

Fuzzy-GMDH مدل (NASH=۰/۸۷۸۸) ارائه می‌دهد. از طرفی مدل دارای عملکرد بهتری در پیش‌بینی دبی روزانه نسبت به دو روش دیگر با مقادیر ضریب ناش به ترتیب ۰/۸۵۵۵ و ۰/۸۷۷۶ است.

کلیدواژه‌ها: پیش‌بینی دبی، رابطه دبی-اشل، رودخانه مند، سیستم استنتاج فازی، شبکه عصبی

مقدمه

به‌منظور برنامه‌ریزی و مدیریت منابع آب، اجرای پروژه‌های آبخیزداری، پیش‌بینی سیل، طراحی‌های مهندسی، عملیات ذخیره آب، آبرسانی، کشتیرانی، تفریح و مدیریت زیست‌محیطی آگاهی از اطلاعات دبی جریان ضروری است [۱۹]. طراحی اغلب سازه‌های هیدرولیکی بر اساس حداکثر دبی سیل و حداکثر ارتفاع آن است. رابطه بین اشل سطح آب (تراز سطح آب) و دبی هم‌زمان جریان در یک رودخانه یا یک کانال باز به‌عنوان رابطه دبی-اشل یا منحنی رتبه‌بندی شناخته شده است. منحنی رتبه‌بندی یک ابزار بسیار مهم در علم هیدرولیک و هیدرولوژی است زیرا مقادیر دبی، وابستگی زیادی به رابطه دبی - اشل در ایستگاه اندازه‌گیری دارد. روش مرسوم برای جمع‌آوری اطلاعات در مورد دبی جریان با اندازه‌گیری اشل رودخانه و سپس استفاده از رابطه دبی-اشل برای پیش‌بینی دبی جریان است؛ بنابراین، اندازه‌گیری مستقیم دبی نیاز به هزینه زیاد، زمان‌بر و در صورت جاری شدن سیل انجام آن دشوار است [۱].

در سال‌های اخیر استفاده از روش‌های هوش مصنوعی در شاخه‌های مختلف علوم مهندسی آب بسیار توسعه یافته است [۱۱ و ۱۴]. روان سالار و همکاران از یک مدل برنامه‌نویسی ژنتیکی موجدار خطی ترکیبی (WLGP) که شامل تبدیل موجک گسسته (DWT) و یک برنامه‌نویسی ژنتیکی خطی (LGP) برای پیش‌بینی جریان ماهانه (Q) در دو ایستگاه پاتاوه و شاه‌مختار، در رودخانه بشار واقع در یاسوج، ایران مورد استفاده قرار دادند. مقایسه نتایج نشان داد که مدل WLGP می‌تواند دقت پیش‌بینی جریان در هر دو ایستگاه را به میزان قابل‌توجهی افزایش دهد [۱۵].

معینی و همکاران از مدل چهار مرحله‌ای شامل میانگین حرکت یکپارچه خود رفتی فصلی (SARIMA) و سیستم‌های استنتاج عصبی فازی تطبیقی (ANFIS) که یک مدل ترکیبی جدید (-SARIMA ANFIS) است، برای پیش‌بینی جریان با استفاده از داده‌های ماهانه استفاده نمودند. مقایسه نتایج نشان می‌دهد که ANFIS از شبکه‌های

پیش‌بینی رابطه دبی-اشل در رودخانه مند بوشهر با استفاده از هیبرید روش‌های Fuzzy و GMDH

گوهر نوروزی^۱، رضا محمدپور^۲، علیرضا والی پور^۳، علی ترابی حقیقی^۴ و محمد مهدی احمدی^۵

تاریخ دریافت: ۱۴۰۰/۰۱/۰۵ تاریخ پذیرش: ۱۴۰۰/۰۹/۱۵

چکیده

شناخت رابطه دبی-اشل در مدیریت و برنامه‌ریزی منابع آب و همچنین طراحی سازه‌های هیدرولیکی، سازمان‌دهی رودخانه‌ها و برنامه‌ریزی برای سیستم‌های هشدار سیل دارای اهمیت بالایی می‌باشند. با پیشرفت علم و افزایش سرعت محاسبات، روش‌های جدیدی تحت عنوان سیستم‌های هوشمند ارائه گردید است که استفاده از آن‌ها می‌تواند گزینه بهتری جهت مدل‌سازی باشد. در این تحقیق به ترتیب از روش‌ها هوشمند ترکیبی Fuzzy-GMDH، RBF و ANFIS استفاده شده است. روش Fuzzy-GMDH که ترکیبی از دو تکنیک منطق فازی (Fuzzy) و روش کنترل گروهی داده‌ها (GMDH) جهت پیش‌بینی دبی-اشل می‌باشد. جهت بررسی مدل پیشنهادی از داده‌های واقعی و نرمال شده رودخانه مند واقع در استان بوشهر استفاده و نتایج با دو روش شبکه‌های عصبی RBF و همچنین ANFIS مقایسه شده است. در ابتدا با استفاده از آنالیز حساسیت پارامترهای مهم تعیین و سپس روش‌های ذکر شده با شاخص‌های آماری از جمله ضریب ناش (NASH) بررسی و مقایسه شده است. نتایج حاصله نشان داد که داده‌های خام در روش Fuzzy-GMDH با مقدار $NASH=۰/۸۸۲۲$ ، دقت بالاتری را نسبت به داده‌های نرمال

۱- نویسنده مسئول و دانشجوی دکتری مهندسی عمران- سازه‌های هیدرولیکی، گروه مهندسی عمران، دانشکده عمران، دانشگاه آزاد اسلامی واحد استهبان پست الکترونیک: Gohari70@yahoo.com

۲- استادیار مهندسی عمران، گروه مهندسی عمران، دانشکده عمران، دانشگاه آزاد اسلامی واحد استهبان، ایران

۳- استادیار مهندسی عمران، گروه مهندسی عمران، دانشکده عمران، دانشگاه آزاد اسلامی واحد شیراز، ایران

۴- دانشیار مهندسی منابع آب و محیط‌زیست، گروه مهندسی منابع آب و محیط‌زیست، دانشگاه اولو، فنلاند

۵- دانشیار مهندسی آب، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، ایران

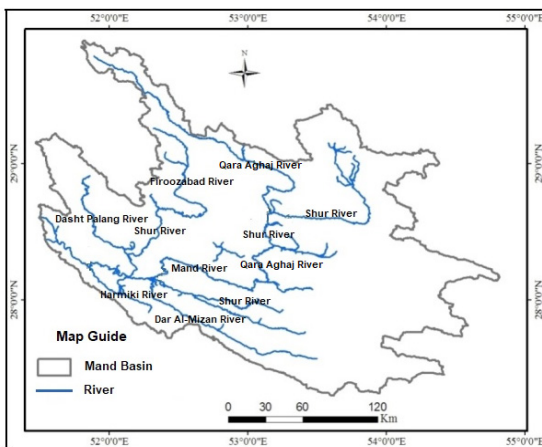
سیستم‌ها قابلیت آن دارند که از مزایای هر دو روش در قالب یک چهارچوب محاسباتی استفاده نمایند. در این راستا برای مقایسه مدل پیشنهادی با دیگر روش‌ها از دو مدل ANFIS و RFB استفاده شده است.

