

مقایسه عملکرد مدل‌های شبکه عصبی و فازی در تعیین دبی ماهانه جریان با استفاده از آمار کوتاه مدت

صدیقه انوری^{۱*}، سعید مرید^۲ و بهرام تقفیان^۳

*- دانشجوی کارشناسی ارشد گروه سازه آبی، دانشگاه تربیت مدرس anvari@modares.ac.ir

۲- دانشیار گروه مهندسی منابع آب، دانشگاه تربیت مدرس

۳- استاد پژوهشکده حفاظت خاک و آبخیزداری

تاریخ پذیرش: ۸۹/۹/۲۷

تاریخ دریافت: ۸۸/۴/۱۲

چکیده

بهره‌برداری بهینه از سیستم‌های منابع آب و به خصوص تعیین زمان واقعی کارکرد مخازن سدها، مستلزم پیش‌بینی آورد رودخانه‌هاست. در این مقاله عملکرد مدل‌های منطق فازی (FL) و شبکه عصبی مصنوعی (ANN) برای پیش‌بینی یک و دو ماه بعد جریان حوضه کارون در محل ایستگاه هیدرومتری پل‌شالو با هم مقایسه شده است. در این راستا از سیستم استنتاجی ممدانی برای ساخت مدل‌های FL و همچنین شبکه‌های پیش‌رو سه لایه برای مدل‌سازی توسط ANN استفاده گردید. بررسی عملکرد این مدل‌ها با شاخص‌های ضریب تبیین (R^2)، میانگین قدر مطلق خطا (MAE) و ریشه میانگین مربعات خطا (RMSE) نشان داد که در شرایط کم بودن داده‌ها، مدل FL نسبت به مدل ANN در پیش‌بینی یک و دو ماه بعد جریان از نظر آماری عملکرد بهتری داشته است. این عملکرد بهتر به طور متوسط مقادیری برابر ۲۵٪ و ۷٪ را به ترتیب برای R^2 و RMSE در پیش‌بینی جریان اسفند ماه به همراه داشته است. نتایج بدست آمده از این دو مدل با مدل رگرسیون خطی چندگانه (MLR) نیز مقایسه گردید که عدم عملکرد مناسب آن را نشان می‌داد.

کلید واژه‌ها: پیش‌بینی جریان، منطق فازی، شبکه عصبی مصنوعی، رگرسیون خطی چندگانه

مقدمه

پیش‌بینی جریان ورودی به مخزن سد نقش اساسی در برنامه‌ریزی، بهره‌برداری و مدیریت بهینه از سیستم‌های منابع آب دارد. اما دوره پیش‌بینی بسته به رژیم رودخانه تفاوت می‌کند. برای سدی مانند کارون ۳ که بیشترین ورودی به آن در ماه‌های اسفند و فروردین اتفاق می‌افتد، پیش‌بینی آورد رودخانه در این ماه‌ها حائز اهمیت خواهد بود. بدین منظور، استفاده از مدل‌های رگرسیون و سری‌های زمانی از سابقه نسبتاً طولانی برخوردار است. تحقیقات نشان داده که بسیاری از این مدل‌ها روابط بین متغیرها را خطی فرض کرده و در مدل کردن پدیده‌های غیر خطی اغلب با

شکست مواجه می‌شوند [۶]. این مشکل باعث گشته که سیستم‌های فازی و مدل‌های شبکه عصبی مصنوعی، به عنوان مدل‌های غیر خطی برای پیش‌بینی بیشتر مورد توجه قرار گیرند [۶، ۱۳].

زیلند و همکاران [۱۷] عملکرد شبکه عصبی مصنوعی را با مدلی به نام ویفز^۱ که برای مدیریت منابع آب حوضه وینیپگ کانادا و پیش‌بینی ورودی‌های هفتگی جریان تا چهار هفته آینده مورد استفاده قرار گرفت، مقایسه کردند، نتایج حاکی از برتری عملکرد مدل‌های شبکه عصبی بود. کولیالی و همکاران [۱۰] جریان یک تا هفت روز بعد ورودی به سد حوضه چات

^۱ WIFFS

(شبکه عصبی، فازی و رگرسیون خطی) جهت پیش-بینی دانست و در نهایت علاوه بر تفاوت‌های ذکر شده، تاکید اصلی مقاله حاضر پیش‌بینی جریان در ماه‌های خاص بوده است که در این‌گونه پیش‌بینی‌ها، مدل در مرحله واسنجی، با الگوهای کمتری مواجه می‌شود. بررسی‌ها نشان داد که در تحقیقات کمی به طول الگوی آموزشی در شبیه‌سازی و همچنین انتخاب مدل‌ها پرداخته شده است [۱۷، ۱۰، ۱۶] که این مهم هدف عمده تحقیق حاضر را رقم می‌زند. لذا در این مقاله، جریان خروجی از حوضه کارون (محل ایستگاه پل شالو) در ماه‌های اسفند و فروردین که در مدیریت آبی، کشاورزی و تولید انرژی برقابی این حوضه نقش اساسی دارند، توسط مدل‌های شبکه عصبی مصنوعی و منطق فازی پیش‌بینی و عملکرد آن‌ها در شرایط وجود آمار کوتاه مدت در مرحله واسنجی با هم مقایسه شده است. همچنین نتایج بدست آمده با مدل رگرسیون خطی چند متغیره، به عنوان مدل جنبی مورد ارزیابی قرار گرفته است.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌ها

حوضه آبریز کارون در جنوب غرب ایران در حد فاصل طول شرقی $30^{\circ} 49'$ تا 52° و عرض شمالی 30° تا $30^{\circ} 32'$ قرار گرفته است. ارتفاع آن از سطح دریا در محل تقاطع با رودخانه دز حدود ۷۰ متر و تا ارتفاعات ۴۵۰۰ متری دنا و کوه‌رنگ ادامه می‌یابد. وسعت این حوضه تا محل ایستگاه پل شالو که در خروجی حوضه واقع است، حدود ۲۴۲۰۲ کیلومتر مربع می‌باشد (شکل ۱). آمار دما (میانگین و حداقل)، بارندگی و دبی ماهانه به مدت سی سال آبی (۱۳۸۲-۱۳۵۳) برای این حوضه در محل ایستگاه پل شالو، موجود می‌باشد. با توجه به تحقیقات انجام شده [۱]، آمار هواشناسی و هیدرومتری این ایستگاه معرف خوبی برای پیش‌بینی جریان حوضه می‌باشد، از این رو در مدل‌سازی، تنها به آمار این ایستگاه اکتفا می‌شود.

