

## پیش‌بینی دبی جریان در کانال مرکب مستقیم با استفاده از روش دسته‌بندی گروهی داده‌ها

عباس پارسائی<sup>۱</sup>، شادی نجفیان<sup>۲</sup>، عبدالرضا ظهیری<sup>۲\*</sup>

<sup>۱</sup> مهندسی سازه‌های آبی، دانشگاه لرستان، خرم‌آباد، ایران

<sup>۲</sup> مهندسی سازه‌های آبی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان، ایران

### تاریخچه داوری:

دریافت: ۲۵ آذر ۱۳۹۶  
بازنگری: ۲۵ بهمن ۱۳۹۶  
پذیرش: ۲۸ بهمن ۱۳۹۶  
ارائه آنلاین: ۱۶ اسفند ۱۳۹۶


### کلمات کلیدی:

مدیریت سیلاب  
عمق نسبی  
مهندسی رودخانه  
شبکه عصبی  
روش دسته‌بندی گروهی داده‌ها

**چکیده:** پیش‌بینی دبی جریان در کانال‌های مرکب یکی از مهم‌ترین مسائل مهندسی هیدرولیک است. از مهم‌ترین پارامترهای جریان در کانال‌های مرکب نیز می‌توان به تنش برشی ظاهری اشاره کرد که در اثر اختلاف سرعت جریان در کانال اصلی و سیلاب دشتها در محل اتصال کانال اصلی به سیلاب‌دشتها به وجود می‌آید. تنش برشی ظاهری باعث ایجاد آشفتگی و گردابه‌های سه بعدی در مرز کانال اصلی و سیلاب‌دشتها و نیز کاهش دبی کل جریان می‌گردد. در این پژوهش، دبی جریان در کانال‌های مرکب مستقیم با استفاده از روش‌های تجربی، روش دسته‌بندی گروهی داده‌ها و شبکه عصبی چندلایه مدلسازی و پیش‌بینی شد. پارامترهای بی‌بعد مورد استفاده بدین منظور عبارتند از عمق نسبی جریان، شعاع هیدرولیکی نسبی، مساحت نسبی و زبری نسبی. نتایج نشان داد که روش دسته‌بندی گروهی داده‌ها با ضریب تبیین  $0.91$  و ریشه میانگین مربعات خطای  $0.057$  دارای مناسبترین عملکرد در تخمین دبی جریان در کانال‌های مرکب است. بررسی ساختار روش دسته‌بندی گروهی داده‌های توسعه داده شده نشان می‌دهد که عمق نسبی جریان و مساحت نسبی تأثیر بیشتری را در مدلسازی ظرفیت کانال‌های مرکب دارند. بررسی عملکرد مدل شبکه عصبی چند لایه توسعه داده شده نشان می‌دهد که این مدل با ضریب تبیین  $0.82$  و ریشه مربعات خطای  $0.065$  دارای دقت بیشتری نسبت به روش‌های تجربی است. تحلیل حساسیت شبکه عصبی چند لایه نشان داد که پارامترهای شیب طولی، عمق و مساحت نسبی تأثیر بیشتری در دقت پیش‌بینی جریان دارند که این نکته ساختار به دست آمده از روش دسته‌بندی گروهی داده‌ها را تأیید می‌نماید.

### ۱- مقدمه

در زمان وقوع سیل در رودخانه‌ها، تراز آب در مقطع اصلی رودخانه افزایش یافته و وارد سیلاب‌دشت‌های اطراف می‌گردد. در این شرایط مقطع جریان عبوری از حالت معمولی خارج شده و به شکل مرکب در می‌آید. با توجه به وجود زبری نسبتاً زیاد سیلاب‌دشت‌ها نسبت به مقطع اصلی، سرعت در قسمت کانال اصلی بیشتر از سرعت جریان در سیلاب‌دشت بوده و در نتیجه اختلاف سرعت میان این دو مقطع موجب ایجاد لایه‌های برشی در محل اتصال جریان کانال اصلی به سیلاب‌دشت شده که نتیجه نهایی این فرآیند تولید گردابه‌هایی طولی در مرز اتصال دو کانال اصلی و سیلاب‌دشت و افت انرژی جریان خواهد شد [۲۲ و ۲۳]. در این شرایط فرض یک‌بعدی بودن جریان اعتبار خود را از دست می‌دهد و برآورد رابطه یک بعدی مانینگ از ظرفیت انتقال با خطای قابل توجهی همراه خواهد بود (شکل ۱) [۱].



شکل ۱. شمایی از هیدرولیک جریان در مقاطع مرکب [۲۸]

Fig. 1. schematic of the flow in open compound channels

سلین [۲۷]، نخستین کسی بود که شکل‌گیری گردابه‌های مرز تماس را در آزمایشگاه مشاهده نمود. وی اذعان داشت که آشفتگی‌های تولید شده در مرز مقاطع جزئی موجب کاهش دبی کل مقطع می‌گردد. پس از سلین، محققان روش‌های بسیاری را به منظور دخالت انتقال ممتنم در محاسبات مربوط به کانال‌های مرکب ارائه نموده‌اند که از این میان می‌توان به آکرز [۱]، شیونو و نایت [۲۸]، بوسمار و زیک [۵]، هات هوف و همکاران [۸]،

\* نویسنده عهده‌دار مکاتبات: zahiri.areza@gmail.com

با دو الگوریتم بهینه‌ساز به پیش‌بینی دبی جریان در مقاطع مرکب منشوری پرداختند. بررسی مرور بر منابع نشان می‌دهد که مدل‌سازی دبی جریان در مقاطع مرکب منشوری با به‌کارگیری مدل دسته‌بندی گروهی داده‌ها به تنهایی انجام نشده است. لذا در این تحقیق مدل‌سازی و پیش‌بینی دبی جریان در کانال‌های مرکب مستقیم با استفاده از این روش مورد بررسی قرار می‌گیرد.

