

پیش‌بینی جریان ماهانه ورودی به مخزن سد شهید عباسپور با استفاده از مدل‌های سری‌های زمانی Box-Jenkins و شبکه‌های عصبی مصنوعی (ANNs)

امیر جلال کمالی¹، محمد محمودیان شوشتری²، نوید جلال کمالی³

چکیده

بهره‌برداری بهینه از انرژی و نیز مصارف شرب، صنعتی، کشاورزی و مخازن سدها و این‌که چه مقدار آب در آینده به‌منظور اخذ تصمیم بهتر و مدیریت کاراتر مخازن در اختیار است، نیازمند اطلاعات جامعی از آینده منابع آب قابل دسترس می‌باشد. در واقع هدف دیگر از تخمین کوتاه مدت رواناب، بررسی احتمال وقوع سیلاب‌ها به‌منظور اجتناب از سرریز شدن سدها یا به حداقل رساندن خسارات احتمالی آنهاست. به‌منظور تسهیل پیش‌بینی جریان، تکنیک‌های مختلفی در طول سالیان گذشته توسعه یافته است. در این تحقیق از آمار 46 ساله (82-1336) ایستگاه هیدرومتری پل شالو در بالادست مخزن سد شهید عباسپور استفاده شده و با کمک مدل‌های باکس-جنکینز و شبکه‌های عصبی جریان ماهانه ورودی به مخزن این سد پیش‌بینی گردیده است. در نهایت بر اساس پیش‌بینی مدل‌ها و مقایسه نتایج آنها با مقادیر مشاهداتی و نیز انحراف معیار (SD)، ضریب تغییرات (CV)، مجموع مربعات خطا (SSE)، ریشه میانگین مربعات خطا (RMSE) و ضریب همبستگی خطی (R^2) نتایج مدل‌ها، نشان داده شد که مدل $ARIMA(0,1,1) \times (1,1,1)_2$ نسبت به مدل ANN (بر اساس آمار موجود) در پیش‌بینی جریان ماهانه از دقت بالاتری برخوردار است.

واژه‌های کلیدی: سری زمانی، شبکه عصبی، جریان ماهانه ورودی، مخزن سد شهید عباسپور

1- عضو هیات علمی دانشگاه آزاد اسلامی واحد کرمان - دانشجوی دکتری هیدرولوژی و منابع آب