دو دیابل^۱ واقع در شمال کانادا را با استفاده از شبکه‌های عصبی پیش‌رو سه لایه پیش‌بینی کردند. همچنین عملکرد این مدل با مدل سری زمانی آرماکس^۲ و مدل بهره‌برداری از مخزن پرویس^۳ مقایسه شد که نتایج حاکی از برتری مدل شبکه عصبی در پیش‌بینی‌ها بوده است. هالید و رایید [۱۱]، از تکنیک منطق فازی برای پیش‌بینی بارندگی ماه ژانویه استفاده کردند. بدین صورت که با دو سری داده‌های ورودی شامل بارندگی ماه‌های نوامبر و دسامبر به عنوان سری اول، کل بارندگی فصل‌های گذشته هند به عنوان سری دوم و در نهایت بارندگی ماه ژانویه به عنوان خروجی، مدل‌سازی انجام شد. نتایج اجرای مدل‌های فازی، دلالت بر توانایی بیشتر مدل هنگامی که از داده‌های سری اول به عنوان ورودی استفاده می‌شود، دارد. چانگ و همکاران [۹]، از یک مدل جدید فازی به نام FEIS^۴ برای پیش‌بینی سیل رودخانه لان-یانگ^۵ در تایوان استفاده و عملکرد این مدل را با مدل‌های شبکه عصبی مقایسه کردند. نتایج حاکی از عملکرد بهتر مدل FEIS نسبت به مدل شبکه عصبی در پیش‌بینی سیلاب بوده است. الویسی و همکاران [۵]، از دو مدل منطق فازی (ممدانی و سوگونو) و یک مدل شبکه عصبی مصنوعی برای پیش-بینی تراز سطح آب رودخانه رنو^۶ واقع در ایتالیا استفاده کردند. نتایج تحقیقات نشان داد که دو مدل بر مبنای منطق فازی، عملکردی بهتر از مدل شبکه عصبی داشته است.

با توجه به مطالب بالا و بررسی سایر منابع، تفاوت سوال این تحقیق با تحقیقات انجام شده دیگر را می‌توان مربوط به در نظر گرفتن نوع متغیر پیش‌بینی (جریان رودخانه)، نوع متغیرهای پیشگو (متغیرهای هواشناسی و هیدرومتری) و مدل‌های بکار گرفته شده

¹ Chute- du-Diable

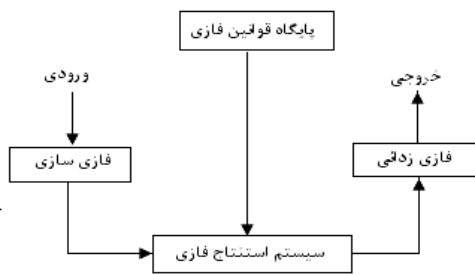
² ARMAX

³ PREVIS


⁴ Fuzzy Exemplar – Based Inference system

⁵ Lan-Yang

⁶ Reno



شکل ۲- شمای کلی یک سیستم فازی [۱۵]



شکل ۱- موقعیت منطقه مورد مطالعه

مجموعه‌های فازی است و سیستم استنتاجی سوگنو که ورودی این سیستم مجموعه‌های فازی ولی خروجی حقیقی آن به صورت ترکیب خطی از ورودی‌هاست. شکل ۳ شمای کلی سیستم استنتاج فازی ممدانی را نشان می‌دهد.

- غیر فازی ساز^۴: نتایج استنتاج فازی را به خروجی‌های حقیقی تبدیل می‌کند. متداول‌ترین روش غیر فازی کردن، روش مرکز ثقل است [۵] که در آن با استفاده از رابطه زیر خروجی‌های حقیقی مدل فازی بدست می‌آید:

$$z^* = \frac{\int (\mu_B(z) \cdot z) dz}{\int (\mu_B(z)) dz} \quad (۱)$$

مدل منطق فازی (FL)

مدل منطق فازی یک فرایند ریاضی-منطق است که می‌تواند عدم قطعیت‌ها و عدم صراحت‌های موجود در دنیای واقعی را با استفاده از سیستم قواعد اگر-آنگاه فازی مدل‌سازی کند [۴].

سیستم قواعد فازی متشکل از چهار مؤلفه اصلی شکل ۲ است که در ادامه تشریح می‌گردد.

فازی سازی داده‌های ورودی^۱: فرآیندی است که ورودی‌های حقیقی را با استفاده از توابع عضویت به ورودی‌های فازی تبدیل می‌کند زیرا ایده اصلی در منطق فازی آنست که بجای تعلق کامل به یک مجموعه، به هر داده اجازه تعلق جزئی به چندین زیرمجموعه از یک مجموعه کلی را می‌دهد [۱۵]. توابع مثلثی و ذوزنقه‌ای از جمله توابع عضویت مرسوم هستند که در کاربردهای مهندسی استفاده می‌شوند [۴].

- قواعد فازی^۲: شامل عبارت‌های اگر-آنگاه است که متغیرهای ورودی را به متغیرهای خروجی ارتباط می‌دهد.