## ۲- مواد و روش‌ها

در این تحقیق از ۳۹۶ سری داده هندسی و هیدرولیکی کانال‌های مرکب با سیلاب‌دشت‌های متقارن در شرایط مختلف آزمایشگاهی، جهت پیش‌بینی دبی جریان با مدل دسته‌بندی گروهی داده‌ها استفاده شده است. در جدول ۱ محدوده تغییرات هندسی و هیدرولیکی این مقاطع ارائه شده است. در ادامه پارامترهای مؤثر بر رفتار هیدرولیکی جریان در مقاطع مرکب، سه روش مقطع واحد، تجزیه قائم مقطع مرکب و کوهیرنس که از کاربردی‌ترین روش‌ها نزد مهندسين رودخانه هستند و نیز مدل GMDH تشریح می‌گردند.

خاتوآ و همکاران [۱۱]، ساهو و همکاران [۲۶]، کردی و همکاران [۱۴] اشاره نمود. مطالعات عددی نیز در این زمینه صورت گرفته است که می‌توان به پژوهش‌های کانوی و همکاران [۶]، فیلونویچ و همکاران [۷]، کوفتیز و پرینس [۱۳] استناد نمود. امروزه با پیشرفت چشم‌گیر روش‌های رایانش نرم در حل مسائل مختلف مهندسی، مهندسين رودخانه را بر این داشته است تا عملکرد این روش‌ها را در حل مسائل اساسی مهندسی رودخانه مورد بررسی قرار دهند. روش دسته‌بندی گروهی داده‌ها<sup>۱</sup> یکی از روش‌های رایانش نرم و از نوع داده محور می‌باشد که توسط ایواخنکو [۱۰] توسعه داده شده است. این مدل به طور گسترده‌ای در زمینه‌های مختلف تحقیقاتی و کاربردی برای برخورد با عدم قطعیت‌ها، سیستم‌های خطی و غیرخطی توسط محققین مختلفی مورد استفاده قرار گرفته است. تاکنون از این روش در مهندسی آب برای بهره‌برداری از مخازن [۴]، تخمین ضریب پراکندگی طولی آلودگی در رودخانه [۱۹ و ۱۸]، تخمین آب‌شستگی پایه‌های پل [۱۷ و ۱۶] استفاده شده است. نجف زاده و ظهیری [۲۰] با ترکیب مدل دسته‌بندی گروهی داده‌ها

### جدول ۱. محدوده تغییرات هندسی و هیدرولیکی کانال‌های مرکب مورد استفاده در این پژوهش

Table 1. Summary of collected data range related to discharge of flow in the compound channel

Q (cms)	S0	n (mc)	n (fp)	b (mc)	y (fp)	y (mc)	محدوده	محقق
۰/۰۰۴۹	۰/۰۰۱	۰/۰۱	۰/۰۱	۰/۰۸	۰/۰۰۹	۰/۰۸۵	حداقل	نایت و همکاران (۲۶)
۰/۰۲۹۴	۰/۰۰۱	۰/۰۱	۰/۰۱	۰/۰۸	۰/۰۷۸	۰/۱۵۴	حداکثر	
۰/۰۱۱۶	۰/۰۰۱	۰/۰۱	۰/۰۱	۰/۰۸	۰/۰۳۶	۰/۱۱۲	متوسط	
۰/۰۰۶۸	.	.	.	.	۰/۰۲۲	۰/۰۲۲	انحراف معیار	
۰/۰۰۰۹	۰/۰۰۰۴	۰/۰۰۹۹	۰/۰۱۱	۰/۲۹	۰/۰۱۵	۰/۱۳۵	حداقل	ورملیتون و هاجیبانوس (۲۸)
۰/۴۸	۰/۰۰۱۸	۰/۰۰۹۹	۰/۰۲۱	۰/۲۹	۰/۰۹	۰/۲۱	حداکثر	
۰/۰۳۷۲	۰/۰۰۰۶	۰/۰۰۹۹	۰/۰۱۶	۰/۲۹	۰/۰۴۷	۰/۱۶۷	متوسط	
۰/۰۷۳۵	۰/۰۰۳	.	۰/۰۰۴۲	.	۰/۰۲۳	۰/۰۲۳	انحراف معیار	
۰/۰۱	۰/۰۰۰۱	۰/۰۰۹۱	۰/۰۰۹۱	۰/۲	۰/۰۰۶	۰/۰۵۸	حداقل	ورملیتون و مرت (۲۸)
۱/۱۱۴۲	۰/۰۰۲	۰/۰۲۱	۰/۰۹۱	۰/۷۵	۰/۱۵۲	۰/۳۰۲	حداکثر	
۰/۳۲۳	۰/۰۰۰۷	۰/۰۱۱۳	۰/۰۲۲	۰/۵۸	۰/۰۵	۰/۱۶۹	متوسط	
۰/۲۹۴۶	۰/۰۰۰۹	۰/۰۰۳	۰/۰۲۳۹	۰/۲۶	۰/۰۴	۰/۰۶۶	انحراف معیار	
۰/۰۱۳	۰/۰۰۲	۰/۰۰۷۹	۰/۰۰۵۶	۰/۲	۰/۰۰۶	۰/۰۵۶	حداقل	تانگ و همکاران (۲۷)
۰/۲۱۸	۰/۰۰۲	۰/۰۳۹	۰/۰۹۵۷	۰/۲	۰/۱۷	۰/۲۲	حداکثر	
۰/۰۴۹۹۹	۰/۰۰۲	۰/۰۱۷	۰/۰۳۴۶۶	۰/۲	۰/۰۴۲	۰/۰۹۲	متوسط	
۰/۰۵۴۶	.	۰/۰۰۹۳	۰/۰۲۲۸	.	۰/۰۴۲	۰/۰۴۲	انحراف معیار	