ajalalkamali@yahoo.com

2- استاد دانشکده مهندسی دانشگاه شهید چمران اهواز

3- عضو هیات علمی دانشگاه آزاد اسلامی واحد کرمان

مقدمه

پیش‌بینی عبارت است از تخمین وضعیت آینده یک پارامتر و دارای چهار بعد است: کیفیت، کمیت، زمان و فضا [2]. با توجه به آمار موجود در ایران به نظر می‌رسد که مدل‌های سری زمانی باکس - جنکینز (Box-Jenkins) و مدل‌های شبکه‌های عصبی مصنوعی (ANNs) گزینه‌های قابل قبول برای توسعه مدل پیش‌بینی جریان می‌باشند. با استفاده از آمار تاریخی از جریان ورودی به محل مخزن می‌توان تابع توزیع احتمال جریان‌های ماهانه ورودی را برای مساله طراحی/ بهره‌برداری از مخازن در زمینه‌های مختلف کشاورزی، صنعتی و شرب مشخص کرد. یکی از اولین کاربردهای پیش‌بینی شدت جریان با استفاده از شبکه‌های عصبی توسط کنگ [6] در سال 1993 انجام شد که در آن علاوه بر شبکه‌های عصبی از مدل‌های ARMA برای پیش‌بینی شدت جریان در رودخانه پیونگ چانگ کشور کره استفاده شد. مطالعات دیگری در همین راستا به تفضیل توسط کارونایتی [7] در سال 1994 انجام شد که در آن برای تخمین شدت جریان یک سایت بدون آمار روی رودخانه هورون در ایالت میشیگان کشور آمریکا انجام گرفت. این مطالعه نشان داد که شبکه‌های عصبی قادر به تطبیق خود با تغییرات زیاد در داده‌های تاریخی شدت جریان می‌باشند. در همین سال بوناف و همکارانش [4] کارایی شبکه عصبی را در پیش‌بینی جریان متوسط روزانه با داشتن آمار جریان متوسط روزانه رودخانه تیر در حوضه‌ای در مرکز ایتالیا ارزیابی کردند. دوسون و ویلی [5] نیز در سال 1998 یک شبکه باز خور 3 لایه را در تخمین رواناب روی حوضه‌های رودخانه‌های آمبر و مول در کشور انگلیس ارزیابی کردند. همچنین در سال 2004 ماریا کاستلانومندز و همکارانش [8] در مطالعه‌ای روی رفتار هیدرولوژیک حوضه رودخانه ژالاس در شمال غربی اسپانیا برای پیش‌بینی دبی متوسط ماهانه از مدل کلاسیک آماری باکس - جنکینز و مدل شبکه‌های عصبی استفاده کردند. هدف اصلی این تحقیق مقایسه پیش‌بینی جریان ماهانه ورودی به مخزن سد شهید عباسپور با استفاده از مدل‌های باکس - جنکینز و شبکه‌های عصبی مصنوعی بر روی آمار تاریخی جریان ماهانه ورودی به مخزن سد می‌باشد. پیش‌بینی چنین جریانی به ارزیابی کاهش احتمال خسارت ناشی از دوره‌های خشکسالی ارزیابی و تولید مطمئن انرژی هیدروالکتریک و همچنین تأمین آب مصارف شرب، صنعتی و کشاورزی کمک می‌نماید.

مواد و روش‌ها

- روش مدل‌سازی سری‌های زمانی - (باکس-جنکینز)

مراحل مختلف برازش یک مدل سری زمانی بر اطلاعات تاریخی ماهانه به قرار زیر است [10].

- نرمال سازی اطلاعات
- تعیین نوع و مرتبه رویه تقاضل گیری جهت ایستای سری زمانی
- تعیین مرتبه و معرفی مدل‌های کاندید
- آزمون‌های مختلف بر پسماندهای مدل‌های تحت بررسی
- بررسی و تفسیر گراف پیش‌بینی به هنگام شده


- نرمال سازی اطلاعات

داده‌های اصلی این تحقیق را اطلاعات جریان ماهانه ورودی به مخزن سد شهید عباسپور در ایستگاه هیدرومتری پل شالو در بالادست مخزن برای دوره آماری 46 ساله (1336 تا 1382) تشکیل می‌دهد که از سازمان آب و برق خوزستان دریافت شده‌است.


بررسی این آمار حکایت از انحراف شدید آن نسبت به توزیع نرمال دارد. در شکل 2 سری زمانی ماهانه داده‌های تاریخی بر کاغذ احتمالات نرمال ترسیم شده‌است. از آنجا که در غالب سری‌های زمانی جریان، همه انحراف معیارها بزرگتر از میانگین است، در نتیجه ضریب تغییرات بزرگتر از یک می‌باشد. ضریب چولگی سری زمانی جریان ماهانه ورودی به مخزن سد شهید عباسپور برابر 1/943681 محاسبه گردیده‌است. شکل 1، نمایانگر سری زمانی داده‌های تاریخی می‌باشد. جهت نرمال سازی اطلاعات آورد ماهانه با استفاده از تبدیلات با کس و کاکس (Box and cox) رابطه (1)، کل سری زمانی ماهانه به طور یکجا با ضریب λ برابر با 5/8413- نرمال شد.