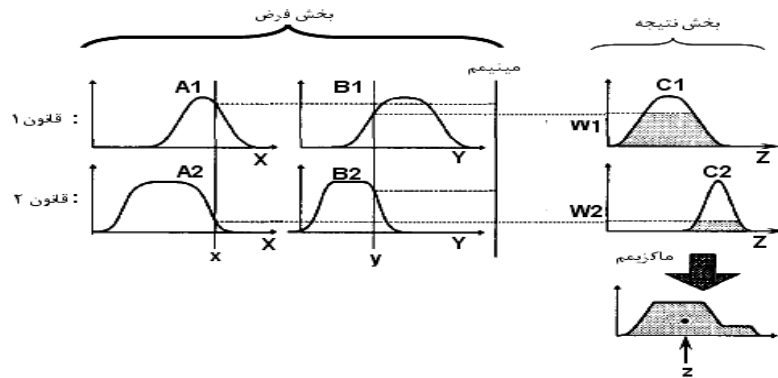
- سیستم استنتاج فازی (FIS)^۳: فرایندی که طی آن خروجی قواعد فازی با هم ترکیب و خروجی کلی سیستم بدست می‌آید، دو نوع FIS که عمدتاً در تحقیقات مختلف استفاده شده شامل سیستم استنتاج فازی ممدانی که ورودی و خروجی این سیستم،

^۱ Fuzzification

^۲ Fuzzy Rules

^۳ Fuzzy Inference System

^۴ Defuzzification



شکل ۳- شمای کلی سیستم استنتاج فازی مدانی [۱۲]

در رابطه بالا z عددی فازی، $\mu_B(z)$ درجه عضویت مربوط به آن و z^* خروجی حقیقی می باشد.

مدل های شبکه عصبی مصنوعی (ANN)^۱ یک سیستم پردازشگر توزیعی اطلاعات است و گسترش آن بدین گونه است که پردازش اطلاعات در واحدهایی به نام نرون انجام می شود. نرون ها با اتصالات^۲ وزن دار بهم وصل می شوند هر نرون مجموع وزنی سیگنال های ورودی را با بکار بردن یک تبدیل غیر خطی موسوم به تابع تحریک^۳، به سیگنال خروجی تبدیل می کند [۷]. کاربردی ترین نوع شبکه های عصبی، شبکه های پیشرو سه لایه هستند [۱۰]. تعداد نرون های موجود در لایه ورودی و خروجی، بستگی به نوع مسئله دارد ولی تعداد نرون های لایه پنهان با سعی و خطا بدست می آید. شمای کلی و سایر جزئیات مربوط به این مدل ها را می توان در مراجع [۵، ۷، ۱۰، ۱۴] مشاهده کرد.

$$R^2 = \frac{\left[\sum_{i=1}^n (Q_i^o - \bar{Q}^o)(Q_i^e - \bar{Q}^e) \right]^2}{\sum_{i=1}^n (Q_i^o - \bar{Q}^o) \sum_{i=1}^n (Q_i^e - \bar{Q}^e)} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_o - Q_e| \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_o - Q_e)^2} \quad (4)$$

در روابط بالا Q_o دبی مشاهده ای، Q_e دبی برآورد شده توسط مدل ها، n تعداد داده ها، \bar{Q}^o میانگین دبی های مشاهده ای و \bar{Q}^e میانگین دبی های محاسباتی است. دبی های مذکور همگی در مقیاس ماهانه هستند. همچنین در این مقاله از شاخص گرافیکی خط ۴۵ درجه که میزان خطای برآورد را بین دبی های مشاهده ای و دبی های تخمینی به صورت کیفی نشان می دهد، نیز استفاده شده است.

آماده سازی مدل پیش بینی

انتخاب ورودی های مناسب، تعیین دوره های آموزش و آزمون، پیش پردازش داده های ورودی به مدل ANN، تعیین ساختار مدل های مورد استفاده در این تحقیق و ارائه نتایج بدست آمده از آنها، از جمله مواردی است که در ادامه تشریح می گردد:

ارزیابی مدل ها

جهت ارزیابی عملکرد مدل ها در این تحقیق، از شاخص هایی همچون ضریب تبیین (R^2)، میانگین خطای مطلق (MAE) و ریشه میانگین مربعات خطا

¹ Artificial Neural Network

² Links

³ Activation Function

انتخاب متغیرهای ورودی

انتخاب مناسب ورودی‌ها نکته مهمی است که قبل از اجرای هر مدل باید به آن توجه شود. در این مقاله برای انتخاب ورودی‌ها از روش همبستگی متقابل (CC)^۱ استفاده شد که در تحقیقات مشابه مانند [۸]، گزارشات مثبتی از آن ارائه شده است. در این روش بین متغیرهای مستقل (مانند متغیرهای هواشناسی) و متغیرهای وابسته (دبی) همبستگی گرفته شد و مواردی که سطح معنی‌داری^۲ ضریب همبستگی در آن‌ها کمتر از ۰/۰۵ باشد، به عنوان ورودی مدل‌ها انتخاب شدند. لازم به ذکر است که این سطح معنی‌داری در اکثر کارهای هیدرولوژیکی معیار قرار می‌گیرد [۳، ۲]. بدین ترتیب بین متغیرهای مستقل یعنی بارندگی، دمای حداقل، دمای میانگین و دبی و هر یک برای ماه‌های آبان، آذر، دی و بهمن (در مجموع ۱۶ متغیر مستقل) و همچنین دبی ماه‌های اسفند و فروردین (دو متغیر وابسته) به طور جداگانه همبستگی دو به دویی برقرار

^۱ Cross Correlation

^۲ Significant Level (Sig)

جدول ۱- ضریب همبستگی متغیرهای ورودی برای پیش‌بینی جریان ماه اسفند

ورودی‌ها	ضریب همبستگی	سطح معنی‌داری
دمای میانگین دی	-۰/۴۴۵	۰/۰۱۴
دمای حداقل آذر	-۰/۴۳۷	۰/۰۱۶
دبی بهمن	۰/۴۸۶	۰/۰۰۷