مواد و روش‌ها

در این پژوهش جهت مدل‌سازی رابطه دبی-اشل در رودخانه مند واقع در استان بوشهر با استفاده از داده‌های اندازه‌گیری شده روزانه در ایستگاه هیدرومتری قنطره، از روش‌های محاسبات نرم نظیر روش هوش مصنوعی RBF، روش ANFIS و روش هیبرید Fuzzy-GMDH استفاده شده است. روش‌های مورد استفاده در محیط نرم‌افزار MATLAB توسط سیستمی با RAM ۴ گیگابایت و CPU برابر با 5i-4200M و ۲/۵ گیگاهرتز اجرا شد. اجرای هر کد کمتر از یک دقیقه به طول می‌انجامد.

حوزه آبخیز مند

حوزه مند با مساحت تقریبی ۴۸۰۰۰ کیلومترمربع در محدوده عرض جغرافیایی ۲۷ درجه و ۲۰ دقیقه تا ۲۹ درجه و ۵۰ دقیقه شمالی و طول جغرافیایی ۵۱ درجه و ۱۵ دقیقه تا ۵۴ درجه و ۴۵ دقیقه شرقی در جنوب غربی و جنوب استان فارس و شمال شرقی استان بوشهر واقع شده است. جهت مدل‌سازی رابطه دبی-اشل در رودخانه مند، از داده‌های مربوط به دبی و اشل اندازه‌گیری شده روزانه در ایستگاه هیدرومتری قنطره با طول دوره آماری چهار سال، از سال ۱۳۸۶ تا سال ۱۳۹۰ استفاده شده که در مجموع ۱۲۷۴ داده می‌باشد. واحد اندازه‌گیری داده‌های اشل، سانتیمتر و واحد اندازه‌گیری داده‌های مربوط به دبی، مترمکعب بر ثانیه می‌باشد. در این پژوهش پس از آنالیز داده‌ها از ۸۹۱ داده‌ها (۷۰ درصد) برای آموزش شبکه و ۳۸۲ داده‌ها (۳۰ درصد) برای آزمون، مدل توسعه داده شده استفاده شده است. پارامترهای آماری داده‌های دبی و اشل این ایستگاه نیز در جدول (۱) ارائه شده است.



شکل ۱- موقعیت منطقه مورد مطالعه [۱۶]
Fig 1. Location of the study area [16]

عصبی مصنوعی (ANN) و مدل‌های SARIMA-ANN دقیق‌تر است و SARIMA-ANFIS در تمام مراحل از همه مدل‌ها برتر است [۱۰].

فنجیان و همکاران قابلیت‌های دورویکرد تحلیل سری زمانی، یعنی آستانه خود هیجان‌انگیز آستانه تحریک‌آمیز (SETAR) و مدل‌های هتروسکوشتی^۱ شرطی کلی اتورژنتیکی تعمیم‌یافته (GARCH)، سپس سه رویکرد هوش مصنوعی شامل شبکه‌های عصبی مصنوعی (ANN)، تطبیقی چند متغیره خطوط رگرسیون (MARS) و مدل جنگل‌های تصادفی (RF) برای پیش‌بینی جریان ماهانه رودخانه ایستگاه‌های برانتفورد^۲ و گالت^۳ در رودخانه گراند^۴، کانادا^۵ استفاده شد. آن‌ها دریافتند که در بین مدل‌های ترکیبی توسعه‌یافته، مدل‌های RF-SETAR به‌طور کلی دارای بهترین دقت برای بهبود مدل‌سازی جریان رودخانه بودند [۴].

سامسودین^۶ و همکاران با ترکیب ماشین بردار پشتیبان حداقل مربعات (LSSVM) و روش کنترل گروهی داده‌های (GMDH) به پیش‌بینی دبی در رودخانه پرداختند. در نهایت نتایج نشان داد که روش ترکیبی (LSSVM) می‌تواند به‌عنوان یک ابزار قدرتمند جهت مدل‌سازی دبی در رودخانه به کار می‌رود [۱۸].

قادری و همکاران از روش NF-GMDH به‌منظور مدل‌سازی بهره‌برداری از مخازن استفاده نمودند. نتایج به‌دست‌آمده از این تحقیق حاکی از آن است که این روش برای بهره‌برداری بهینه از مخازن دشت تهران-کرج از عملکرد بالایی برخوردار است اما عملکرد GMDH بهتر از NF-GMDH بوده است [۶].

حسین زاده و همکاران به بررسی مدل‌سازی رابطه دبی-اشل در رودخانه با استفاده از روش‌های هوشمند داده محور (GMDH) و (NF-GMDH) پرداختند. روش GMDH در مقایسه با NF-GMDH از دقت بالاتری جهت شبیه‌سازی رابطه دبی-اشل برخوردار است [۸].

بررسی سوابق پژوهش عنوان‌شده، نشان می‌دهد که استفاده از الگوریتم GMDH، به دلیل سرعت بالا و عملکرد مناسب در یافتن جواب‌های باکیفیت بالا، در مهندسی آب در حال گسترش است. در این پژوهش به بررسی توانایی روش هیبرید Fuzzy-GMDH در پیش‌بینی رابطه دبی-اشل در رودخانه مند پرداخته شده است. استفاده از الگوریتم Fuzzy-GMDH و امکان توسعه آن به‌خصوص در مسائل مدیریتی منابع آب (که غالباً داده‌ها به‌صورت کیفی هستند) می‌تواند حائز اهمیت باشد.