$$y_t = \frac{x_t^\lambda - 1}{\lambda} \quad (1)$$


تبدیلات با کس و کاکس تبدیلاتی نهایی هستند که تابع احتمال اطلاعات تبدیل یافته را به تابع نرمال نزدیک می‌کنند. مدلسازی بر سری زمانی حاصل از تبدیلات با کس و کاکس نتایج قابل قبولی ارائه نموده‌است [10]. شکل (3) نمایشگر سری زمانی نرمال شده می‌باشد. لازم به ذکر است که مطابق آزمون کلموگروف-اسمیرنوف با حدود اطمینان 95% برازش توزیع نرمال سری زمانی تبدیل یافته قابل قبول می‌باشد. مطالعه همبستگی نگار سری زمانی تاریخی ماهانه شکل 4، حاکی از رفتارهای تناوبی آن می‌باشد، به گونه‌ای که مطابق آن جریان ماهانه در زمان‌های تأخیر 1، 2، 12، 24 و 48 (ماه) همبستگی معنی داری از خود نشان می‌دهد. بررسی ضرایب خود همبستگی جزئی سری زمانی مذکور شکل 6، در زمان‌های تأخیر 1 و 2 تا زمان تأخیر 67 ماه نیز حاکی از وجود همبستگی جزئی معنی دار است و پس از آن ضرایب مذکور مستهلک می‌گردند. با ترسیم توابع فوق شکل‌های 5 و 6 برای سری زمانی یکجا نرمال شده ملاحظه می‌گردد که رفتار دو تابع تحت بررسی در این سری زمانی کاملاً مشابه با سری زمانی تاریخی بوده جز آن‌که این سری زمانی همبستگی‌های قویتری از خود نشان می‌دهد. رفتار تناوبی نشان از نیاز سری زمانی مذکور به طی کردن فرایند تعاضل گیری برای ایستا شدن دارد [10].




شکل 1- نمودار سری زمانی داده‌های مشاهداتی



شکل 2- سری زمانی جریان ماهانه رودخانه کارون در محل ایستگاه پل شالو بر کاغذ احتمالات نرمال



شکل 3- سری زمانی نرمال شده بر کاغذ احتمالاتی نرمال



شکل 4- همبستگی نگار (ACF) اطلاعات تاریخی

- تفاضل گیری و ایستاسازی سری زمانی

جهت ایستاسازی سری زمانی یک‌جا نرمال شده نیاز به بررسی ترکیبات مختلف فصلی و غیر فصلی تفاضل گیری سری زمانی می‌باشد. فرایند تفاضل گیری عبارت است از کم کردن عناصر سری زمانی از یکدیگر با زمان‌های تاخیر فصلی و غیر فصلی و سپس برآزش مدل سری زمانی بر سری تفاضل گیری شده حاصل و نهایتاً بازگشت به حالت ابتدایی از طریق فرآیند جمع بستن. این عمل موجب حذف عناصر غیر ایستاکننده سری زمانی می‌شود. بررسی‌ها نشان دهنده این است که ترکیب همزمان تفاضل گیری فصلی و غیر فصلی با گام یک، حالت تناوبی را به‌طور کامل حذف می‌نماید. همان‌طور که در شکل 7، ملاحظه می‌شود همبستگی نگار اطلاعات نرمال شده نشان دهنده ایستا شدن سری زمانی بر اثر تفاضل گیری همزمان فصلی و غیر فصلی با مرتبه یک است.

- تعیین مرتبه و معرفی مدل‌های کاندید


با توجه به اشکال توابع همبستگی نگار (ACF) و همبستگی نگار جزئی (PACF) سری‌های زمانی نرمال شده مرتبه‌های مندرج در جدول 1 برای مدل سری زمانی پیشنهاد می‌گردد. پسماندها که عبارتند از تفاوت بین مقادیر مشاهده شده و پیش‌بینی یا برآزش یافته، نشان دهنده آن بخش از مشاهدات هستند که توسط مدل ارایه شده قادر به بیان نمی‌باشند. به این ترتیب به‌نظر می‌رسد که بتوان مجموع مربعات پسماندها را به‌عنوان معیار انتخاب مدل در نظر گرفت. با بررسی مرتبه‌های کاندید شده در جدول 1 و معیار فوق مدل $ARIMA(0,1,1)^*(1,1,1)_2$ مورد توجه بیشتر قرار گرفت.