1 Group Method of Data Handling (GMDH)

حدافل	۰/۰۶	۰/۰۱	۰/۲	۰/۰۰۹	۰/۰۰۹	۰/۰۰۲	۰/۰۱۴۸	سکین (۲۹)
حداکثر	۰/۱۶۸	۰/۱۱۸	۰/۲	۰/۰۴۹	۰/۰۰۹	۰/۰۰۲	۰/۰۵۵۳	
متوسط	۰/۰۹	۰/۰۴	۰/۲	۰/۰۲۸۸	۰/۰۰۹	۰/۰۰۲	۰/۰۲۹۹	
انحراف معیار	۰/۰۲۷	۰/۰۲۷	۰	۰/۰۰۱۷۷	۰	۰	۰/۰۱۱۷	
حدافل	۰/۰۶۱	۰/۰۱۱	۰/۲	۰/۰۰۶۳	۰/۰۰۹۱	۰/۰۰۲	۰/۰۱۸	آتابای و نایت (۲)
حداکثر	۰/۱۲	۰/۰۷	۰/۲	۰/۰۱۱۲	۰/۰۱۱۵	۰/۰۰۲	۰/۱۸۳	
متوسط	۰/۰۷۲	۰/۰۲۲	۰/۲	۰/۰۰۸۱	۰/۰۰۹۸	۰/۰۰۲	۰/۰۴۷۴	
انحراف معیار	۰/۰۱۴	۰/۰۱۴	۰	۰/۰۰۱۳	۰/۰۰۰۶	۰	۰/۰۳۹۱	
حدافل	۰/۱۳۶	۰/۰۱۶	۰/۰۶	۰/۰۱	۰/۰۱	۰/۰۰۱۹	۰/۰۰۸۷	خاتوآ و همکاران (۱۱)
حداکثر	۰/۲۲۳	۰/۱۰۳	۰/۰۶	۰/۰۱	۰/۰۱	۰/۰۰۱۹	۰/۰۳۹۱	
متوسط	۰/۱۷۴	۰/۰۵۴	۰/۰۶	۰/۰۱	۰/۰۱	۰/۰۰۱۹	۰/۰۲۱۲	
انحراف معیار	۰/۰۳۱	۰/۰۳۱	۰	۰	۰	۰	۰/۰۱۱۱	
حدافل	۰/۲۰۷	۰/۰۰۷	۰/۲۸	۰/۰۱	۰/۰۱	۰/۰۰۰۱	۰/۰۲۶	ایکیدا و مک ایوان (۹)
حداکثر	۰/۲۷۸	۰/۷۸	۰/۲۸	۰/۰۱	۰/۰۱	۰/۰۰۰۳	۰/۰۷۳	
متوسط	۰/۲۴۲	۰/۰۴۲	۰/۲۸	۰/۰۱	۰/۰۱	۰/۰۰۰۲	۰/۰۴۸۶	
انحراف معیار	۰/۰۱۸	۰/۰۱۸	۰	۰	۰	۰/۰۰۰۱	۰/۰۱۳۳	
حدافل	۰/۰۷۱	۰/۰۰۶	۰/۱۷	۰/۰۱	۰/۰۱	۰/۰۰۱۱	۰/۰۱۳	موهانتی و خاتوآ (۱۴)
حداکثر	۰/۱۱۵	۰/۰۵	۰/۱۷	۰/۰۱	۰/۰۱	۰/۰۰۱۱	۰/۱۰۶۲	
متوسط	۰/۹۱	۰/۰۲۶	۰/۱۷	۰/۰۱	۰/۰۱	۰/۰۰۱۱	۰/۰۴۶۷	
انحراف معیار	۰/۰۱۶	۰/۰۱۶	۰	۰	۰	۰	۰/۰۳۲۶	
حدافل	۰/۱۹۵	۰/۰۱۵	۰/۲	۰/۰۱۳۹	۰/۰۱۳۹	۰/۰۰۰۹	۰/۰۳۳۵	یونسی و همکاران (۳۲)
حداکثر	۰/۳۳۳	۰/۱۵۳	۰/۲	۰/۰۱۶۵	۰/۰۱۳۹	۰/۰۰۰۹	۰/۰۶۸۲	
متوسط	۰/۲۵۷	۰/۰۷۷	۰/۲	۰/۰۱۵۴	۰/۰۱۳۹	۰/۰۰۰۹	۰/۰۵۱۱	
انحراف معیار	۰/۰۳۶	۰/۰۳۶	۰	۰/۰۰۱۱	۰	۰	۰/۰۰۹۸	

## ۲-۱- پارامترهای مؤثر بر دبی جریان

هیدرولیک جریان در مقاطع مرکب به علت وجود لایه‌های برشی در محل اتصال کانال اصلی به سیلاب‌دشت‌ها از پیچیدگی خاصی برخوردار است. در رابطه (۱) مهم‌ترین پارامترهای هندسی و هیدرولیکی مؤثر بر دبی جریان در این نوع مقاطع ارائه شده است:

$$Q = \phi(f_{fp}, f_{mc}, A_{fp}, A_{mc}, R_{fp}, R_{mc}, S_0, h, (H - h)) \quad (1)$$

که در آن  $f_{fp}$  و  $f_{mc}$  به ترتیب زبری سیلاب‌دشت و کانال اصلی، و  $A_{fp}$  سطح مقطع سیلاب‌دشت و کانال اصلی، و  $R_{fp}$  و  $R_{mc}$  شعاع هیدرولیکی سیلاب‌دشت و کانال اصلی،  $S_0$  شیب طولی کف،  $h$  عمق لبریزی،  $H-h$  عمق آب در سیلاب‌دشت و  $Q$  دبی کل جریان می‌باشد. ساهو و همکاران [۲۶]، به منظور پیش‌بینی دبی جریان در مقاطع مرکب منشوری با مسیر