هدف اصلی از اجرای این تحقیق، مطالعه توانایی‌های تکنیک Fuzzy-GMDH برای پیش‌بینی رابطه دبی-اشل می‌باشد؛ زیرا این

1. heteroscedasticity
2. Brantford
3. Galt
4. Grand
5. Canada
6. Sumsudin

جدول ۱- مشخصات آماری داده‌های دبی و اشل روزانه ایستگاه هیدرومتری قنطره

Table 1. Statistical characteristics of daily flow and discharge data of Qantara hydrometric station

پارامترهای آماری	Statistical parameters	کل داده‌ها		داده‌های آموزش		داده‌های آزمایش	
		اشل (cm) Stage	دبی (m ³ /t) Discharge	اشل (cm) Stage	دبی (m ³ /t) Discharge	اشل (cm) Stage	دبی (m ³ /t) Discharge
کمینه	Minimum	56	0.543	59	0.543	56	0.899
بیشینه	Maximum	90	5.37	90	5.37	84.5	5.35
میانگین	Average	69.985	2.284	72.307	2.417	64.644	2.417
واریانس	Variance	46.892	0.838	32.004	0.793	39.464	0.801
انحراف معیار	Standard deviation	6.847	0.915	5.657	0.891	6.282	0.895

جدول ۲- ضرایب همبستگی متغیرهای ورودی نسبت به دبی روزانه Q_t

Table 2. Correlation coefficients of input variables to the daily flow rate Q_t

	H(t)	H(t-1)	H(t-2)	H(t-3)	H(t-4)	Q(t-1)	Q(t-2)	Q(t-3)	Q(t-4)	Q(t)
H(t)	1									
H(t-1)	0.9660	1								
H(t-2)	0.9396	0.9659	1							
H(t-3)	0.9201	0.9394	0.9658	1						
H(t-4)	0.9039	0.9199	0.9392	0.9657	1					
Q(t-1)	0.7590	0.7970	0.7435	0.7073	0.6834	1				
Q(t-2)	0.7214	0.7584	0.7965	0.7429	0.7066	0.9091	1			
Q(t-3)	0.6900	0.7209	0.7580	0.7961	0.7424	0.8340	0.9090	1		
Q(t-4)	0.6646	0.6894	0.7203	0.7575	0.7975	0.7736	0.8339	0.9090	1	
Q(t)	0.7975	0.7441	0.7080	0.6841	0.6663	0.9092	0.8342	0.7738	0.7271	1

انتخاب متغیرها

و حداکثر مقدار مجموعه داده‌ها هستند. با توجه به داده‌های قابل دسترس در حوضه آبریز مند و ضریب همبستگی پیرسون مطابق جدول (۲)، مدل‌سازی رابطه دبی-اشل در رودخانه مند انجام شده است. مطابق جدول دو میزان همبستگی داده‌ها دبی با تأخیرهای زمانی روزانه Q(t-1)، Q(t-2)، Q(t-3)، Q(t-4) و همچنین داده‌های مربوط به اشل در گام‌های زمانی H(t)، H(t-1)، H(t-2)، H(t-3)، H(t-4) مورد بررسی قرار گرفته است.

با توجه به مقادیر به دست آمده مقدار ۰/۷۵ به عنوان معیار انتخاب متغیرها در نظر گرفته شد که بر اساس آن پنج سناریو مختلف با بیشترین میزان همبستگی برای متغیرهای ورودی مدل تعریف و در جدول (۳) آورده شده است. همان گونه که مشاهده می‌شود بیشترین همبستگی در بین متغیرهای دارای یک کمیت مشابه و غیرمشابه به ترتیب مربوطه به نسبت H(t) به H(t-1) با مقدار ۰/۹۶۶۰ و نسبت H(t) به Q(t) با مقدار ۰/۷۹۷۵ است.

بر اساس مشاهدات تجربی و مطالعه سایر محققان، از جمله متغیرهای ورودی مؤثر در پیش‌بینی جریان رودخانه و مدل‌سازی رابطه دبی-اشل در یک حوضه آبریز می‌توان به میزان جریان رودخانه و همچنین ارتفاع سطح آب (اشل) در گام‌های زمانی مختلف اشاره نمود. به منظور آموزش شبکه، سعی بر آن شد تا مجموعه داده‌هایی با ترکیب دبی و اشل به عنوان ورودی انتخاب شوند که دربرگیرنده تمام خصوصیات (بیشینه، کمینه، ...) متغیرها ورودی باشد، همچنین جهت ارزیابی عملکرد شبکه، داده‌ها به دو صورت خام و نرمال بررسی می‌شوند. برای نرمال‌سازی داده‌ها از معادله (۱) که به صورت زیر بیان می‌گردد استفاده شده است [۲].

$$X_n = \frac{(X - X_{min})(0.9 - 0.1)}{(X_{max} - X_{min})} + 0.1 \quad (1)$$

که در آن X_n مقدار نرمال X و X_{min} و X_{max} به ترتیب حداقل

جدول ۳- سناریوهای مختلف جهت پیش‌بینی دبی

Table 3. Different scenarios for flow forecasting

سناریو	ساختار سناریو
Scenario	Scenario structure
Scenario	$Q_t = f(H_t, Q_{t-1})$
Scce. 1	$Q_t = f(H_t, Q_{t-1}, Q_{t-2})$
Scce. 2	$Q_t = f(H_t, Q_{t-1}, Q_{t-2}, Q_{t-3})$
Scce. 3	$Q_t = f(Q_{t-1}, Q_{t-2})$
Scce. 4	$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3})$
Scce. 5	$Q_t = f(H_t, Q_{t-1})$

بر اساس جدول (۳) سناریوهای یک و چهار از دو متغیر، سناریوهای دو و پنج از سه متغیر و سناریو سه از چهار متغیر ورودی، جهت پیش‌بینی دبی استفاده شده است. هم‌چنین سه سناریو اول جدول فوق‌الذکر بر اساس دو نوع متغیر (دبی و اشل) و دو سناریوی چهار و پنج بر اساس یک نوع متغیر (دبی) تعریف شده است. پس از بررسی پارامترها، گام‌های زمانی t برای اشل و $t-1$ ، $t-2$ و $t-3$ برای دبی انتخاب شده است زیرا انتخاب پارامترهای مؤثر با گام‌های زمانی مناسب سبب بهبود عملکرد مدل‌ها جهت فرآیند

مدل‌سازی و پیش‌بینی خواهد شد. در همین راستا جهت بررسی و آنالیز حساسیت برای تعیین متغیرهای اصلی و مهم برای داده‌های خام و نرمال از مدل ANFIS استفاده شده که در جداول (۴) و (۵) قابل مشاهده است.