- آزمون‌های مختلف بر پسماندهای مدل‌های تحت بررسی


به‌منظور تعیین صحت و دقت مدل $ARIMA(0,1,1)^*(1,1,1)_2$ در پیش‌بینی جریان ماهانه ورودی به مخزن سد شهید عباسپور، آزمون‌هایی بر پسماندهای این مدل صورت پذیرفت. مهمترین آزمون مدل‌های فوق عبارت از تحقیق مستقل بودن پسماندها است. بررسی مذکور از طریق ترسیم توابع همبستگی نگار (ACF) و همبستگی نگار جزئی (PACF) و نیز ترسیم پسماندها بر کاغذ احتمالات نرمال انجام می‌گیرد. شکل‌های 8 و 9 دلالت بر اغتشاش خالص پسماندها دارند. به‌این‌صورت که کمترین مقدار خود همبستگی در زمان‌های تاخیر مختلف بر پسماندهای مدل منتخب، مشاهده می‌شود.

جدول ۱- مرتبه‌های پیشنهادی


مرتبۀ	میانگین متحرک (MA)	میانگین متحرک فصلی (SMA)	اتورگرسیو (AR)	اتورگرسیو فصلی (SAR)	تفاضل‌گیری غیر فصلی (d)	تفاضل‌گیری فصلی (D)
سری زمانی نرمال شده	0/1 و 2	12	0/1	0/1	1	1



شکل ۵- فاصله همبستگی نگار (ACF) اطلاعات نرمال شده با تفاضل‌گیری همزمان فصلی و غیر فصلی مرتبه یک



شکل ۶- همبستگی نگار پسماندهای مدل $ARIMA(0,1,1)*(1,1,1)_{12}$



شکل ۷- همبستگی نگار جزئی پسماندهای مدل $ARIMA(0,1,1)*(1,1,1)_{12}$ شبکه‌های عصبی مصنوعی (ANN)

دیدگاه جدید شبکه‌های عصبی در دهه 40 قرن بیستم شروع شد، زمانی که وارن مک کلاچ - والتر پیترز [3] نشان دادند که شبکه عصبی در اصل می‌تواند هر تابع حسابی و منطقی را محاسبه نماید. سیستم ANNs، که سعی در مدل کردن ساختار نرو- سیناپتیکی مغز دارد، یک مجموعه کاملاً ساده از واحدهای پردازش ساده می‌باشد، که این واحدها نیز توسط اتصالات واسطه فیلتر و تصحیح می‌گردند. آنچه شبکه محاسبه می‌نماید به وسیله طبیعت و توپولوژی اتصالات درونی میان پردازشگرهایش تعریف می‌شود. بعضی از انواع ANNs بطور اتوماتیک توان به دست آوردن انواع طراحی را دارند (حتی وقتی که تعداد اندازه‌گیری‌های همراه باخطا؛ در داده‌ها وجود داشته باشد). ANNs با داشتن ویژگی‌های حفظ تجربه، قابلیت یادگیری، قابلیت تعمیم‌دهی بر اساس فرایند درونیابی تحمل‌پذیری خطاها (مقاوم بودن)، سرعت عمل، سادگی، آموزش پذیری و خلاصه‌سازی، هم اکنون در رشته‌های مختلف علوم از جمله مهندسی عمران کاربرد دارد و استفاده از آن معمول است [3].

- فرایندهای مدل‌سازی شبکه‌های عصبی مصنوعی

با توجه به این‌که دوره آماری جریان ماهانه ورودی به مخزن سد شهید عباسپور یک سری زمانی هیدرولوژیک جریان رودخانه‌ای در مقابل زمان می‌باشد، در مدل‌سازی چنین مسایلی که با عمل پیش‌بینی یا تخمین همراه می‌باشد، شبکه‌های عصبی پیشخور چند لایه پرسترون پیشنهاد شده است [7]. در این تحقیق نیز از شبکه‌های عصبی پیشخور دو لایه پرسترون با الگوریتم آموزشی LM استفاده گردیده است. این الگوریتم یکی از الگوریتم‌های سریعی است که برای آموزش شبکه‌های پیشخور مورد استفاده قرار می‌گیرد. به‌طور کلی شبکه‌های عصبی پیشخور دارای سه لایه به نام‌های لایه‌های ورودی، میانی (پنهان) و خروجی می‌باشند. تعداد لایه‌های پنهان محدودیتی ندارد. در این شبکه‌ها نرون‌های هر لایه به نرون‌های لایه بعد از خود سیگنال می‌فرستند. هر نرون بردار ورودی را در وزن‌های خود ضرب کرده و با بایاس جمع می‌کند [1].

