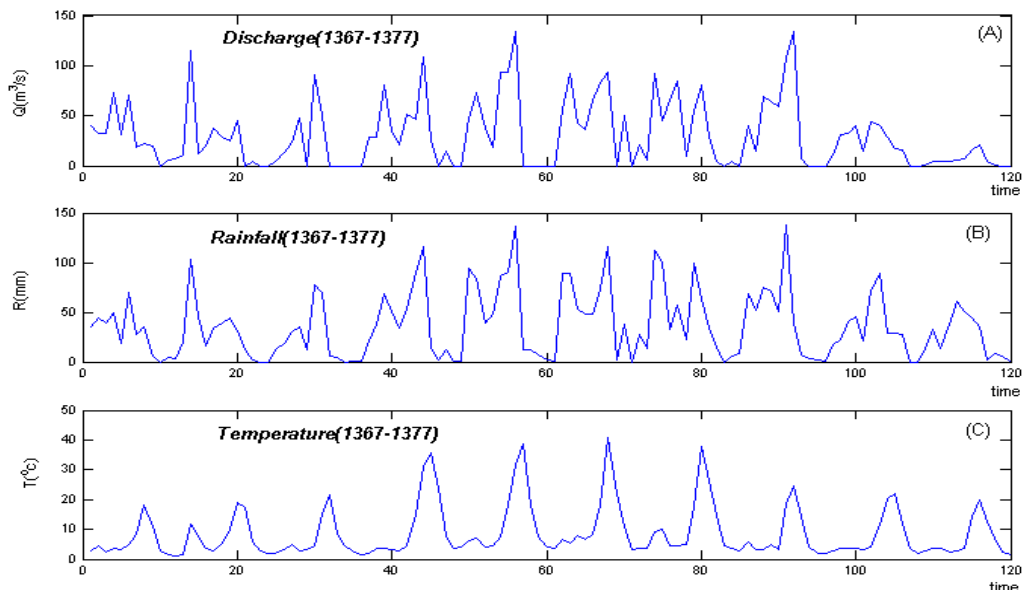
$$Q(i) = F(Q(i-2), Q(i-1), R(i-2), R(i-1), T(i-2), T(i-1), T(i), R(i)) \quad (12)$$

$$Q(i) = F(Q(i-1), R(i-1), T(i-1), T(i), R(i)) \quad (13)$$

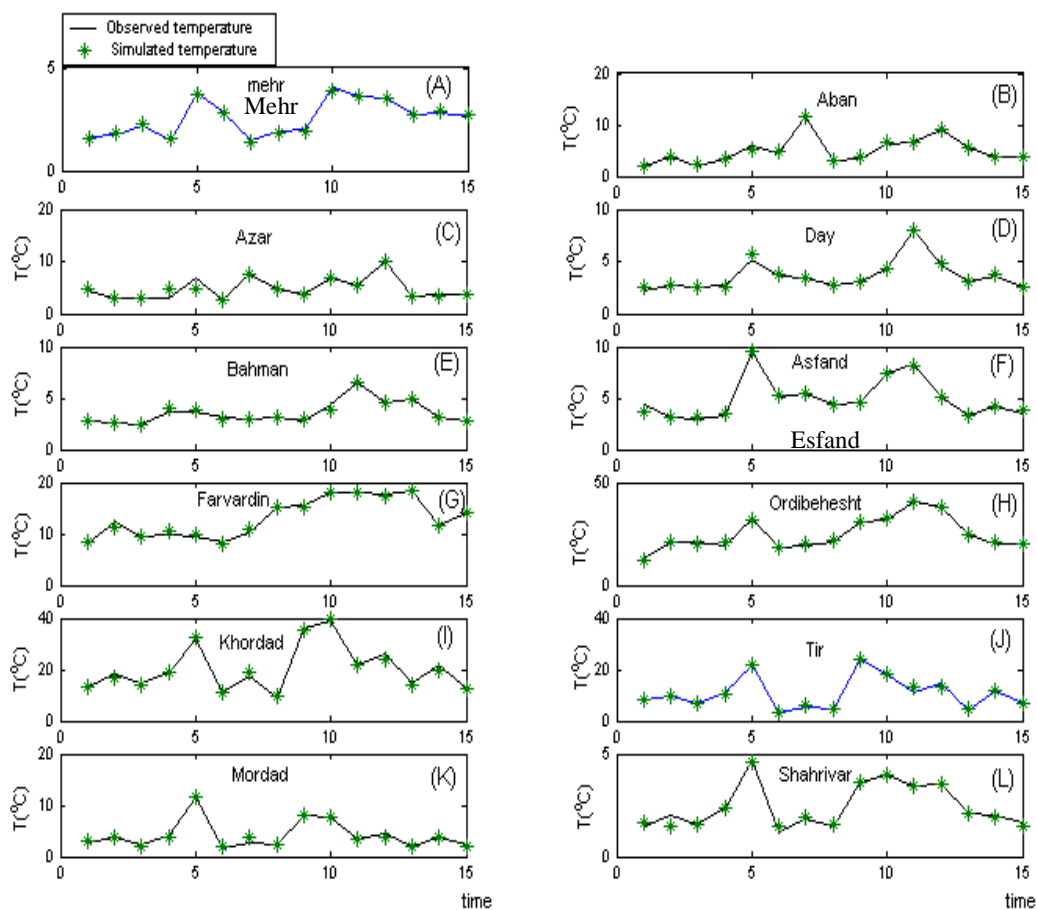
$$Q(i) = F(Q(i-1), R(i-1), R(i)) \quad (14)$$