جدول ۲- ضریب همبستگی متغیرهای ورودی برای پیش‌بینی جریان ماه فروردین

ورودی‌ها	ضریب همبستگی	سطح معنی‌داری
دمای میانگین دی	-۰/۵۲۳	۰/۰۰۳
دمای حداقل آذر	-۰/۳۶۰	۰/۰۴۹
دبی بهمن	۰/۴۸۴	۰/۰۰۷

[۱۴، ۱۷]. در این تحقیق به دلیل استفاده از تابع سیگموئیدی با خروجی‌های بین صفر و یک و نیز با بررسی منابع، داده‌های ورودی و خروجی توسط رابطه زیر در محدوده [۰/۱-۰/۹] تغییر مقیاس یافتند [۱۶، ۱۷]:

$$X_n = 0.8 \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) + 0.1 \quad (5)$$

در این رابطه، X_{\min} کم‌ترین مقدار متغیرهای ورودی، X_{\max} بیشترین مقدار متغیر ورودی و X_n تغییر مقیاس یافته متغیر X است.

مشخصات مدل‌های فازی

نکته اصلی در طراحی مدل‌های فازی تعیین نوع سیستم استنتاج فازی (FIS) است. در این مقاله از FIS ممدانی استفاده و بعد از شناسایی ورودی‌ها، برای مدل‌سازی گام‌های استنتاجی ذیل طی شد:

- کلاسه‌بندی متغیرهای ورودی و خروجی با توجه به توزیع فراوانی داده‌های مشاهده‌ای [۴] و نظرات کارشناسی در سه دسته: کم^۱، متوسط^۲ و زیاد^۱. بدین

گردید، سپس متغیرهای فوق مطابق با آنچه که در جداول ۱ و ۲ آمده‌اند، به عنوان ورودی مدل‌های شبکه عصبی، فازی و رگرسیون خطی انتخاب شدند. این متغیرها برای پیش‌بینی دبی ماه‌های اسفند و فروردین شامل دبی بهمن (Q- bahman)، دمای حداقل آذر (Tmin-azar) و دمای میانگین دی (Tmean-dey) بود. ضریب همبستگی بین هر یک از متغیرهای پیشگو و متغیر پیش‌بینی به همراه سطح معنی‌داری آن‌ها، در جداول ۱ و ۲ آورده شده است.

معماری مدل ANN و پیش پردازش ورودی‌ها

با توجه به اینکه بیش از ۹۰٪ شبکه‌های عصبی کاربردی در هیدرولوژی، شبکه‌های پیشرو با یک لایه پنهان هستند [۷، ۱۰]، در این مقاله نیز، از این شبکه‌ها استفاده گردید. همچنین با انجام سعی و خطا بر روی معماری و توابع مدل‌های شبکه عصبی، تابع تحریک سیگموئیدی به دلیل ارائه نتایج بهتر، مورد استفاده قرار گرفت.

به منظور اجتناب از اشباع سیگنال خروجی و کوچک شدن بیش از حد وزن‌های شبکه، داده‌های ورودی و خروجی باید در محدوده‌ای خاص، بسته به نوع تابع تحریک استفاده شده در شبکه، تغییر شکل پیدا کنند

¹ Low

² Medium

برای آزمون مدل‌ها انتخاب شدند. پارامترهای آماری متغیرهای پیشگو و پیش‌بینی برای این دوره‌ها در جدول ۳ آمده است.

منظور با محاسبه میانگین و انحراف معیار مربوط به هر متغیر، اعدادی که پراکنش آن‌ها با انحراف معیار مثبت یا منفی کمی از میانگین فاصله داشت در دسته متوسط، اعدادی که پراکنش آن‌ها با انحراف معیار مثبت زیادی از میانگین فاصله داشت در دسته زیاد و در نهایت اعدادی که پراکنش آن‌ها با انحراف معیار منفی زیادی از میانگین فاصله داشت در دسته کم قرار گرفت.

- مقایسه متغیرهای ورودی با تابع عضویت مثلثی مربوط به هر کلاس: علت انتخاب این نوع تابع عضویت، کم بودن پارامترهای تابع و کاربرد بیشتر آن است [۴، ۵].

- استخراج قوانین اگر- آنگاه مناسب با استفاده از داده‌های تاریخی مشاهداتی.

- ترکیب مقادیر عضویت روی بخش فرض توسط عمل گر AND، انجام عملیات استنتاج و غیر فازی کردن به روش مرکز ثقل.

مدل‌های رگرسیون خطی چندگانه (MLR)^۲

برای پیش‌بینی جریان هر ماه توسط این مدل‌ها با استفاده از داده‌های دوره واسنجی، بین متغیرهای پیشگو و پیش‌بینی، یک مدل خطی چند متغیره برآزش یافته و سپس عملکرد این مدل با داده‌های دوره آزمون مورد ارزیابی قرار گرفت.

تعیین دوره‌های آموزش و آزمون

در هر سه مدل مورد استفاده در این مقاله، داده‌های ۲۰ سال ابتدای دوره آماری (۷۲-۱۳۵۳) برای آموزش و داده‌های ۱۰ سال آخر (۸۲-۱۳۷۳)

¹ High

² Multiple Linear Regression

جدول ۳- مشخصات آماری متغیرهای پیشگو و پیش‌بینی برای دوره‌های آموزش و آزمون مدل‌ها