حاصل این عبارت یک ورودی خالص به تابع محرکه خواهد شد، که به صورت زیر بیان می‌شود:

$$net_j = \sum_{j=1}^n w_{ij} x_j + w_0 \quad (2)$$

که در آن:

net_j = ورودی خالص به تابع محرکه،

w_{ij} = ماتریس وزن‌های شبکه،

x_j = بردار ورودی به شبکه و


w_0 = بردار بایاس شبکه می‌باشد.

درون گره j یک تابع ریاضی F به نام تابع محرکه (فعالیت) وجود دارد که بر روی net_j عمل کرده و نتیجه به صورت Y_j از گره j خارج می‌شود. سپس خروجی Y_j از گره j به عنوان ورودی به گره‌های لایه بعدی فرستاده می‌شود اما پیش از ورود به گره‌های لایه بعد در وزن‌های اتصال مربوطه ضرب می‌شود و این گسترش اطلاعات تا رسیدن به لایه خروجی ادامه می‌یابد. خروجی لایه خروجی، نتیجه نهایی عکس‌العمل‌های شبکه عصبی در برابر ورودی به شبکه می‌باشد. تابع محرکه بر اساس نیاز مساله انتخاب می‌شود. در عمل تعداد محدودی از توابع محرکه مورد استفاده قرار می‌گیرند. در شبکه MLP به کار گرفته شده اکثراً از تابع محرکه لگاریتم سیگموئید (logsig) در

$$a = f(n) = \frac{1}{1 + e^{-cn}}, c > 0$$

لایه پنهان استفاده می‌شود. در تابع محرکه لگاریتم سیگموئید، دامنه ورودی نامحدود می‌باشد ولی خروجی آن محدود و بین $[0,1]$ و با فرمول زیر بیان می‌شود:

(3)



شکل 8- شبکه دو لایه پیشخور پرسپترون مورد استفا

مفهوم علایم به کار گرفته در شکل 8 عبارتند از:

a1: خروجی لایه پنهان

a2: خروجی شبکه

IW {1,1}: ماتریس وزن ورودی ها (Input weights)

LW{2,1}: ماتریس وزن لایه ها (Layer Weights) b : بردار بایاس

n1: ورودی خالص به تابع محرکه لایه پنهان و n2: ورودی خالص به تابع محرکه لایه خروجی

- تعمیم دهی در فرایند مدل سازی شبکه های عصبی مصنوعی

یکی از مشکلاتی که ممکن است در طول آموزش شبکه عصبی پیش آید پدیده بیش برآزش می‌باشد. در هنگام آموزش، خطا روی مجموعه آموزشی به سمت یک مقدار خیلی کوچک میل می‌کند اما زمانی که اطلاعات جدیدی به شبکه آموزش داده شده معرفی می‌شود یا در واقع هنگامی که شبکه در مرحله آزمون قرار می‌گیرد قادر به تعمیم دهی مدل به مجموعه داده های جدید نیست [7]. یکی از راه های بهبود تعمیم دهی در مرحله آموزش (با توجه به حجم اندک داده های آماری) کاهش تکرارها یا epoch ها در مرحله آموزش است. در واقع به دنبال یک آموزش اِپتیمم هستیم تا شبکه قادر به تعمیم مطلوب مدل در مرحله آزمون باشد، زیرا هر چه بیشتر میانگین مربع خطا MSE در مرحله آموزش به سمت صفر میل کند در مرحله آزمون جواب مطلوبی حاصل نخواهد شد [6].