بر اساس نتایج جداول (۴) تا (۵) مشاهده می‌شود که پارامترهای $H(t)$ ، $Q(t-1)$ و $Q(t-2)$ عملکرد قابل توجهی جهت پیش‌بینی رابطه دبی- اشل دارند به گونه‌ای که برای داده‌های خام مقادیر NASH، RMSE و MAE برای قسمت آزمون به ترتیب برابر با 0.8235 ، 0.2766 و 0.1820 و برای داده‌های نرمال مقادیر NASH، RMSE و MAE برای قسمت آزمون به ترتیب برابر با 0.8235 ، 0.2766 و 0.1820 می‌باشد.

نتایج این مطالعه نشان می‌دهد که سناریو دو، در دو حالت داده‌های خام و نرمال با متغیرهای $H(t)$ ، $Q(t-1)$ و $Q(t-2)$ می‌تواند به‌عنوان یک مدل قابل قبول با دقت بالا انتخاب شود. افزودن پارامترهای دیگر تأثیر کمی در افزایش دقت عملکرد دارد؛ بنابراین، پارامترهای ذکر شده برای پیش‌بینی دبی رودخانه مند با استفاده از ANFIS، RBF و Fuzzy-GMDH انتخاب شدند.

شبکه‌های با تابع پایه‌ی شعاعی (RBF)

شبکه‌های چندلایه پیش‌خور یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشند. به‌طورمعمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نرون‌های پایه) می‌باشند

جدول ۴- آنالیز حساسیت جهت تعیین متغیر مهم داده‌های خام

Table 4. Sensitivity analysis to determine the important raw data variable

سناریو Scenario	پارامترهای ورودی input parameters	آموزش train			آزمون test		
		NASH	RMSE	MAE	NASH	RMSE	RMSE
۱	(H_t, Q_{t-1})	0.9041	0.2759	0.1638	0.8700	0.3231	0.3231
۲	(H_t, Q_{t-1}, Q_{t-2})	0.9127	0.2633	0.1622	0.8776	0.3135	0.3135
۳	$(H_t, Q_{t-1}, Q_{t-2}, Q_{t-3})$	0.8964	0.2868	0.1670	0.8418	0.3565	0.3565
۴	(Q_{t-1}, Q_{t-2})	0.8407	0.3558	0.1632	0.7759	0.4243	0.4243
۵	$(Q_{t-1}, Q_{t-2}, Q_{t-3})$	0.8431	0.3530	0.1680	0.7713	0.4287	0.4287

جدول ۵- آنالیز حساسیت جهت تعیین متغیر مهم داده‌های نرمال

Table 5. Sensitivity analysis to determine the important variable of normal data

سناریو Scenario	پارامترهای ورودی input parameters	آموزش train			آزمون test		
		NASH	RMSE	MAE	NASH	RMSE	RMSE
۱	(H_t, Q_{t-1})	0.9041	0.0457	0.0271	0.8700	0.0535	0.0309
۲	(H_t, Q_{t-1}, Q_{t-2})	0.9127	0.0436	0.0268	0.8776	0.0519	0.0260
۳	$(H_t, Q_{t-1}, Q_{t-2}, Q_{t-3})$	0.8964	0.0475	0.0276	0.8418	0.0590	0.0350
۴	(Q_{t-1}, Q_{t-2})	0.8407	0.0589	0.0270	0.7759	0.0703	0.0317
۵	$(Q_{t-1}, Q_{t-2}, Q_{t-3})$	0.8431	0.0585	0.0278	0.7713	0.0710	0.0320

که تشکیل دهنده‌ی لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشند [۷].

ورودی‌های یک نرون شعاعی، با سایر نرون‌ها متفاوت است. در نرون شعاعی ورودی‌های تابع انتقال برابر است با بردار فاصله بین وزن‌ها و ورودی‌ها، ضربدر بایاس. لایه ورودی، مقادیر را به هر یک از گره‌های لایه پنهان ارسال می‌کند. هر یک از گره‌های واقع در لایه پنهان (نرون‌ها) با یک تابع f مشخص می‌شوند که سیگنال‌های ورودی را انتقال می‌دهند.

برای p امین الگوی ورودی یعنی X^p ، پاسخ z امین گره پنهان یعنی y_j برابر است با:

$$y_j = f \left\{ \frac{\|X^p - U_j\|}{2\sigma_j^2} \right\} \quad (2)$$

که در آن $\|X^p - U_j\|$ برابر نرم اقلیدسی، U_j مرکز j امین تابع شعاعی و σ گستره‌ی RBF است که در آن مقدار تابع به‌زور مشخص از صفر متفاوت است. خروجی شبکه با استفاده از مجموع وزن‌دار خطی پاسخ‌های لایه پنهان در هر یک از گره‌های خروجی به دست می‌آید. خروجی k امین گره در لایه‌ی خروجی یعنی Z_{pk} از رابطه‌ی زیر محاسبه می‌شود:

$$Z_{pk} = \sum_{j=1}^L y_j w_{kj} \quad (3)$$

که در آن w_{kj} وزن پیوند بین گره‌های پنهان و خروجی است. متداول‌ترین تابع RBF تابع گاوسی می‌باشد [۱۷].

روش ANFIS

ANFIS که توسط جانگ^۱ [۹] معرفی شده است، یک رویکرد شبکه عصبی برای عملکرد تقریبی است که می‌تواند به‌صورت ترکیبی از ANN ها و سیستم استنتاج فازی (FIS) بیان شود [۳]. این روش به‌عنوان یک شبکه چندلایه، از الگوریتم‌های یادگیری شبکه عصبی و سیستم فازی برای یافتن ارتباط بین ورودی و خروجی استفاده می‌کند [۵].