پارامترهای آماری	مرحله آموزش					مرحله آزمون				
	دمای میانگین دی (°C)	دمای حداقل آذر (°C)	دبی بهمن (m ³ /s)	دبی اسفند (m ³ /s)	دبی فروردین (m ³ /s)	دمای میانگین دی (°C)	دمای حداقل آذر (°C)	دبی بهمن (m ³ /s)	دبی اسفند (m ³ /s)	دبی فروردین (m ³ /s)
میانگین	۹/۸	۷/۲	۳۷۸/۹	۵۹۹/۴	۷۸۱/۴	۱۱/۰	۸/۵	۳۲۷/۵	۴۷۶	۶۴۸/۲۰
انحراف	۱/۳	۱/۳	۱۷۳/۳	۳۰۹/۴	۲۷۴/۱۰	۱/۵	۱/۵۰	۱۵۶/۳	۱۸۸/۱	۲۷۳/۵
مینیم	۷/۸	۴/۵	۱۶۵/۴	۲۲۵/۶	۴۱۵/۷	۸/۵	۵/۶۰	۱۲۴/۸	۲۰۹/۶۰	۲۹۶/۹
ماکزیم	۱۲/۷	۹/۴	۹۰۱/۳	۱۴۹۶/۹	۱۵۸۷/۵	۱۳/۲	۱۰/۶۰	۵۹۳/۱	۷۲۷/۲۰	۱۱۶۲/۷

داده‌های مشاهداتی، بعضی از داده‌ها در دو کلاس قرار می‌گرفتند، مثلاً در دومین قانون این جدول، برای دمای میانگین ماه دی و حداقل ماه آذر، دو کلاس کم و متوسط وجود داشت که با سعی و خطا و همچنین در نظر گرفتن شاخص‌های ارزیابی مدل‌ها، کلاس کم، مناسب‌تر شناخته شد. در نتیجه سعی و خطا روی کلاس‌های هر متغیر نیز انجام گرفت و در نهایت، عملکرد سه مدل ANN، FL و MLR با ورودی‌های مشابه بررسی شد که نتایج حاصل در جدول ۵ آمده است.

در ادامه نتایج مدل‌های شبکه عصبی، منطق فازی و رگرسیون خطی چندگانه که از این به بعد در متن مقاله به ترتیب به صورت ANN، FL، MLR نمایش داده می‌شوند ارائه می‌گردد.

نتایج

نتایج پیش‌بینی جریان اسفند ماه

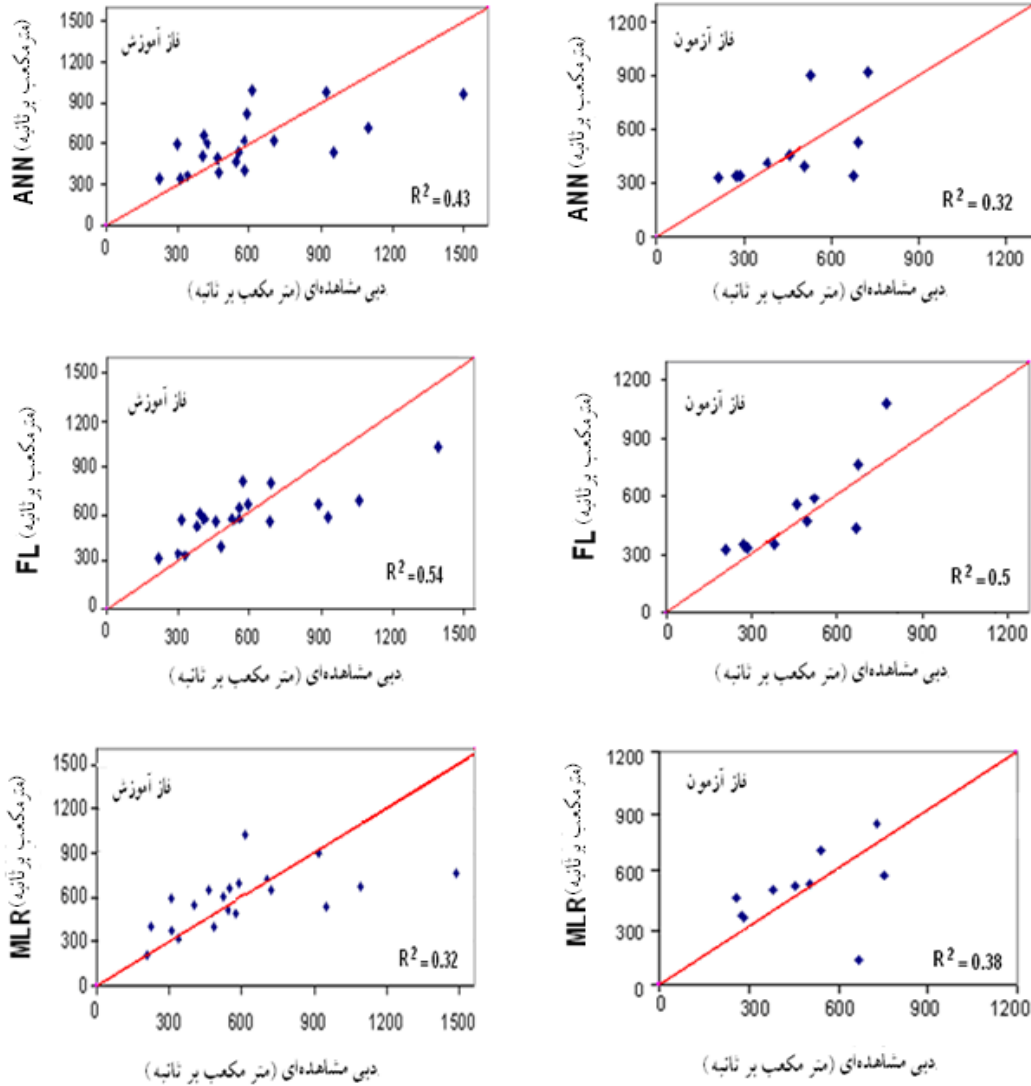
برای پیش‌بینی جریان ماه اسفند تعداد نرون‌های لایه پنهان در مدل ANN با سعی و خطا ۲ و قوانین استخراج شده برای مدل FL مطابق جدول ۴، بدست آمد. همچنین پارامترهای توابع عضویت و میزان همپوشانی آن‌ها با سعی و خطا حاصل شد [۴]. لازم به ذکر است که در استخراج قوانین جدول ۴ به وسیله