- تعیین الگوی ورودی

برای تعیین بهترین الگوی ورودی به شبکه، عوامل مختلفی که ممکن است در پدیده موثر باشند باید در نظر گرفته شوند. بنابراین باید الگوهای ورودی مختلف را به شبکه عرضه نمود در نهایت با سعی و خطا از بین الگوهای مختلف الگویی که بهترین کارایی را ایجاد می‌کند به عنوان بهترین الگوی ورودی در نظر گرفته شود. در این تحقیق احتمال گام‌های زمانی مختلف شدت جریان ورودی به مخزن سد در طول دوره آماری 46 ساله برای مدل‌سازی جریان ماهانه ورودی به مخزن سد شهید عباسپور مورد بررسی قرار گرفت. الگوی کلی استفاده شده در این تحقیق به صورت زیر است:

(4)

$$Q(t) = F_{non}[Q(t-1), \dots, Q(t-n_q)] + e(t) \quad \text{که در آن:}$$

$Q(t)$ = جریان ورودی به مخزن سد در ماه t (آینده)

$Q(t-1)$ = جریان ورودی به مخزن در ماه قبلی

n_q = تعداد ماه‌های قبلی جریان‌های ورودی به مخزن سد که در شبیه‌سازی موثرند

$e(t)$ = تابع خطا که باید مینیمم شود

F_{non} = یک تابع خطی ناشناخته که به صورت نگاشت زیر عمل می‌کند،

(5)

$$F = R^p \rightarrow R$$

که در آن:

P = بعد بردار ورودی

مقدار n_q با سعی و خطا به دست می‌آید. به این صورت که با در نظر گرفتن مقادیر مختلف برای آن، الگوهای مختلف ساخته می‌شود، سپس شبکه عصبی با این الگوهای ورودی آموزش داده می‌شود و سرانجام کارایی شبکه‌ها بررسی می‌گردد. در این تحقیق بعد از سعی و خطاهای انجام شده بهترین الگوی ورودی برای پیش‌بینی جریان ماهانه ورودی به مخزن سد شهید عباسپور به صورت زیر به دست آمده:

$$Q(t) = F_{non}[Q(t-1), Q(t-2), \dots, Q(t-11)] \quad (6)$$

مدل مطلوب مدلی است دو لایه با 11 نرون ورودی (زمان تأخیر با گام 11)، 7 نرون در لایه اول و یک نرون در لایه خروجی با 500 تکرار دارد.

- نتایج

معیارهای زیر برای کارایی مدل‌ها و مقایسه نتایج به کار رفته است:

$SD = \sqrt{\frac{1}{N} \sum_{i=1}^N ((calc)_i - avg.calc)^2}$ <p>(7)</p>	انحراف معیار (SD)
$CV = \frac{SD}{avg.calc} (100)$ <p>(8)</p>	ضریب تغییرات (CV)
$SSE = \sum_1^N (pbs - calc)^2$ <p>(9)</p>	مجموع مربعات خطا (SSE)
$RMSE = \sqrt{\frac{\sum_1^N (obs - calc)^2}{N}}$ <p>(10)</p>	ریشه میانگین مربعات خطا (RMSE)
$R^2 = \frac{\sum_1^N (calc - avg.obs)^2}{\sum_1^N (obs - avg.obs)^2}$ <p>(11)</p>	ضریب همبستگی خطی (R ²)

در روابط فوق: calc = مقادیر محاسباتی، obs = مقادیر مشاهداتی، avg.calc = متوسط مقادیر محاسباتی، avg.obs = متوسط مقادیر مشاهداتی و N = تعداد داده‌ها می‌باشد. هرچه انحراف معیار کوچکتر باشد، میزان پراکندگی داده‌ها نسبت به میانگین کمتر می‌باشد. همچنین هرچه مقدار ضرایب تغییرات کمتر باشد، پراکندگی داده‌ها و در نتیجه دقت مدل بیشتر است. مقدار مطلوب برای SSE و نیز RMSE برابر با صفر و برای R² برابر با یک می‌باشد