مستقیم با به کار بردن مدل شبکه عصبی مصنوعی<sup>۱</sup> پارامترهای رابطه (۱) را به صورت پارامترهای بی‌بعد درآورده و آن‌ها را به عنوان متغیرهای ورودی برای توسعه مدل شبکه عصبی بکار بردند. در رابطه (۲) پارامترهای بی‌بعدی که توسعه مدل رایانش نرم و روش‌های تحلیلی بر اساس آن صورت گرفته است، ارائه شده است.

$$Q = \phi(f_r, A_r, R_r, S_0, H_r) \quad (2)$$

که در آن  $f_r = f_{fp}/f_{mc}$  زبری نسبی،  $A_r = A_{fp}/A_{mc}$  سطح مقطع نسبی،  $R_r = R_{fp}/R_{mc}$  شعاع هیدرولیکی نسبی و  $H_r = H-h/H$  عمق نسبی می‌باشد [۱۹].

1 Artificial Neural Network

### ۲-۴- روش کوهیرنس

آکرز [۱] نشان داد هرچه اختلاف سرعت در این دو مقطع بیشتر باشد، میزان تنش برشی و در نتیجه خطای روش‌های تجزیه مقطع مرکب نیز بیشتر می‌شود. وی پارامتر بدون بعدی به نام کوهیرنس<sup>۳</sup> مقطع را معرفی نمود که بیان کننده میزان تشابه جریان در مقطع اصلی و دشت‌های سیلابی بوده به صورت زیر تعریف شده است.

$$COH = \frac{(1+A_*)^{\frac{3}{2}} / \sqrt{\left(1+P_*^{\frac{4}{3}} n_*^2 / A_*^{\frac{1}{3}}\right)}}{1+A_*^{\frac{5}{3}} / \left(n_* P_*^{\frac{2}{3}}\right)} \quad (6)$$

$$A_* = \frac{N_{fp} A_{fp}}{A_{mc}}, P_* = \frac{N_{fp} P_{fp}}{P_{mc}}, n_* = \frac{n_{fp}}{n_{mc}} \quad (7)$$

که در آن  $N_{fp}$  تعداد سیلاب دشت می‌باشد.

### ۲-۵- روش دسته‌بندی گروهی داده‌ها

GMDH یکی از رویکردهای استقرائی مبتنی بر تئوری پرسپترون بوده که برای شناسائی سیستم‌ها، مدل‌سازی و پیش‌بینی سیستم‌های پیچیده توسعه داده شده است. GMDH ترکیبی از آدلین‌ها<sup>۴</sup> می‌باشد و نسخه‌های اصلاح شده‌ای از این روش برای کاربردهای مختلف مدل‌سازی مورد استفاده قرار گرفته است. این روش نسبت به ساختار نوع پرسپترون دارای دقت بالاتری است چرا که از طبقه‌بندی اطلاعات به صورت مفید و غیرمفید استفاده کرده و به تعداد داده‌های مشاهداتی کمتری احتیاج دارد. همچنین زمان انجام محاسبات کمتر می‌شود [۹]. در شکل ۴ دیگرام شماتیک شبکه GMDH همراه با نمایی از ساختار آدلین با تابع محرک چندجمله‌ای درجه دو نشان داده شده است. در این شکل sq و X به ترتیب بیانگر مجذور و حاصل ضرب، x1 و x2 ورودی‌ها و y خروجی می‌باشد. معیار خارجی برای تعیین ساختار شبکه به صورت زیر تعریف می‌شود:

$$R^2 = \frac{\sum_{t=1}^N (\hat{y}(t) - \bar{\hat{y}})^2}{\sum_{t=1}^N (y(t) - \bar{y})^2} \quad (8)$$

که Y خروجی مطلوب، y خروجی محاسباتی، y میانگین خروجی‌های محاسباتی و y میانگین خروجی‌های مطلوب است.

### ۲-۲- روش مقطع واحد

در این روش تمامی مقطع مرکب به عنوان یک مقطع واحد فرض می‌شود و از روابط مقاومتی معمول نظیر مانینگ یک بار برای کل مقطع استفاده می‌گردد. روش‌های متعددی جهت برآورد ضریب زبری معادل پیشنهاد شده است که در رابطه (۳) به روش هورتون اشاره شده است. عموماً روش مقطع واحد<sup>۱</sup> کم‌ترین برآورد را در میان تمامی روش‌های برآورد ظرفیت انتقال در کانال‌های مرکب ارائه می‌دهد [۲۲ و ۲۳].

$$n_e = \frac{\left[ \sum_{i=1}^N \left( P_i n_i^{\frac{3}{2}} \right) \right]^{\frac{2}{3}}}{P^{\frac{2}{3}}} \quad (3)$$


$$Q = \frac{1}{n_e} A R^{\frac{2}{3}} S_b^{\frac{1}{2}} \quad (4)$$

که در این روابط  $P_i$  پیرامون مرطوب بخش  $\lambda_m$  از مقطع است که دارای ضریب زبری مانینگ  $n_i$  می‌باشد، P پیرامون مرطوب کل مقطع جریان و N تعداد زیرمقاطع است.