جدول ۴ - قوانین استخراج شده برای پیش‌بینی جریان ماه اسفند به وسیله مدل FL

فراوانی	بخش نتیجه (آنگاه)		بخش فرض (اگر)	
	دبی اسفند	دبی بهمن	دمای حداقل آذر	دمای میانگین دی
۳	متوسط	کم	متوسط	کم
۲	متوسط	زیاد	کم	کم
۱	کم	کم	متوسط	کم
۴	متوسط	متوسط	متوسط	متوسط
۱	متوسط	متوسط	کم	کم
۱	متوسط	کم	کم	متوسط
۲	متوسط	کم	زیاد	متوسط
۱	متوسط	متوسط	متوسط	متوسط
۲	متوسط	کم	کم	متوسط
۱	زیاد	متوسط	متوسط	کم
۱	کم	متوسط	متوسط	زیاد
۱	کم	کم	زیاد	زیاد

جدول ۵- نتایج مدل‌های ANN، FL و MLR در پیش‌بینی جریان ماه اسفند

مدل	آموزش			آزمون			
	RMSE	R ²	MAE	RMSE	R ²	Sig	MAE
ANN	۲۲۶/۹	۰/۴۳	۱۷۰/۱۴	۱۸۸/۹	۰/۳۲	۰/۰۹	۱۴۴/۸۴
FL	۲۱۴/۶۱	۰/۵۴	۱۵۹/۰۸	۱۹۷/۷۶	۰/۵	۰/۰۲۲	۱۳۱/۹۶
MLR	۲۴۸/۷۱	۰/۳۲	۱۷۰/۳	۱۵۸/۵۶	۰/۳۸	۰/۰۶	۱۰۲/۱۷



شکل ۴- نتایج مدل‌های ANN، FL و MLR در مرحله آموزش و آزمون برای پیش‌بینی جریان ماه اسفند

عملکرد را داشته است. شکل ۴ نیز نتایج عملکرد این سه مدل را نشان می‌دهد. همان‌طور که مشاهده می‌شود تمام مدل‌ها در دبی‌های کم عملکردی تقریباً مشابه

همان‌طوری که از جدول ۵ پیداست مدل FL، با توجه به شاخص‌های RMSE، MAE و معنی‌دار بودن ضریب تبیین آن (Sig = 0.022) در پیش‌بینی جریان اسفند ماه بهترین

یادآوری می شود هنگامی که مقدار آماره t ، بزرگتر از عدد جدول باشد فرض صفر (یعنی صفر بودن مقدار ثابت یا ضرایب رگرسیونی) رد می شود. با توجه به مشخصات آماری مذکور و همچنین جدول ۵، پیداست که مدل رگرسیونی ماه اسفند برای پیش بینی جریان این ماه از اعتبار لازم برخوردار نبوده است. در ادامه نیز عملکرد سه مدل ANN، FL و MLR برای پیش بینی جریان اسفند ماه با شکل (۴) نمایش داده شده است.

نتایج مدل های ANN، FL و MLR در پیش بینی جریان ماه فروردین

برای پیش بینی جریان ماه فروردین، تعداد نرون های لایه پنهان در مدل ANN با سعی و خطا ۲ و قوانین استخراج شده برای مدل FL، مطابق جدول ۶ بدست آمد.

در نهایت، عملکرد سه مدل ANN، FL و MLR با ورودی های مشابه مورد بررسی قرار گرفت که نتایج حاصل در جدول ۷ آمده است.

داشتند و تفاوت عملکرد آنها عمدتاً در دبی های زیاد است که مدل FL برای این دبی ها قابلیت بهتری داشته است. این بدان علت می باشد که در مدل سازی به روش FL برای الگوهایی با دبی های زیاد هم قوانین جداگانه ای وجود دارد، اما ANN تنها تابع مشاهدات و وزن های شبکه است که اتکا به مشاهدات دارد. نتایج مدل MLR نیز نشان دهنده عدم عملکرد مناسب این مدل برای پیش بینی جریان بود. معادله ۶ و توضیحات بعد آن، رابطه و مشخصات آماری مدل رگرسیونی پیش بینی جریان ماه اسفند را نشان می دهد:

$$Q_{Esf} = 1074 - 75.1 \times T_{mean.dey} - 2.8 \times T_{min.azar} + 0.741 \times Q_{bahman} \quad (۶)$$

$$R^2 = 0.32$$


در این رابطه آماره t برای مقدار ثابت رگرسیون و نیز هر یک از متغیرهای $T_{min.azar}$ ، $T_{mean-dey}$ و Q_{bahman} به ترتیب $1/8$ ، $-1/33$ ، $-0/04$ ، $1/82$ تعیین گردید. با استفاده از جدول t ، برای سطح معنی داری ۵٪ و درجه آزادی ۱۶ ($n-4$) داریم $t_{(0.975,16)} = 2.12$. مقایسه بین آماره ها و مقدار بدست آمده از جدول نشان می دهد که مقدار ثابت رگرسیون و سه متغیر دیگر رابطه، معنی دار نمی باشند.

جدول ۶ - قوانین استخراج شده توسط مدل FL برای پیش بینی جریان ماه فروردین

بخش نتیجه (آنگاه)			بخش فرض (اگر)		فراوانی
دبی فروردین		دبی بهمن	دمای حداقل آذر	دمای میانگین دی	
کم	کم	کم	متوسط	کم	۳
متوسط	متوسط	زیاد	کم	کم	۱
متوسط	متوسط	متوسط	متوسط	متوسط	۲
متوسط	متوسط	متوسط	متوسط	متوسط	۶
زیاد	زیاد	متوسط	کم	کم	۱
متوسط	متوسط	متوسط	زیاد	زیاد	۱
کم	کم	کم	متوسط	متوسط	۱
متوسط	متوسط	کم	زیاد	متوسط	۲
کم	کم	متوسط	متوسط	متوسط	۱
زیاد	زیاد	متوسط	متوسط	کم	۱
کم	کم	متوسط	متوسط	زیاد	۱