جدول 2- مقایسه معیارهای عددی برای مقایسه نتایج


معیار مقایسه	مدل	SD	CV	SSE	RMSE	R ²
ANN		225/8	79/96	420741/157	83/74	0/94
ARIMA		202/5	78/7	281442/094	68/49	0/82

همان‌طور که در جدول 2 ملاحظه می‌گردد پنج معیار ذکر شده در بالا برای هر کلام از مدل‌های پیش‌بینی جریان کامل $ARIMA(0,1,1) \times (1,1,1)_2$ و شبکه عصبی پرسپترون دو لایه پیش‌خور با 11 بردار ورودی، 7 نرون در لایه مخفی و 500 تکرار محاسبه شده است. نتایج محاسبات نشان داد که مدل تک متغیره ARIMA علی‌رغم آن‌که دارای ساختاری خطی است اما پیش‌بینی بهتری را بر داده‌ها ارائه کرده است. به‌طور کلی نتایج پیش‌بینی به هنگام شده دلالت بر کارایی مدل مذکور در مدیریت مخزن دارد. بدون شک آن‌چه که از واژه پیش‌بینی در مطالعات هیدرولوژی مد نظر است ارائه مقادیری است که با توجه به سری زمانی جریان تاریخی، دارای بیشترین احتمال وقوع می‌باشند و به هیچ رو منظور ارائه مقادیر دقیق برای جریان‌های آینده نیست. چراکه با توجه به تغییر پذیری‌های شدید زمانی و مکانی پارامترهای هیدرولوژیک چنین ادعایی صرفاً به معنای عدم درک صحیح از چرخه پیچیده هیدرولوژی و

شرایط حاکم بر آن می‌باشد. به هر حال مطالعات محققین حاکی از این است که مقادیر حاصل از مطالعات نظیر، علی‌رغم عدم اطمینان‌های حاکم بر آنها، به گونه‌ای بسیار موثر در مدیریت کاراتر منابع آب تاثیر دارد [10].

- بحث و نتیجه‌گیری

در این تحقیق با بهره‌گیری از اطلاعات مشاهداتی در ایستگاه هیدرومتری پل شالو (به عنوان ورودی به مخزن سد شهید عباسپور) و با توسل به شیوه‌های آماری، مدل‌هایی به‌منظور پیش‌بینی جریان ماهانه ورودی به مخزن سد ارایه گردید. همان‌طور که در شکل‌های 9 و 11 ملاحظه می‌گردد پیش‌بینی برای سال‌های آبی 1377 تا 1382 صورت گرفته است. تبعیت مدل‌ها از فراز و نشیب‌های داده‌های تاریخی قابل قبول می‌باشد، اما مدل برازش یافته ARIMA شکل 11 مطابقت بیشتری با داده‌های تاریخی نشان می‌دهد. هرچند که در نقطه پیک هیدروگراف مقادیر مشاهداتی با هیدروگراف پیش‌بینی مدل ANNs شکل 9 نزدیکی بیشتری دارد ولی در قسمت بازوی پایین رونده مطابقت هیدروگراف پیش‌بینی ARIMA با داده‌های تاریخی بسیار بیشتر از مطابقت هیدروگراف خروجی شبکه‌های عصبی با داده‌های تاریخی می‌باشد. در ماه‌های 36 تا 48 که جریان ماهانه افزایش ناگهانی پیدا کرده، هر دو مدل ARIMA و ANN نتوانستند پیش‌بینی خوبی ارایه دهند این پدیده یکی از اشکالات عمده پیش‌بینی سری‌های زمانی هیدرولوژیک است که مدل‌های آماری در مقابل تغییرات ناگهانی نمی‌توانند برازش خوبی ارایه دهند. به‌منظور بررسی تأثیر تعداد داده‌های آماری بر افزایش کارایی و دقت مدل‌های جعبه سیاه در پیش‌بینی سری‌های زمانی جریان ماهانه سعی شده‌است تا علاوه بر آموزش مدل‌ها با 41 سال آمار سری زمانی جریان ماهانه این مدل‌ها با تعداد آمار بیشتری آموزش داده شود و اثر این افزایش آمار را بر روی دقت پیش‌بینی مدل‌های شبکه‌های عصبی و سری‌های زمانی (باکس - جنکینز) مشاهده گردد. در این راستا 45 سال آبی برای آموزش و تخمین پارامترهای مدل به عنوان مجموعه‌های آموزشی و یک سال آبی آخر (82-1381) به‌عنوان مجموعه آزمون مورد بررسی قرار گرفت. همان‌طور که در نمودارهای پیش‌بینی به هنگام شده شکل‌های 9 و 11، ملاحظه می‌گردد مدل‌هایی که از 41 سال داده برای آموزش و تخمین پارامترها بهره برده‌اند در مقایسه با مدل‌هایی که 45 سال داده برای آموزش آنها به‌کار رفته (نمودارهای پیش‌بینی به هنگام شده شکل‌های 10 و 12 از دقت پایین‌تری در پیش‌بینی سال آبی 1381 تا 1382 برخوردار می‌باشند. بنابراین افزایش آمار سری زمانی جریان ماهانه برای آموزش مدل‌های تک متغیره جعبه سیاه، کارایی این مدل‌ها را در پیش‌بینی‌های کوتاه مدت به طرز قابل ملاحظه‌ای افزایش می‌دهد.