$$Q(i) = F(R(i-2), R(i-1), T(i-2), T(i-1), T(i), R(i)) \quad (15)$$

$$Q(i) = F(Q(i-3), Q(i-2), Q(i-1), R(i))$$



شکل ۲- نمودار مقادیر ماهانه مشاهده شده، A: جریان رودخانه B: بارندگی C: دما



شکل ۳- نمودارهای مقادیر واقعی و شبیه سازی شده دما برای ماههای مختلف

جدول ۱- آماره‌های ارزیابی شبکه‌های عصبی شبیه ساز دما

شهریور	مرداد	تیر	خرداد	اردیبهشت	فروردین	اسفند	بهمن	دی	آذر	آبان	مهر
											۰/۹۹

R^2 = ضریب نیکویی برازش - MAE (Sutcliff) = میانگین قدر مطلق خطا - RMSE = مجذور میانگین مربعات خطا

انجام گردید. مقدار MAE و RMSE برای کل دوره شبیه سازی برترتیب ۲۳/۹ و ۱۲۷/۷ بدست آمد.

۴-۳- شبیه سازی جریان رودخانه

در این تحقیق شبیه سازی جریان رودخانه در دو حالت انجام گردید.

حالت اول) شبیه‌سازی جریان رودخانه بامقدار ورودی R(i)

در این حالت شبیه‌سازی توابع (۱۱) تا (۱۵) همراه با R(i) بوسیله طراحی شش شبکه انجام گردید. نمودار مقادیر واقعی و شبیه سازی شده برای حالت اول در شکل شماره (۴) آورده شده است.

حالت دوم) شبیه‌سازی جریان رودخانه بدون مقدار ورودی R(i)

شبیه‌سازی توابع (۱۱) تا (۱۵) بدون ورودی R(i) نیز از طریق طراحی شش شبکه انجام گردید. نمودار مقادیر واقعی و پیش بینی شده برای حالت دوم در شکل شماره (۵) آورده شده است.

در جدول شماره (۲) آماره‌های ارزیابی شبکه در حالت اول و دوم در مرحله شبیه سازی و آزمون شبکه‌های عصبی شبیه‌ساز جریان ماهانه آورده شده است.

در این رابطه $T(i-n)$ ، $R(i-n)$ ، $Q(i-n)$ به ترتیب دبی، بارش و دمای متوسط ماهانه در n پله زمانی (پله‌های ماهانه) ماقبل زمان (i) ام هستند. در مرحله پیش بینی جریان برای سال ۱۳۷۹ تا ۱۳۸۰، ورودی بارش در ماه (i) ام، سال آبی مذکور از طریق مدل (FSAM) برآورد خواهد شد. تمامی شبکه‌های عصبی در محیط نرم‌افزار MATLAB طراحی و آموزش داده شدند.