جدول ۷- نتایج مدل‌های ANN، FL و MLR در پیش‌بینی جریان ماه فروردین

مدل	آموزش			آزمون			
	RMSE	R ²	MAE	RMSE	R ²	Sig	MAE
ANN	۱۹۸/۱۸	۰/۴۸	۱۷۲/۱۸	۲۱۷/۹۶	۰/۳۱	۰/۱۰	۱۹۹/۵۵
FL	۲۰۶/۲	۰/۴۶	۱۷۲/۳۱	۲۶۳/۰	۰/۴۵	۰/۰۳	۲۱۹/۸۲
MLR	۲۱۷/۴۴	۰/۳۰	۱۸۶/۵۵	۲۰۵/۳۱	۰/۵۲	۰/۰۶۷	۱۹۲/۵۶



شکل ۵- پیش‌بینی جریان ماه فروردین توسط مدل‌های ANN و FL

Qbahman به ترتیب ۲/۳۹، -۱/۳۱، -۰/۲، ۱/۸۴،

تعیین

گردید. با استفاده از جدول t، برای سطح معنی‌داری ۵٪ و درجه آزادی ۱۶ (n-4) داریم $t_{(0.975,16)} = 2.12$. مقایسه بین آماره‌ها و مقدار بدست آمده از جدول نشان می‌دهد که بجز مقدار ثابت رگرسیونی، سه متغیر دیگر رابطه، معنی‌دار نمی‌باشند. با توجه به مشخصات آماری مذکور و شاخص‌های موجود در جدول ۷، پیداست که این مدل رگرسیونی جهت پیش‌بینی جریان ماه فروردین، از اعتبار کافی برخوردار نیست.

نتایج مدل MLR برای پیش‌بینی جریان ماه‌های اسفند و فروردین، نشان داد که این مدل عملکرد مناسبی در پیش‌بینی‌ها نداشته است لذا از تحلیل‌های بعدی حذف می‌گردد.

مقایسه نتایج مدل‌های ANN و FL در پیش‌بینی جریان ماه‌های اسفند و فروردین

مقایسه عملکرد دو مدل ANN و FL برای پیش‌بینی جریان نشان داد که مدل FL با وجود شرایط


نتایج جدول ۷ حاکی از آنست که مدل FL روند جریان را بهتر از ANN مدل کرده است. همچنین مدل ANN در مرحله آزمون عملکرد ضعیف‌تری نسبت به مرحله آموزش داشته و خطای فوق‌برازشی در آن اتفاق افتاده است. از طرف دیگر در ایجاد قوانین فازی علاوه بر در نظر گرفتن آمار موجود، نظرات کارشناسی هم دخیل بوده است که این خود عاملی است که می‌تواند بهبود عملکرد آن را نسبت به مدل ANN سبب شود. عملکرد این دو مدل برای پیش‌بینی جریان ماه فروردین در شکل ۵ آمده است.

معادله ۷ نیز رابطه مدل رگرسیونی پیش‌بینی جریان ماه فروردین را نشان می‌دهد:

$$Q_{Far} = 1249 - 64.7 \times T_{mean.dey} - 11.2 \times T_{min.azar} + 0.653 \times Q_{bahman} \quad (7)$$

$$R^2 = 0.3$$

در این رابطه آماره t برای مقدار ثابت رگرسیون و نیز هر یک از متغیرهای Tmean-dey، Tmin.azar و



شکل ۶- نمودار توزیع خطای مدل های ANN و FL در پیش بینی جریان ماه اسفند

MLR برای پیش بینی های ذکر شده، مورد ارزیابی قرار گرفتند. همچنین جهت واسنجی مدل های مذکور، از داده های ماهانه بارندگی، دبی و دمای ایستگاه پل شالو به مدت ۳۰ سال آبی استفاده گردید که نتایج زیر از اجرای مدل ها قابل ارائه می باشد:

- از مجموع متغیرهای دبی، بارندگی، دمای حداقل و میانگین (برای ماه های آبان تا بهمن)، دبی ماه بهمن، دمای میانگین ماه دی و دمای حداقل ماه آذر به عنوان بهترین متغیرهای ورودی در پیش بینی جریان ماه های اسفند و فروردین انتخاب شدند.

- با استفاده از توزیع فراوانی متغیرهای ورودی، تعداد سه کلاس کم، متوسط و زیاد برای ساختن قوانین سیستم استنتاج فازی مناسب شناخته شد.

- با انجام سعی و خطا بر روی ساختار و معماری مدل های ANN، تابع تحریک سیگموئیدی و همچنین تعداد ۲ نرون در لایه پنهان، بهترین نتایج را برای این مدل ها به دنبال داشت.

- با انجام آنالیز CC و همچنین سعی و خطا، مشاهده شد که متغیرهای دمایی حوضه، بیشترین تاثیر را بر جریان ماه های اسفند و فروردین داشته اند که این با توجه به برف گیر بودن حوضه قابل تفسیر است.

- شاخص های میانگین خطا نشان داد که در پیش بینی جریان ماه خاص و شرایط مواجهه با الگوهای کم آموزشی، مدل FL نسبت به مدل ANN و MLR عملکرد بهتری داشته است و این برتری عملکرد با سایر تحقیقات انجام شده توسط ANN و FL مشابهت دارد [۵، ۹].

کم داده در پیش بینی یک و دو ماه بعد جریان بهتر از مدل ANN عمل کرده است که این برتری در مراجع دیگر هم گزارش شده است [۵، ۹].