- منابع

- 1- اس.وی، کارتالویوس، "منطق فازی و شبکه‌های عصبی (مفاهیم و کاربرد)"، مترجمان: محمود جوراییان، رحمت ا. هوشمند (1381). اهواز، دانشگاه شهید چمران.
- 2- جلال کمالی، ن. برهانی، ع (1380). "پیش‌بینی جریان ورودی به مخزن سد و نیار با استفاده از تئوری سری‌های زمانی برای بهره‌برداری از مخزن در شرایط اضطراری خشکی"، اولین کنفرانس بین‌المللی سازه‌های هیدرولیکی، ص 77-84.
- 3- مهدی زاده، م. (1383)، "شبکه‌های عصبی مصنوعی و کاربردهای آن در مهندسی عمران"، تبریز، نشر عبادی.
- 4- Bonafe, A., Galeati, G., and Sforna, M. (1994). "Neural networks for daily mean flow forecasting." Hydr. Engrg. Software V, W.R. Blain and K.L. Katsifarakis, eds., Computational Mechanics Publications, Southampton, U.K., 1, 131-138.
- 5- Dawson, C. W., and Wilby, R. (1998). "An artificial neural network approach to rainfall-runoff modeling." Hydrological Sci., 43(1), 47-66.
- 6- Kang, K. W., Kim, J. H., Park, C. Y., and Ham, K. J. (1993). "Evaluation of hydrological forecasting system based on neural network model." Proc., 25th Congress of Int. Assoc. for Hydr. Res., International Association for Hydraulic Research, Delft, The Netherlands, 257-264.
- 7- Karunanithi, N., Grenney, W. J., Whitley, D., and Bovee, K. (1994). "Neural networks for river flow prediction." J. Comp. in Civ. Engrg., ASCE, 8(2), 201-220.
- 8- Mari'a Castellano- Méndez,*, Wenceslao Gonza'lez- Manteiga, Manuel Febrero-Bande, Jose' Manuel Prada-Sánchez, Roma'n Lozano- Caldero'n. (2004). "Modelling of the monthly and daily behavior of the runoff of the Xallas river using Box-Jenkins and neural networks methods.", Journal of Hydrology 296 (2004) 38-58.
- 9- S.L. Ho, M. Xie, T.N. Goh, (2002). "A comparative study of neural network and Box-Jenkins ARIMA modeling in time series prediction.", Computers and Industrial Engineering, pp. 371-375.
- 10- Salas, J. D., Delleur, J. W., Yevjevich, V., and Lane, W. L. (1980). "Applied modeling of hydrologic time series.", Water Resources Publication, Littleton, Colo.
- 11- Martin T. Hagan, Mohammad B. Menhaj, (1994). "Training feed forward networks with the marquardt algorithm," IEEE Transactions on Neural Networks. vol. 5, no. 6, november..