۴-۱- شبیه سازی دما

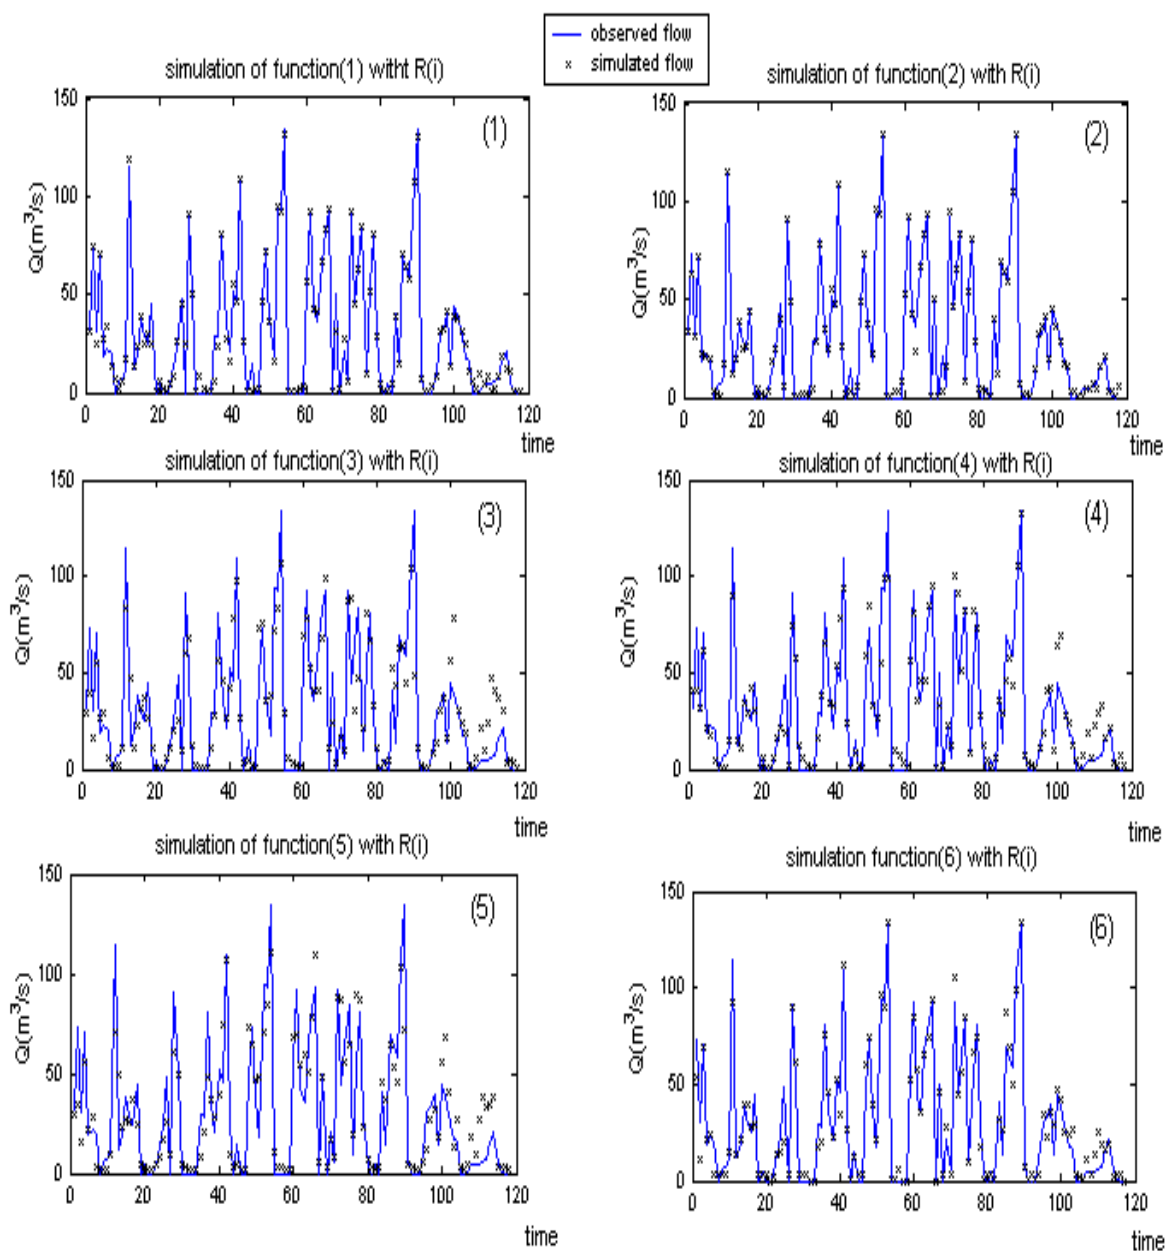
در این مرحله از شبیه‌سازی، متوسط مقادیر دمای حوزه مابین سال‌های ۱۳۶۰-۱۳۷۵ به مدت ۱۵ سال مد نظر قرار گرفت. شبیه‌سازی هر ماه در طول سال‌های مذکور به طور جداگانه انجام گردید. در کل ۱۲ شبکه طراحی، و پیش‌بینی و صحت‌یابی شبکه‌ها برای پنج سال متوالی ۱۳۷۶-۱۳۸۰ انجام گردید. براساس تست همبستگی بین داده‌های دما، در تأخیرهای زمانی یک ماهه ارزیابی شبکه‌های شبیه ساز دما آورده شده است.