در این مطالعه، ANFIS از مدل فازی سگنو^۲ استفاده می‌کند. این FIS از یک معادله خطی استفاده می‌کند و می‌توان بازده پارامترها را با آخرین روش خطای مربع تعیین کرد. اگر فرض کنیم که FIS دارای دو ورودی x و y یک خروجی باشد، در مدل فازی سگنو مرتبه اول، یک قاعده مشترک با دو قانون $if - then$ ممکن است به‌صورت زیر تعریف شود:

$$Rule 1: If x is A_1 and is B_1 then f_1 \quad (4)$$

$$= p_1x + q_1y + r_1$$

$$Rule 2: If x is A_2 and is B_2 then f_2 \quad (5)$$

$$= p_2x + q_2y + r_2$$

که در آن x و y ورودی هستند. A_1 و B_1 به ترتیب MF برای x و y هستند. p_1 ، q_1 و r_1 پارامترهای عملکرد خروجی هستند. توابع ANFIS در هر لایه می‌تواند به‌صورت زیر ارائه شود:

لایه اول: این لایه شامل گره‌های سازگار است که می‌تواند درجه‌های عضویت را برای گره ورودی ایجاد کند و خروجی آن را به‌صورت زیر توصیف کرد:

$$Q_{1,i} = \mu_{A_i}(x) \text{ for } i = 1, 2 \text{ or} \quad (6)$$

$$Q_{1,i} = \mu_{B_{i-2}}(y) \text{ for } i = 3, 4 \quad (7)$$

که در آن x و y گره‌های ورودی هستند. A_1 و B_1 مجموعه فازی هستند. $\mu(x)$ و $\mu(y)$ توابع عضویت هستند [۳].

لایه دوم: تمام گره‌های این لایه می‌توان با Π نام‌گذاری کرد و هر گره سیگنال‌های ورودی را چند برابر می‌کند. خروجی که توانایی یک قانون را نشان می‌دهد می‌تواند به‌صورت زیر محاسبه شود:

$$Q_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \text{ for } i = 1, 2 \quad (8)$$

لایه سوم: هر گره در این لایه با N نشان داده می‌شود و توانایی نرمال را با استفاده از معادله زیر تخمین می‌زند:

$$Q_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \text{ for } i = 1, 2 \quad (9)$$

لایه چهارم: هر گره در این لایه سهم هر قاعده را در خروجی مدل با عملکرد زیر محاسبه می‌کند:

$$Q_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (10)$$

که در آن p_1 ، q_1 و r_1 پارامترهای تنظیم شده و w_1 خروجی لایه سه است.

لایه پنجم: خروجی کلی ANFIS را می‌توان در این لایه محاسبه کرد:

$$Q_{5,i} = f_{out} = \sum_i \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (11)$$

و خروجی نهایی f_{out} را می‌توان به‌صورت زیر نوشت:

$$f_{out} = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2 \quad (12)$$

در فرایند یادگیری ANFIS، الگوریتم ترکیبی پارامترهای فرضیه بهینه و پارامترهای پیش رو آن را به دست می‌آورد.

روش هیبرید Fuzzy-GMDH

معمولاً در روش‌های مختلط خصوصیات قوی هر رویکرد روی دیگری اثر گذاشته و منجر به تولید یک سیستم هوشمند قدرتمندتر می‌گردد. در این پژوهش از تلفیق دو کد Fuzzy و GMDH باهدف به‌کارگیری از پارامترهای Fuzzy برای بهبود نتایج به‌دست‌آمده، دقت و سرعت بیشتر محاسبات، نسبت به کد GMDH استفاده گردید. به‌منظور تلفیق دو کد Fuzzy و GMDH، ابتدا ساختار یک مدل با

1. Jang
2. Sugeno

پارامترهای مشخص که متناسب با ورودی‌ها، تابع عضویت و قوانین است، انتخاب و برای تبدیل به داده‌های فازی وارد ساختار Fuzzy می‌شوند. پس از فازی سازی و فراخوانی داده‌ها در ساختار GMDH، بخشی از داده‌های موجود که دربرگیرنده تمامی خصوصیات داده‌ها باشد، انتخاب شده و در مرحله آموزش با حداقل کردن میزان خطا، پارامترهای مدل به مقادیر واقعی نزدیک می‌شود. پس از آموزش سیستم و انتخاب پارامترهای مناسب، لازم است تا از دقت و اعتبار مدل اطمینان حاصل شود. از این رو بخشی از داده‌ها که در مرحله آموزش به کار نرفته، به عنوان ورودی توسط توابع استاندارد در مرحله صحت سنجی مورد استفاده قرار می‌گیرند.

معیارهای آماری

برای بررسی نتایج به دست آمده از مدل سازی در این مطالعه از چندین معیار آماری استفاده شده است. این معیارهای آماری شامل ضریب ناش (NASH)، انحراف نسبی (RB)، ضریب تعیین (R^2) و میانگین خطای مربعات (MSE) می‌باشند. این معیارها به صورت زیر تعریف می‌شوند:

$$(13)$$

$$NASH = 1 - \frac{\sum_{t=1}^n (Q_t - \hat{Q})^2}{\sum_{t=1}^n (Q_t - \bar{Q}_t)^2}$$

$$(14)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |Q_t - \hat{Q}|$$

$$(15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Q_t - \hat{Q})^2}$$

$$(16)$$

$$R^2 = \left[\frac{\sum_{t=1}^n (Q_t - \bar{Q}_t) \cdot (\hat{Q} - \bar{\hat{Q}})}{\sqrt{\sum_{t=1}^n (Q_t - \bar{Q}_t)^2 \cdot \sum_{t=1}^n (\hat{Q} - \bar{\hat{Q}})^2}} \right]^2$$

که n تعداد کل داده‌ها، \hat{Q} داده‌های مدل، Q_t داده‌های مشاهداتی، \bar{Q}_t میانگین داده‌های مشاهداتی و $\bar{\hat{Q}}$ میانگین داده‌های مدل است [۲۰].

نتایج

توسعه مدل RBF

متغیرهای ورودی منتخب برای این مدل توسعه داده شده شامل $Q(t-1)$ ، $H(t)$ و $Q(t-2)$ می‌باشند و همان‌طور که قبلاً ذکر شد، خروجی این مدل، دبی اندازه‌گیری شده در زمان t، Q_t است.

مدل RBF در حالت داده‌های خام با ۱۱ نرون و نرمال با ۱۲ نرون بهترین نتیجه را ارائه می‌دهد که شاخص‌های آماری آن برای داده‌های خام به ترتیب برابر با $NASH=0/8555$ ، $RMSE=0/3408$ ، $MAE=0/2179$ و $R^2=0/9332$ و برای حالت نرمال برابر با $NASH=0/8822$ ، $RMSE=0/3076$ ، $MAE=0/2067$ و $R^2=0/9399$ است. همان‌گونه که مشاهده می‌شود، ضرایب $NASH$ و R^2 به دست آمده در حالت داده‌های خام به مراتب از ضرایب $NASH$ و R^2 داده‌های نرمال بهتر است.