### ۲-۳- روش تجزیه مقطع

در روش تجزیه مقطع<sup>۲</sup> مقطع مرکب به کانال اصلی و یک یا دو سیلاب دشت در طرفین آن تقسیم می‌گردد و با استفاده از رابطه مانینگ، دبی جریان در هر یک از زیرمقاطع محاسبه می‌شود. استفاده از روش تقسیم مقطع بدون اعمال اصلاحاتی در آن به معنای صرف نظر از اثرات کاهش ناحیه تبادل تنش داخلی و برآورد بیش از واقعیت ظرفیت انتقال مقطع مرکب می‌باشد [۲۴]. در رابطه (۵)  $R_i$  و  $A_i$  به ترتیب شعاع هیدرولیکی و سطح مقطع بخش  $\lambda_m$  از مقطع است.

$$Q = \left( \sum_{i=1}^N \frac{A_i R_i^{\frac{2}{3}}}{n_i} \right) S_0^{\frac{1}{2}} \quad (5)$$



شکل ۲. روش‌های مختلف تقسیم مقطع (a-b: قائم، a-c: مایل و a-a: افقی) [۲۳]

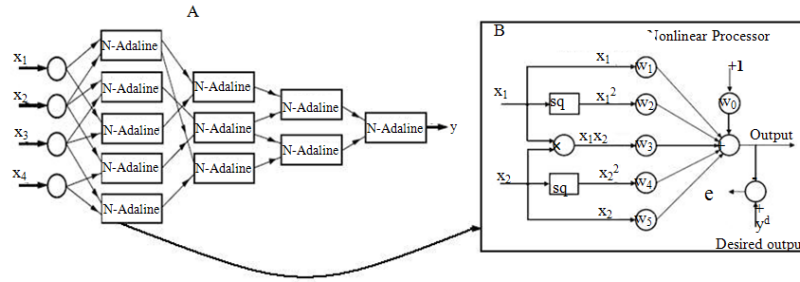
Fig. 2. Types of separating boundary between main channel and floodplains. a-b: vertical, a-c: diagonal, a-a: horizontal

3 Coherence Method (COHM)

4 Adelines

1 Single Channel Method (SCM)

2 Divided Channel Method (DCM)



شکل ۳. شمایی از توسعه مدل GMDH

Fig. 3. GMDH architecture

ماتریس‌های  $\phi$ ،  $X$  و  $W$  دارای ابعاد  $1 \times N$ ،  $N \times 6$  و  $1 \times 6$  هستند. معادلات نرمال با استفاده از ضرب طرفین رابطه بالا در ترانهاده ماتریس  $X$  به دست می‌آیند:

$$X^T \phi = (X^T X) W \Rightarrow W = (X^T X)^{-1} X^T \phi \quad (12)$$

یک ماتریس  $6 \times 6$  بوده و می‌توان ضرایب را با استفاده از روش معکوس به دست آورد. ماتریس  $W$  شامل مجموعه‌ای از ۶ ضریب می‌باشد که قادر به تقریب خروجی‌های صحیح با حداقل میانگین مربعات خطا می‌باشد. مراحل فوق برای تمام نرون‌های لایه اول و همچنین برای تمام نرون‌های لایه‌های بعدی نیز تکرار می‌شوند. بعد از به دست آمدن ضرایب بر اساس داده‌های آموزشی، شاخص عملکرد نرون‌های به دست آمده از طریق همبستگی یا محاسبه میانگین خطای مربعات بین خروجی‌های واقعی داده‌های کنترل محاسبه می‌شوند و تنها نرون‌هایی که دارای شاخص عملکرد بالاتر از مقدار آستانه هستند برای ادامه مسیر انتخاب می‌شوند.

### ۲-۶- شبکه عصبی چندلایه

شبکه‌های عصبی انواع مختلفی دارند که پرکاربردترین آنها شبکه عصبی چندلایه است. طراحی مدل شبکه عصبی چندلایه شامل چند مرحله است که عبارتند از: تعریف تعداد لایه‌های مدل شامل لایه ورودی، لایه(های) پنهان، لایه خروجی، تعداد نرون در هر لایه، تعریف تابع فعال انتقال و همچنین در نهایت انتخاب روش آموزش شبکه عصبی (شکل ۴). منظور از آموزش شبکه عصبی تعیین مقادیر وزن‌ها و ثابت‌هایی است که در هر ورودی ضرب و جمع شده می‌شود. [۲۳ و ۲۲ و ۱۷].

ساختار شبکه از طریق الگوریتم ارائه شده تعیین می‌شود: انتخاب متغیرهای ورودی به مدل، جمع‌آوری مجموعه‌ای از داده‌های مشاهداتی مرتبط با موضوع مورد بررسی، تقسیم‌بندی داده‌ها به دو گروه داده‌های واسنجی و اعتبارسنجی، ساخت  $N$ -آدالین برای تمام ترکیبات ۲ تایی از متغیرهای ورودی، انتخاب نوع تابع محرک برای هر نرون، تخمین ضرایب وزنی برای تمام  $N$ -آدالین‌ها با روش تخمین حداقل مربعات (LSE) و محاسبه معیار فیلتراسیون، مقایسه معیار محاسبه شده برای تمام  $N$ -آدالین‌ها با مقدار آستانه تعیین شده (اگر مقدار آستانه بزرگ‌تر از معیار باشد،  $N$ -آدالین حذف می‌شود و دیگر  $N$ -آدالین‌ها برای لایه بعد باقی می‌مانند). هر نرون در ساختار GMDH یک تابع غیرخطی از ورودی‌ها را اجرا می‌کند. این تابع غیرخطی بصورت زیر می‌باشد:

$$Y = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1^2 + w_4 x_2^2 + w_5 x_1 x_2 \quad (9)$$