در ادامه نتایج مدل های ANN و FL با استفاده از رسم نمودار توزیع خطا [۱۳] نیز ارزیابی و نتایج آن برای ماه اسفند در شکل ۶ ارائه شده است. در این شکل، محور افقی قدر مطلق خطای نسبی (بر حسب درصد) است که از تقسیم قدر مطلق خطا بر مقادیر مشاهده شده بدست می آید و محور عمودی نیز فراوانی تجمعی است. با توجه به این شکل، مدل FL برای ۴۰ درصد داده ها، خطایی برابر ۱۲ درصد ولی مدل ANN خطایی برابر با ۲۰ درصد را در پیش بینی جریان ماه اسفند به همراه داشته است. همچنین برای ۹۰ درصد داده ها مدل FL خطایی برابر ۵۰٪ را دارا بوده و این در حالیست که مدل ANN خطایی برابر با ۶۲ درصد را در پیش بینی جریان این ماه به همراه داشته است. بنابراین نمودار توزیع خطا، همانند معیارهای RMSE، MAE و R^2 که شاخص های میانگین خطا هستند، موید آن بود که مدل FL در پیش بینی جریان ماه اسفند، عملکرد بهتری نسبت به مدل ANN داشته است.

نتیجه گیری

مقاله حاضر تلاشی بود برای پیش بینی جریان ماه های فروردین و اردیبهشت رودخانه کارون که در بهره برداری سد کارون ۳ از اهمیت زیادی برخوردار است. با توجه به نوع مسئله و سوال آن، تحقیق با تعداد محدودی الگوی آموزشی مواجه شد از اینرو مدل های ANN، FL و

خطای زیادی همراه بود که در این خصوص استفاده از تکنیک‌های خوشه‌بندی جهت استخراج قوانین و یا استفاده از مدل‌های نرو فازی برای ادامه کار قابل پیشنهاد می‌باشد. همچنین با توجه به برفی بودن منطقه مطالعاتی، احتمال ارتقاء نتایج با بارگیری سری کامل داده‌های تاریخی سطح برف حاصل از تصاویر ماهواره‌ای به عنوان ورودی مدل‌ها وجود خواهد داشت.

- نمودارهای توزیع خطا نشان داد که به ازای ۹۰ درصد از جریان‌های پیش‌بینی شده در ماه اسفند، مدل FL دارای خطای نسبی برابر با ۵۰ درصد بوده ولی مدل ANN برای همین پیش‌بینی‌ها خطایی برابر با ۶۲ در صد را به همراه داشته است در نتیجه نمودارهای توزیع خطا نیز همانند شاخص‌های متوسط خطا عملکرد بهتر مدل FL را تایید می‌کنند.

- علیرغم کارکرد بهتر مدل فازی نسبت به مدل‌های شبکه عصبی و رگرسیون چند متغیره در این تحقیق، پیدا کردن قوانین مدل فازی بسیار زمان‌بر و با سعی و

مراجع

۱. انوری، ص. ۱۳۸۷. ارتقاء عملکرد مدل‌های هوشمند جهت پیش‌بینی جریان رودخانه با استفاده از داده‌های توزیع مکانی اقلیمی و سطح برف. پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه تربیت مدرس، ۱۴۵ ص.
۲. شریفی، م. ر.، آخوند علی، ع. م.، پرهت، ج. و ج. محمدی. ۱۳۸۶. ارزیابی دو روش معادله همبستگی خطی و کریجینگ معمولی به منظور برآورد توزیع مکانی عمق برف در حوزه آبخیز صمصامی. مجله علوم و مهندسی آبخیزداری ایران، جلد ۱، شماره ۱، ۳۸-۲۴.
۳. ناظم السادات، س. م. ج. و ا. شیروانی. ۱۳۸۴. پیش‌بینی دمای سطح آب خلیج فارس با استفاده از رگرسیون چندگانه و تحلیل مؤلفه‌های اصلی. مجله علوم و فنون کشاورزی و منابع طبیعی، جلد ۹، شماره ۳، ۱۲-۱.
4. Adriaenssens, V., De Baets, B., Goethals, P. and De Pauw, N., 2004. Review, Fuzzy rule-based models for decision support in ecosystem management. *The Science of the Total Environment*, 319: 1-12.
5. Alvisi, S., Mascellani, G., Franchini, M. and Bardossy, A., 2006. Water level forecasting through fuzzy logic and artificial neural network approaches. *Hydrology and Earth System Sciences*, 10: 1-17.
6. Aqil, M., Kita, I., Yano, A. and Nishiyama, S., 2006. Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *Journal of Environmental management* 10: 1-9.
7. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000. Artificial neural networks in hydrology, I: preliminary concepts. *Journal of Hydrologic Engineering*, 5(2): 115-123.
8. Bowden, G., Dandy, G. and Maier, H., 2005. Input determination for neural network models in water resources applications. Part 1-background and methodology. *Journal of Hydrology*, 301: 75-92.

9. Chang, L., Chang, F. and Tsai, Y. 2006. Fuzzy exemplar-based inference system for flood forecasting, *Water Resources Research*, 41(2): 1-20.
10. Coulibaly, P., Anctil, F. and Bobée, B., 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, 230: 244-257.
11. Halide, H. and Ridd, P. 2000. Modeling inter-annual variation of a local rainfall data using a fuzzy logic technique, International Research Institute for Climate Prediction, USA.
12. Jang, J. S, R 1993. ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transaction on Systems Manual and Cybernetics*, 23(3): 665–685.
13. Nayaka, P.C., Sudheerb, K.P., Ranganc, D.M. and Ramasastrri, K.S., 2004. A neuro- fuzzy computing technique for modeling hydrological time series . *Journal of Hydrology*, 291: 52–66.
14. Sajikumar, N. and Thandaveswara, B.S., 1999. A non-linear rainfall–runoff model using an artificial neural network. *Journal of Hydrology*, 216: 32–55
15. Tayfur, G. and Singh, V., 2006. ANN and Fuzzy Logic Models for Simulating Event-Based Rainfall-Runoff. *Journal of Hydrologic Engineerin, ASCE*, 132: 1321-1330.
16. Wang, W., Van Gelderp, H.A.J.M., Vrijling, J.K. and Ma, J., 2006. Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology* 324: 383–399
17. Zealand, C. M., Burn, D. H., Simonovic, S.P., 1999. Short term streamflow forecasting using artificial neural networks. *Journal of Hydrology*, 214: 32-48.