توسعه مدل ANFIS

جهت یافتن بهترین نتیجه مدل ANFIS در دو حالت استفاده از داده‌های خام و نرمال از مراکز خوشه‌ای متفاوت استفاده شد.

مدل ANFIS با مرکز خوشه‌ای ۰/۲۲ با مقادیر یکسان $NASH$ و R^2 به ترتیب برابر با ۰/۷۷۶ و ۰/۹۳۸۴ برای دو حالت داده‌های خام و نرمال، دارای بهترین عملکرد جهت پیش‌بینی رابطه دبی-اشل است. مقادیر شاخص‌های آماری $RMSE$ و MAE برای حالت داده‌های خام به ترتیب برابر است با ۰/۳۱۳۵ و ۰/۱۵۷۳ و در حالت نرمال برابر با ۰/۵۱۹، $RMSE=0/519$ ، $MAE=0/260$ است.

روش هیبریدی Fuzzy-GMDH

در این بخش جهت پیش‌بینی دبی رودخانه مند، از همان داده‌های ورودی دو مدل RBF و ANFIS که یک‌بار به صورت داده‌های خام و بار دیگر به صورت داده‌های نرمال بوده، استفاده شد. توابع عضویت مورد استفاده در این روش تابع عضویت گوسین با معادله محرک درجه دو بوده است.

قبل از نتایج به دست آمده از مدل هوشمند Fuzzy-GMDH صحت مدل توسعه داده شده توسط سری زمانی مغشوش Glass-Mackey مورد بررسی قرار گرفت.

مدل Fuzzy-GMDH با چهار لایه مخفی و چهار نرون در هر دو حالت داده‌های خام و نرمال بهترین نتیجه را ارائه می‌دهد که شاخص‌های آماری آن برای داده‌های خام به ترتیب برابر با $NASH=0/8822$ ، $RMSE=0/3076$ ، $MAE=0/2067$ و $R^2=0/9399$ است. R^2 و برای حالت نرمال برابر با $NASH=0/8788$ ، $RMSE=0/3076$ ، $MAE=0/2067$ و $R^2=0/9399$ است. همان‌گونه که مشاهده می‌شود، ضرایب $NASH$ و R^2 به دست آمده در حالت داده‌های خام به مراتب از ضرایب $NASH$ و R^2 داده‌های نرمال بهتر است.

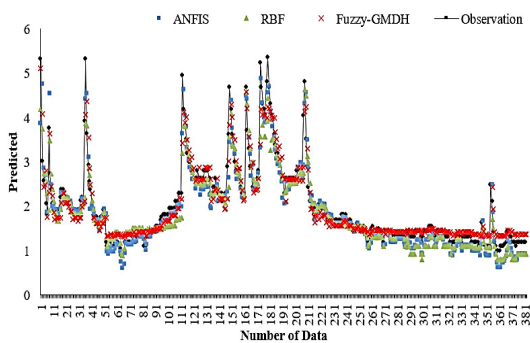
جدول ۶- مقایسه روش‌های RBF، ANFIS و Fuzzy-GMDH با استفاده از داده‌های خام

Table 6. Comparison of RBF, ANFIS and Fuzzy-GMDH methods using raw data

روش‌ها methods	آموزش train				آزمون test			
	NASH	RMSE	MAE	R^2	NASH	RMSE	RMSE	R^2
RBF	0.8708	0.3203	0.1929	0.9332	0.8555	0.3408	0.2179	0.9338
ANFIS	0.9127	0.2633	0.1600	0.9553	0.8776	0.3135	0.1573	0.9384
Fuzzy-GMDH	0.8763	0.3134	0.2032	0.9366	0.8822	0.3076	0.2067	0.9399

جدول ۷- مقایسه روش‌های RBF، ANFIS و Fuzzy-GMDH با استفاده از داده‌های نرمال
Table 7. Comparison of RBF, ANFIS and Fuzzy-GMDH methods using normal data

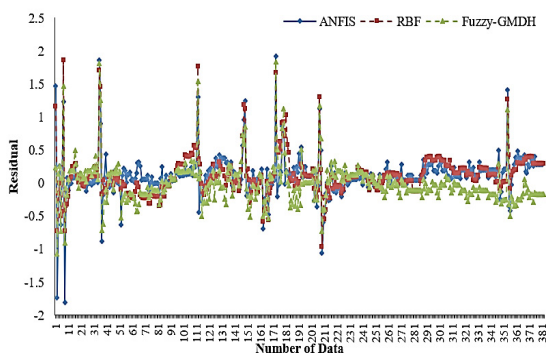
روش‌ها methods	آموزش train				آزمون test			
	NASH	RMSE	MAE	R ²	NASH	RMSE	RMSE	R ²
RBF	0.8944	0.0480	0.0284	0.9457	0.8483	0.0578	0.0299	0.9223
ANFIS	0.9127	0.0436	0.0268	0.9553	0.8776	0.0519	0.0260	0.9384
Fuzzy-GMDH	0.8742	0.0523	0.0327	0.9352	0.8788	0.0517	0.0335	0.9392



شکل ۳- مقدار دبی محاسباتی در مرحله آزمون ANFIS، RBF و Fuzzy-GMDH

Fig 3. Computational flow rate in ANFIS, RBF and Fuzzy-GMDH test phase

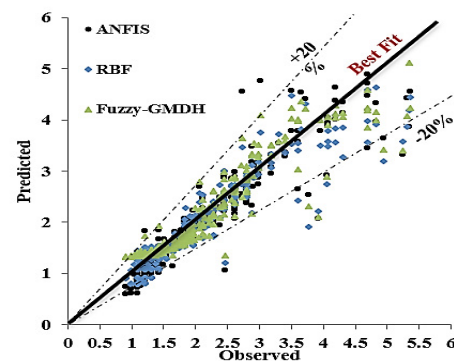
در شکل (۴) مقادیر باقی‌مانده از سه روش انتخاب شده در این پژوهش ارائه شده است. مطابق این شکل، میزان اختلاف مقادیر به‌دست‌آمده با مقادیر مشاهداتی در روش Fuzzy-GMDH از دو روش RBF و ANFIS کمتر است و حول نقطه صفر پراکنده هستند؛ بنابراین روش Fuzzy-GMDH نسبت به دو روش دیگر دارای دقت بهتر جهت برآورد و تخمین مقادیر دبی می‌باشد.