۴-۲- شبیه سازی و پیش بینی بارش

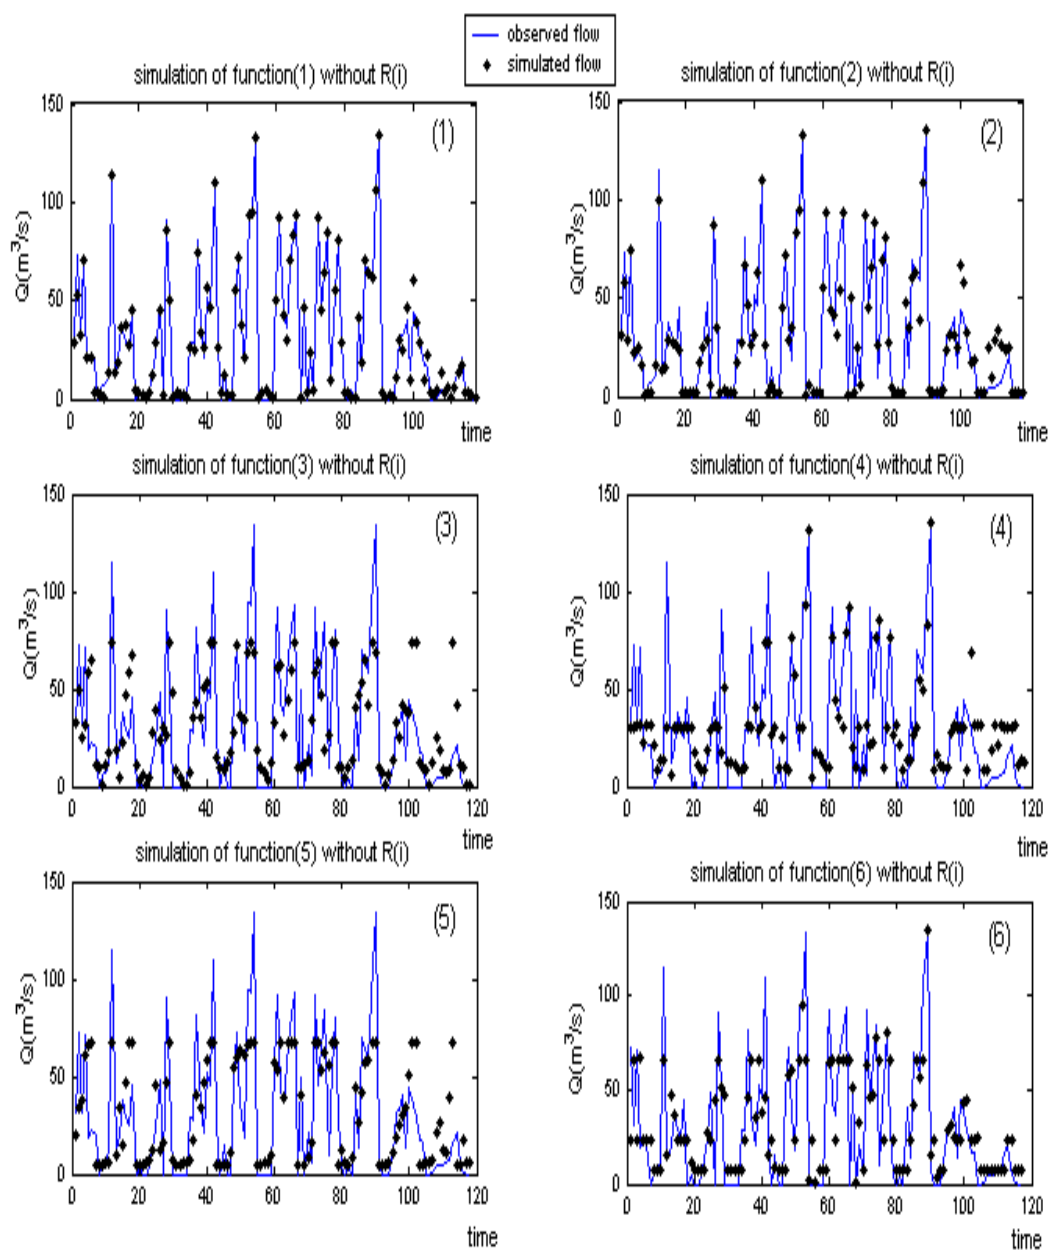
پیش بینی بارش ماهانه سال ۱۳۷۹-۱۳۸۰ براساس شبیه سازی آمار بلندمدت بارش حوزه باراندوزچای (۲۹ ساله) توسط مدل FSAM