ضرایب ۶ گانه هر نرون در شبکه از طریق رویکرد حداقل مربعات محاسبه می‌شوند که مراحل انجام این کار به صورت زیر است. فرض کنید  $N$  بردار ورودی  $(x_{n1}, x_{n2}, \dots, x_{np})$  که  $X_n = (x_{n1}, x_{n2}, \dots, x_{np})$  در مجموعه آموزشی وجود داشته که هر کدام از  $P$  مقدار صحیح تشکیل شده باشند. مقدار مطلوب خروجی  $\phi_n$  با  $n$  نشان داده می‌شود. می‌بایست مجموعه‌ای از ضرایب ۶ گانه برای هر نرون پیدا شود به طوری که میانگین مربعات خطا بین خروجی‌های این نرون  $Y_n$  و مقدار واقعی  $\phi_n$  حداقل باشد. با استفاده از معادلات نرمال گوسین، ضرایب به صورت زیر به دست می‌آیند:


$$\begin{aligned} \phi_1 &= w_0 + w_1 x_{1i} + w_2 x_{1j} + w_3 x_{1i}^2 + w_4 x_{1j}^2 + w_5 x_{1i} x_{1j} \\ \phi_2 &= w_0 + w_1 x_{2i} + w_2 x_{2j} + w_3 x_{2i}^2 + w_4 x_{2j}^2 + w_5 x_{2i} x_{2j} \\ \phi_N &= w_0 + w_1 x_{Ni} + w_2 x_{Nj} + w_3 x_{Ni}^2 + w_4 x_{Nj}^2 + w_5 x_{Ni} x_{Nj} \end{aligned} \quad (10)$$

که به صورت ماتریس کلی زیر نوشته می‌شود:

$$\phi = XW \quad (11)$$

1 Least Squar Error

است که روش تقسیم مقطع افقی از دقت بهتری برخوردار بوده و قادر به پیش‌بینی دبی جریان در مقادیر حداکثر می‌باشد. روش تقسیم واحد با ضریب تعیین ۰/۴۸ عملکرد ضعیفی را در برآورد دبی جریان دارد و با افزایش دبی جریان به سرعت از دقت آن کاسته می‌شود که می‌توان آن را ناشی از عدم دخالت انتقال ممتنم میان کانال اصلی و سیلابدشت در این روش دانست.



شکل ۴. نمایی شماتیک از ساختار یک شبکه عصبی چندلایه

Fig. 4. Schematic of typical multi-layer neural network model

### ۳-۲- روش دسته‌بندی گروهی داده‌ها

در این قسمت عملکرد روش دسته‌بندی گروهی داده‌ها جهت پیش‌بینی جریان در کانال‌های مرکب ارائه می‌گردد. برای توسعه روش گروه‌بندی داده‌ها، داده‌های جمع‌آوری شده جدول ۱ به دو دسته آموزش و آزمایش تقسیم شد. جدول ۲ محدوده داده‌های تخصیص داده شده به مرحله توسعه مدل را ارائه می‌کند. ۸۰٪ داده‌ها برای واسنجی و مابقی برای اعتبارسنجی مدل توسعه داده شده استفاده شد. ساختار مدل توسعه داده شده در شکل ۶ نشان داده شده است. مدل ارائه شده دارای چهار لایه پنهان است که در لایه اول و دوم هر کدام چهار نرون و در لایه سوم و چهارم به ترتیب پنج و هفت نرون موجود است. ساختار مدل توسعه داده شده نشان می‌دهد که دو پارامتر عمق و سطح مقطع نسبی دارای اهمیت بیشتری نسبت به سایر پارامترهای دخیل در پیش‌بینی جریان در کانال‌های مرکب دارند. عملکرد مدل توسعه داده شده در مراحل آموزش (واسنجی) و آزمایش (اعتبارسنجی) در شکل‌های ۷ و ۸ آورده شده است. همان‌طور که مشاهده می‌شود ریشه میانگین مجذور خطای مدل در مرحله واسنجی برابر با ۰/۰۸۴ و برای مرحله آزمایش (اعتبارسنجی) برابر با ۰/۰۵۷ است. ضرایب موجود در تابع محرک نرون‌های مدل توسعه داده شده در جدول ۳ آورده شده است. مقایسه عملکرد روش دسته‌بندی گروهی داده‌ها و روش‌های تجربی نشان می‌دهد که عملکرد روش دسته‌بندی گروهی داده دقیق‌تر است.

### ۳- نتایج و بحث

#### ۳-۱- روش‌های تجربی

در این قسمت عملکرد روش‌های تجربی ارائه شده در قسمت مواد و روش‌ها با استفاده از داده‌های جمع‌آوری شده (جدول ۱) مورد بررسی قرار می‌گیرد. بدین منظور شاخص‌های خطا مانند ضریب تعیین<sup>۱</sup> و ریشه میانگین مربعات خطا<sup>۲</sup> استفاده گردید. شاخص‌های خطا همواره مقداری میانگین برای عملکرد روش‌ها ارائه می‌دهند لذا سعی شده است که نتایج روش‌های تجربی به کار گرفته شده همراه با داده‌های مشاهداتی ارائه گردد (شکل ۵). بررسی‌ها نشان می‌دهد که روش تقسیم مقطع با در نظر گرفتن خط افقی به عنوان مرز بین زیر مقاطع با ضریب تعیین ۰/۷۶ دارای بهترین عملکرد است. دقت مناسب روش تقسیم مقطع مربوط به در نظر گرفتن تنش‌های بین لایه‌های جریان در بین زیرمقاطع است. همان‌طور که ملاحظه می‌شود دقت تمامی روش‌های تحلیلی به غیر از روش تقسیم مقطع قائم و افقی، با افزایش دبی جریان کاهش می‌یابد که ناشی از افزایش شدت انتقال جرم و ممتنم میان مقطع اصلی و سیلابدشت است. بررسی شکل ۵ حاکی از این