شکل ۴- اختلاف مقدار دبی محاسباتی و مشاهداتی در مرحله آزمون ANFIS، RBF و Fuzzy-GMDH

Fig 4. Comparison of computational and observational flow rates in ANFIS, RBF and Fuzzy-GMDH test phase

بر اساس جداول (۶) و (۷) و مقایسه نتایج به‌دست‌آمده قسمت آزمون از سه روش، مشاهده می‌شود که روش Fuzzy-GMDH در دو حالت داده‌های خام با مقادیر $NASH=0/0,8822$ ، $RMSE=0/3076$ ، $MAE=0/2067$ و $R^2=0/9399$ و داده‌های نرمال $NASH=0/8788$ ، $RMSE=0/0517$ و $R^2=0/9392$ دارای بهترین عملکرد در بین دو روش دیگر می‌باشد. با توجه به شاخص‌های آماری $NASH$ و R^2 مشاهده می‌شود دقت نتایج به‌دست‌آمده در حالت خام به‌مراتب بهتر از حالت نرمال می‌باشد بنابراین در ادامه نتایج بر اساس داده‌های خام ارائه شده است. در شکل (۲) پراکندگی داده‌های مشاهداتی و پیش‌بینی شده توسط مدل‌ها مشاهده می‌شود. مطابق این شکل، داده‌های پیش‌بینی شده توسط شبکه Fuzzy-GMDH پراکندگی کمتری نسبت به خط مرکزی داشته که نشان‌دهنده دقت بالای این روش نسبت به دو روش است.



شکل ۲- مقایسه داده‌های خام مشاهده شده و پیش‌بینی شده در مرحله آزمون

Fig 2. Comparison of raw data observed and predicted in the test phase


شکل (۳) مقادیر به‌دست‌آمده را نسبت به مقادیر مشاهداتی را در مرحله آزمون نشان می‌دهد. همان‌طور که مشاهده می‌شود، مقادیر به‌دست‌آمده از روش Fuzzy-GMDH دقت بالاتری در برآورد مقدار دبی مشاهداتی نسبت به دو روش دیگر دارد. هم‌چنین میزان کمتری داده پرت پیش‌بینی شده دارد.

GMDH تعیین برخی از مشخصات نظیر تعیین بازه توابع عضویت، نوع توابع عضویت، تعیین قوانین و همچنین نحوه ترکیب آن‌ها بر عهده کارشناسان است. بر اساس نتایج و عملکرد قابل قبولی که روش Fuzzy-GMDH از خود جهت برآورد دبی روزانه نشان داد، می‌توان از آن برای سایر بخش‌های مهندسی آب استفاده نمود و نحوه عملکرد آن را مورد سنجش قرارداد.

منابع

1. Al-Aboodi, A.H. Ibrahim, H.T. and Al-Rekabi, W.S. 2018. Stage-Discharge Relationship Modeling Using Data Mining Techniques in an Arid Region, International Journal of Applied Engineering Research, ISSN 0973-4562, Volume 13, Number, 1 pp. 326-336
2. Begum, S.A. Fujail, A.K.M. and Barbhuiya, A.K. 2012. Artificial neural network to predict equilibrium local scour depth around semicircular bridge abutments, 6thSASTech, Malaysia, Kuala Lumpur, Organized by Khavaran Institute of Higher Education, 24–25 March
3. Buragohain, M and Mahanta, C. 2008. A novel approach for ANFIS modelling based on full factorial design, Appl Soft Comput J., 8:609–625
4. Fathian, F. Fakheri-Fard, A. Ouarda, T.B.M.J. Dinpashoh, Y. and Nadoushani, S.S.M. 2019. Multiple streamflow time series modeling using VAR–MGARCH approach. Stoch Environ Res, Risk Assess, 33 (2), 407–425
5. Gallo, G. Perfilieva, I. Spagnuolo, M. and Spinello, S. 1999. Geographical data analysis via mountain function, Int J Intell Syst, 14:359–373
6. Ghaderi, K. Arab, D. and Samani, J.M. 2011. Modeling the operation of reservoirs using the intelligent hybrid system NF-GMDH, 4th Iranian Water Resources Management Conference Amirkabir University of Technology, Tehran. (In Persian)
7. Haykin, S. 1999. Neural networks: A comprehensive foundation, NJ. Prentice-Hall Inc, Englewood Cliffs.
8. Hosseinzadeh, M. Ghaderi, K. and Ahmadi, M.M. 2013. Modeling the Escher discharge relationship in the river using intelligent methods (NF-GMDH and GMDH). National Conference on Water Consumption Optimization, Gorgan. (In Persian)
9. Jang, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system, IEEE Trans Syst Man Cybern, 23:665–685
10. Moeni, H. Bonakdari, H. and Ebtehaj, I. 2017. Integrated SARIMA with neuro-fuzzy systems and neural networks for monthly inflow prediction, Water Resour, Manage. 31 (7), 2141–

در شکل (۵)، نمودار تیلور برای سه روش مورد استفاده در این پژوهش ارائه شده است. این نمودار بر اساس میزان انحراف معیار و همبستگی ترسیم شده که محور افق انحراف معیار و شعاع نمودار میزان همبستگی می‌باشد. مقادیر داده‌های مشاهداتی به صورت Actual نشان داده شده است. چنانچه روش‌های انتخابی به سمت این نقطه نزدیک‌تر باشند نشان‌دهنده دقت روش مذکور می‌باشد. با توجه به اینکه روش Fuzzy-GMDH نسبت به دو روش دیگر فاصله کمتری به داده‌های مشاهداتی دارد، بنابراین دقت این روش نسبت به دو روش دیگر بیشتر بوده و نمایانگر عملکرد بالای این روش می‌باشد.