جدول ۲- آماره‌های ارزیابی شبیه سازی در حالت اول و دوم

نوع عملکرد شبکه	تابع (۱)		تابع (۲)		تابع (۳)		تابع (۴)		تابع (۵)		تابع (۶)	
	حالت اول	حالت دوم	حالت اول	حالت دوم	حالت اول	حالت دوم	حالت اول	حالت دوم	حالت اول	حالت دوم	حالت اول	حالت دوم
آموزش												
آزمون												
آموزش												
آزمون												
آموزش												
آزمون												۰/۷۳



شکل ۴- نمودارهای مقادیر واقعی و شبیه سازی شده برای حالت اول

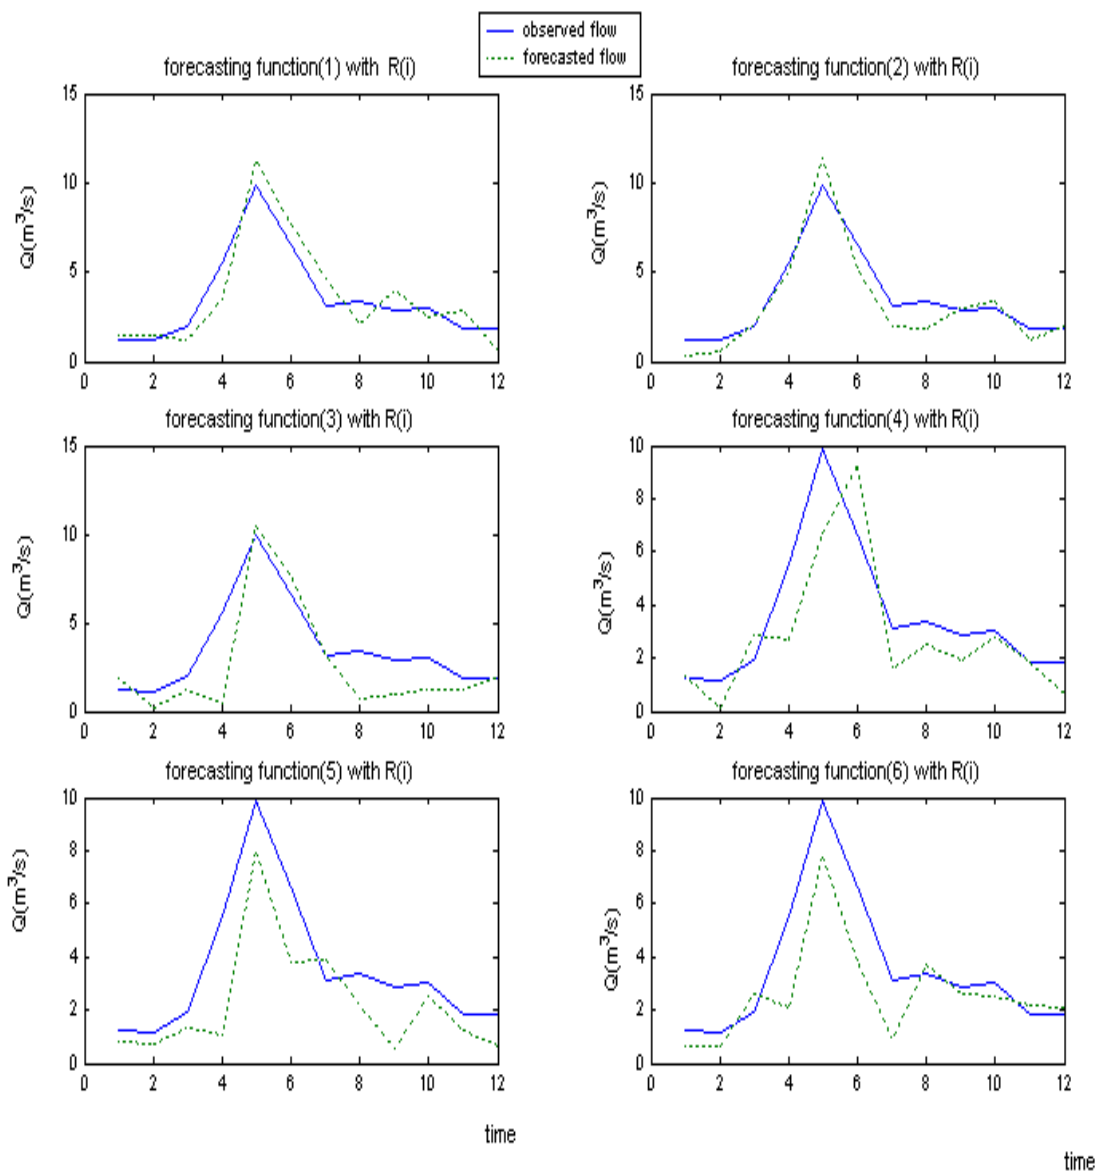


شکل ۵- نمودارهای مقادیر واقعی و شبیه سازی شده برای حالت دوم

۴-۴- پیش بینی جریان رودخانه

قابلیت پیش‌بینی در سال آبی ۱۳۷۹-۱۳۸۰ را نخواهد داشت. نمودار جریان واقعی و پیش‌بینی شده سال ۱۳۷۹-۱۳۸۰ برای حالت اول (با ورودی $R(i)$) در شکل شماره (۶) آورده شده است. پیش‌بینی در این سال در توابع (۵) و (۲) به ترتیب با بیشترین و کمترین خطا، برابر ۴۵ و ۱۰ درصد بدست آمد. در توابع (۱۲)، (۱۳)، و (۱۶) خطای پیش‌بینی به ترتیب برابر ۱۵/۷، ۲۵/۱، ۳۶/۸ و ۳۸/۱ درصد بدست آمد.