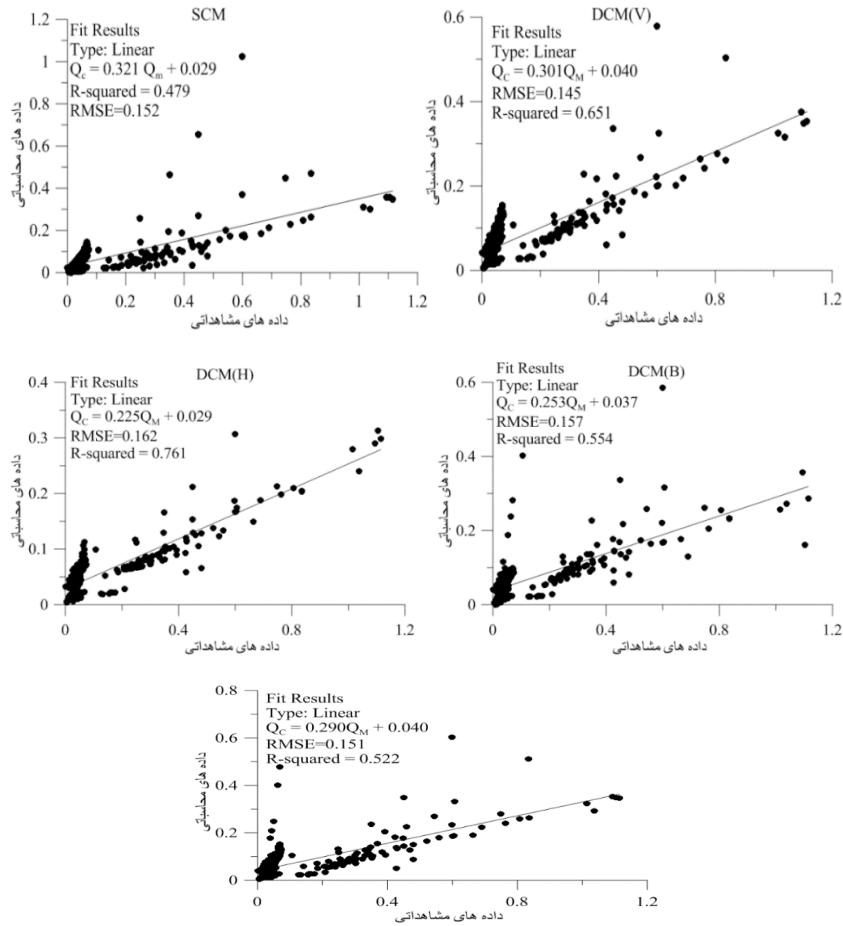
### جدول ۲. محدوده داده‌های اختصاص داده شده در مراحل تهیه روش دسته‌بندی گروهی داده‌ها

Table 2. Summary of data range related to development of GMDH model

مرحله	محدوده	زبری نسبی	سطح مقطع نسبی	شعاع هیدرولیکی نسبی	شیب طولی	عمق نسبی	دبی جریان
آموزش (کالیبراسیون)	حداقل	۰/۱۶	۰/۱۰	۱/۳۸	۰/۰۰	۲/۰۴	۰/۰۰
	حداکثر	۳/۰۰	۴/۴۹	۲۶/۶۰	۰/۰۰	۲/۶۳	۱/۱۱
	میانگین	۰/۸۶	۰/۷۹	۵/۰۶	۰/۰۰	۰/۴۷	۰/۱۳
	انحراف معیار	۰/۳۸	۰/۶۳	۳/۹۳	۰/۰۰	۰/۴۵	۱/۲۰

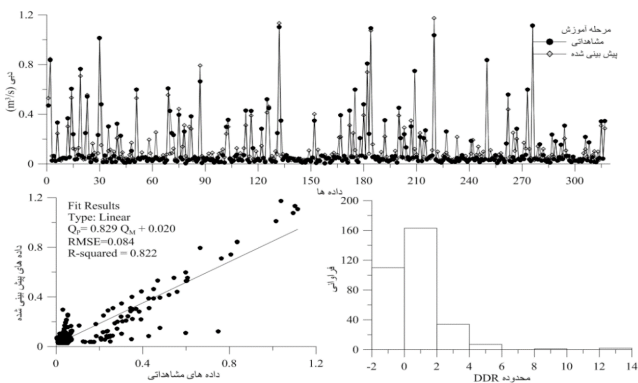
1 R-Squared ( $R^2$ )

2 Root Mean Square Error (RMSE)




شکل ۵. نتایج ارزیابی روش های تجربی

Fig. 5. The results of analytical approaches



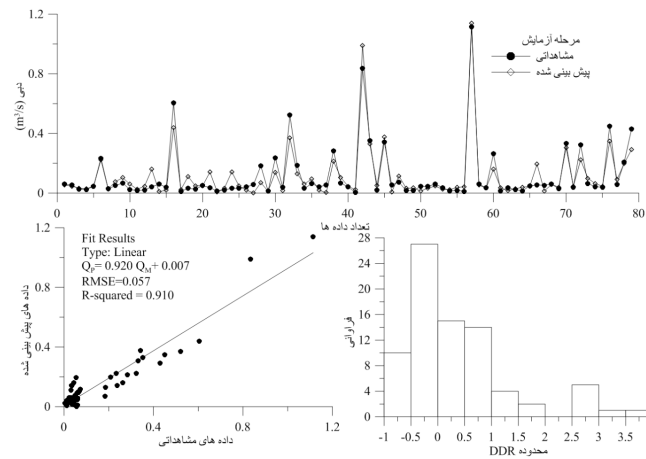
شکل ۷. عملکرد روش دسته بندی گروهی داده ها در مرحله آموزش