شکل ۵- نمودار تیلور ANFIS، RBF و Fuzzy-GMDH
Fig 5. Taylor chart ANFIS, RBF and Fuzzy-GMDH

بحث و نتیجه‌گیری

برآورد قابل اطمینان دبی رودخانه‌ها از بخش‌های اساسی مدیریت و برنامه‌ریزی منابع آب سطحی می‌باشد. در این مطالعه روش هیبریدی جدید Fuzzy-GMDH جهت پیش‌بینی دبی - اشل رودخانه ارائه شد. این روش‌ها برای سیستم‌هایی با متغیر زیاد مناسب هستند. با استفاده از آنالیز حساسیت و بر اساس شاخص‌های آماری پنج سناریو تعریف و جهت توسعه سناریوهای مذکور از قسمت برنامه‌نویسی نرم‌افزار MATLAB استفاده شده است. از میان آن‌ها پارامترهای $H(t)$ ، $Q(t-1)$ و $Q(t-2)$ به‌عنوان بهترین ترکیب ورودی جهت برآورد دبی روزانه انتخاب شد که مقادیر آماری NASH، RMSE و MAE برای داده‌های خام در قسمت آزمون به ترتیب برابر با ۰/۸۲۳۵، ۰/۲۷۶۶ و ۰/۱۸۲۰ و برای داده‌های نرمال در قسمت آزمون به ترتیب برابر با ۰/۸۲۳۵، ۰/۰۶۲۴ و ۰/۰۳۰۱ بود. با وجود اینکه پاسخ‌های تولیدشده در هر دو حالت داده‌های خام و نرمال شده توسط هر سه روش ANFIS، RBF و Fuzzy-GMDH با توجه به شاخص‌های آماری ارائه‌شده، دارای دقت قابل قبولی می‌باشند اما نتایج به‌دست‌آمده از مدل Fuzzy-GMDH در حالت داده‌های خام دقت بالاتری نسبت به داده‌های نرمال با مقادیر $R^2=0/9399$ ، $NASH=0/9399$ ، $RMSE=0/3076$ و $MAE=0/2067$ داشت. از طرفی مدل Fuzzy-GMDH دارای عملکرد بهتری در پیش‌بینی دبی روزانه نسبت به دو روش ANFIS و RBF با مقادیر ضریب ناش به ترتیب ۰/۸۵۵۵ و ۰/۸۷۷۶ بود. در روش Fuzzy-

17. Sudheer, K.P. and Jain, S.K. 2003. Radial basis function neural network for modeling rating curves, *J Hydrol Engin ASCE*, 8 (3): 161-164.
18. Sumsudin, R. Ismail, S. and Shabri, A. 2010. River Flow Forecasting: A Hybrid Model of Self Organizing Maps and Least Square Support Vector Machine, *Hybrid. Earth Syst. Sci. Discuss*, Vol. 7, pp. 8179-8212
19. Vafakhah, M. and Shojae, Gh., R. 2008. Determining the most suitable Dubai-Ashle relationship in Zayandehrood regulating dam hydrometric station, *Journal of Agricultural Science and Technology and Natural Resources*, Year 11, Issue 42 (b)
20. Wang, W.C. Chau, K.W. Cheng, C.T. and Qui, L. 2009. A comparison of performance of several Artificial intelligence methods for forecasting monthly discharge time series, *Journal of Hydrology*, 374: 294-306.
- 2156.
11. Mohammadpour, R. 2017. Prediction of local scour around complex piers using GEP and M5-Tree, *Arabian Journal of Geosciences*, 10, 416.
12. Mohammadpour, R. Asai, Z. Shojaeian, M. R. and Sadeghzadeh, M. 2018. A hybrid of ANN and CLA to predict rainfall, *Arabian Journal of Geosciences*, 11, 533.
13. Mohammadpour, R. Ghani, A. A. and Azamathulla, H. M. 2013. Estimation of dimension and time variation of local scour at short abutment, *International Journal of River Basin Management*, 11, 121-135.
14. Pham, Q.B. Mohammadpour, R. Linh, N.T.T. Mohajane, M. Pourjaseem, A. Sammen, S.S. Anh, D.T. and Nam, V.T. 2020. Application of soft computing to predict water quality in wetland, *Environmental Science and Pollution Research*.
15. Ravansalar, M. Rajaei, T. and Kisi, O. 2017. Wavelet-linear genetic programming: A new approach for modeling monthly streamflow, *J. Hydrol*, 549, 461-475.
16. Shayan, S. Zare, G.H.R. Yamani, M. Sharifikia M. and Soltanpoor, M. 2014. Analysis of the trend of statistical changes in discharge and sediment of the catchment area and its application in environmental planning, *Two Quarterly Journal of Applied Geomorphology of Iran*, first year, second issue. (In Persian)

Prediction of Stage–Discharge Relationship in Bushehr Mand River Using Hybrid Fuzzy and GMDH Methods

G. Noruozi¹, R. Mohammadpour², A. R. Valipour³, A. Torabi Haghighi⁴ and M. M. Ahmadi⁵

Received: 25-03-2021 Accepted: 06-12-2021

Abstract

Understanding the Stage–Discharge relationship is of great importance in the management and planning of water resources, as well as the design of hydraulic structures, the organization of rivers, and the planning of flood warning systems. With the advancement of science and increasing the speed of computing, new methods called intelligent systems have been introduced, the use of which can be a better option for modeling. In this research, Fuzzy-GMDH, RBF and ANFIS combined intelligent methods have been used, respectively. The Fuzzy-GMDH method, which is a combination of two techniques of fuzzy logic (Fuzzy) and Group Method of Data Handling (GMDH) for flow-prediction. To study the proposed model, real and normalized data of Mand River located in Bushehr province were used and the results were compared with two methods of RBF and ANFIS neural networks. First, important parameters were determined using sensitivity analysis and then the mentioned methods were evaluated and compared with statistical indicators such as Nash coefficient (NASH). The results showed that the raw data in the Fuzzy-GMDH method with a value of NASH = 0.8822, offers higher accuracy than normal data (NASH = 0.8888). On the other hand, the Fuzzy-GMDH model has a better performance in predicting discharge daily than the other two methods with flow coefficient values of 0.8555 and 0.8776, respectively.

Keywords: ANN, ANFIS, Forecasting discharge, Mand river, Stage–discharge relationsh

1. Corresponding author and PhD student in Civil-Water Engineering, Islamic Azad University, Estahban, Iran.
Email: Gohari70@yahoo.com
2. Assistant Professor Civil Engineering, Department of Civil Engineering, Faculty of Civil Engineering, Islamic Azad University, Estahban, Iran.
3. Assistant Professor Civil Engineering, Department of Civil Engineering, Faculty of Civil Engineering, Islamic Azad University, Shiraz, Iran.
4. Associate Professor Water Resources and Environmental Engineering, Department of Water Resources and Environmental Engineering, University of Oulu, Finland.
5. Associate Professor Water Engineering, Department of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Iran.