پس از شبیه‌سازی بارش توسط مدل FSAM براساس تست همبستگی بین داده‌های دما در تأخیرهای زمانی یک ماهه و دوماهه، دما و جریان توسط شبکه‌های عصبی جریان سال ۱۳۷۹-۱۳۸۰ پیش‌بینی گردید. باید توجه داشت که جهت پیش‌بینی جریان رودخانه در این سال‌ها در حالت دوم (بدون ورودی $R(i)$) تنها ماه اول سال آبی مورد نظر، قابل پیش‌بینی بوده و سایر ماهها به علت نداشتن بارش بهنگام $R(i)$ (که باید توسط مدل FSAM ارائه می‌شود)،



شکل ۶- نمودارهای جریان واقعی و پیش‌بینی شده برای سال ۸۰-۷۹ در حالت اول

۵- جمع بندی و نتیجه گیری

نتایج با توجه به تحقیق حاضر و تحقیقات گذشته به شرح زیر ارائه می شود:

۱- با توجه به پدیده ذوب زودرس برفها در سالهای اخیر (افشار و همکاران، ۱۳۷۶)، وابستگی جریان رودخانهها به بارشهایی از قبیل باران، که تاثیرات بهنگام بر روی جریان رودخانهها می گذارد، زیاد شده، از اینرو مدل سازیهایی که بتواند این تاثیرات را در اهداف کار خود قرار دهند اهمیت بسزایی خواهند داشت.

۲- سرعت آموزش شبکهها در حالت اول در حد قابل توجهی نسبت به حالت دوم بالاتر بوده و این امر نشان دهنده تاثیر بسیار زیاد ورودی بارش بهنگام روی شبیه سازیها می باشد.

۳- وجود عامل جریان رودخانه در ورودیهای شبکه از اهمیت ویژه ای برخوردار است.

۴- با توجه به شکل (۲)، نوسانات منظمی در تغییرات دما، بارش و جریان رودخانه حوزه باراندوز دیده می شود. از این رو به دلیل قدرت بالای شبکههای عصبی در نگاشت های غیرخطی، عملکرد شبکههای موجود در این حوزه بسیار مناسب بوده و بنابراین توصیه می گردد حیطة علمی این مقاله در مورد حوزههای بزرگتر که درجه غیرخطی در میان ورودیهای در نظر گرفته شده بالا می باشد، بکار گرفته شود.

۵- حد پیش بینی در روش بکار گرفته شده در این مقاله یک سال می باشد. دلیل این امر کاهش دقت مدل FSAM در پیش بینی بارشهای چند سال متوالی است.

۶- در شبکههای عصبی شبیه ساز جریان رودخانهها، تعداد سیکل های آموزشی در دقت شبیه سازی اهمیت زیادی داشته،

بنابراین تنظیم تعداد سیکل های آموزش توسط طراح بسیار مهم می باشد.

۷- بهترین شبیه سازی برای تابع (۲)، در حالت اول و خطای نسبی پیش بینی، در بهترین حالت برای تابع (۲) حدوداً ۱۰ درصد و بیشترین مقدار برای تابع (۱۴) برابر ۴۵ درصد بدست آمد.

۶- تشکر

از آقایان مهندس کامران زینالزاده و صمد دعایی به خاطر همکاری صمیمانه اشان در طول انجام این تحقیق کمال تشکر را دارم.

۷- مراجع

افشار، ن. ر، فهیمی، ه. (۱۳۷۶). گزارش پیش بینی بارش کل کشور. سازمان تحقیقات منابع آب.

منهاج، م. ب. (۱۳۷۹). مبانی شبکه های عصبی. دانشگاه صنعتی امیر کبیر، جلد اول.

نیرومند، ح. ع. (۱۳۷۶). تحلیل سری های زمانی، دانشگاه فردوسی مشهد.

Howard, D. and Mark, B. (2001). User's Guide for Neural Network Toolbox with Matlab. Version 6.1.

Kuo, L. H., Hoshin, V. G. and Sorooshian, S. (1993). Artificial Neural Network Modeling of the Rainfall-Runoff Process. *Water Resources Research*. 29(4): pp. 1185-1194.

Nguyen, T. D., Huynh, H. P. and Ashim, D. S. (1999). Neural Network Models For Flow Forecasting, *Water SA* 25(1): pp. 33-39.

تاریخ دریافت مقاله: ۳۱ تیر ۱۳۸۲

تاریخ پذیرش مقاله: ۸ فروردین ۱۳۸۴