Fig. 7. Performance of GMDH in training stage



شکل ۶. مدل استخراج شده از روش دسته بندی گروهی داده ها

Fig. 6. Schematic of the design of GMDH model



شکل ۸. عملکرد روش دسته‌بندی گروهی داده‌ها در مرحله آزمایش


Fig. 8. Performance of GMDH in testing stage

جدول ۳. ضرایب تابع محرک روش دسته‌بندی گروهی داده‌ها

Table 3. The coefficient of transfer (activated) function of GMDH

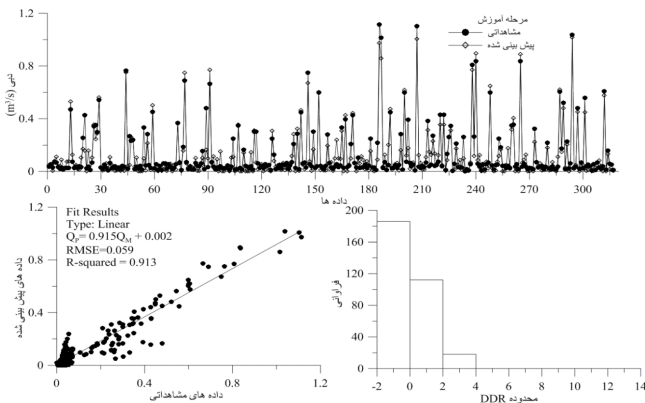
ضرایب تابع							
شماره لایه	نرون	$b_0$	$b_1$	$b_2$	$b_3$	$b_4$	$b_5$
۱	۱	۰/۰۹	-۴۵۱/۰۳	۰/۶۴	۲۲۵۹۷۲/۰۷	۰/۰۵	-۳۷۹/۳۱
	۲	۰/۳۵	-۰/۰۸	۰/۳۲	۰/۰۲	-۰/۰۳	-۱/۴۳
	۳	۰/۴۰	-۰/۱۵	-۵۶۶/۰۴	۰/۰۳	۱۸۸۷۶۵/۴۹	۸۶/۲۴
	۴	۰/۱۰	-۰/۰۹	-۰/۰۶	۰/۰۴	-۰/۰۱	۰/۲۷
۲	۱	-۰/۰۲	۰/۳۷	۰/۳۱	۰/۸۱	۰/۶۳	۰/۹۰
	۲	۰/۰۳	۰/۲۷	-۰/۳۸	۱/۵۱	۳/۱۳	-۰/۹۱
	۳	۰/۰۷	-۰/۰۷	-۰/۴۶	۰/۸۵	۱/۰۸	۴/۵۷
	۴	-۰/۰۳	۰/۹۶	۰/۴۰	۰/۳۷	۰/۴۶	-۱/۳۹
۳	۱	-۰/۰۲	۰/۳۱	۰/۷۵	۰/۳۶	-۰/۳۲	۰/۳۲
	۲	-۰/۰۲	۰/۹۳	۰/۲۰	-۰/۰۹	۰/۸۸	-۰/۷۰
	۳	-۰/۰۳	۰/۴۳	۰/۸۴	۴/۳۱	۲/۶۲	-۷/۴۱
	۴	-۰/۰۱	۱/۵۳	-۰/۳۱	-۶/۹۲	-۵/۲۱	۱۲/۲۸
۴	۱	۰/۰۰	۰/۴۱	۰/۵۷	-۰/۲۱	-۱/۸۳	۲/۰۸
	۲	-۰/۰۱	۰/۵۱	۰/۷۶	-۶/۶۲	-۳/۷۰	۹/۸۲
	۳	۰/۰۰	۱/۱۷	-۰/۲۱	-۰/۷۸	۰/۱۹	۰/۷۴
	۴	۰/۰۰	۱/۲۵	-۰/۱۵	-۲/۲۵	-۱/۵۴	۳/۸۰
۵	۱	۰/۰۳	۱/۵۱	-۰/۹۲	-۳/۵۷	-۱/۷۰	۶/۲۰
	۲	۰/۰۱	۱/۵۱	-۰/۶۵	-۳/۰۲	۰/۸۵	۲/۴۱
	۳	-۰/۰۱	۰/۵۷	۰/۵۴	۳/۸۳	۴/۰۵	-۸/۰۶





شکل ۹. ساختار منتخب برای شبکه عصبی چندلایه توسعه داده شده

Fig. 9. Schematic of the design of a multi-layer neural network model



شکل ۱۰. عملکرد مدل شبکه عصبی در مرحله آموزش

Fig. 10. Performance of neural network model in training stage

### ۳-۳- مدل شبکه عصبی چندلایه

همان‌طور که اشاره شد شبکه عصبی چندلایه یکی از پرکاربردترین مدل‌های هوش مصنوعی در مدل‌سازی پدیده‌های مهندسی است. ورودی‌های مدل شبکه عصبی در ضرایبی (وزن) ضرب شده و سپس با یک مقدار ثابت جمع می‌شوند. سپس تابع انتقال بر روی حاصل آن جمع می‌شود. طراحی مدل شبکه عصبی چندلایه شامل چند مرحله است که عبارتند از: تعریف تعداد لایه‌های مدل شامل لایه ورودی، لایه(های) پنهان، لایه خروجی، تعداد نرون در هر لایه، تعریف تابع فعال انتقال و همچنین در نهایت انتخاب روش آموزش شبکه عصبی. خلاصه‌ای از مراحل طراحی مدل شبکه عصبی چند لایه جهت پیش‌بینی دبی جریان عبوری از کانال‌های مرکب در جدول ۴ ارائه شده است. همان‌طور که از این شکل مشخص است، تابع tansing بهترین عملکرد را در میان توابع انتقال ارزیابی شده دارد. همچنین این جدول نشان می‌دهد که افزایش تعداد نرون‌های با تابع فعال‌سازی tansing تأثیر قابل ملاحظه‌ای در افزایش دقت مدل ندارد. ساختار منتخب مدل شبکه عصبی چندلایه در شکل ۹ نشان داده شده است. عملکرد شبکه عصبی توسعه داده شده در مراحل توسعه و صحت‌سنجی در شکل‌های ۱۰ و ۱۱ نشان داده شده است. همان‌طور که مشاهده می‌گردد، دقت مدل شبکه عصبی توسعه داده شده جهت پیش‌بینی دبی جریان مناسب است. مقایسه عملکرد شبکه عصبی توسعه داده شده با روش دسته‌بندی گروهی داده‌ها نشان می‌دهد که دقت مدل شبکه عصبی در هر دو مرحله توسعه بهتر ولی دقت مدل دسته‌بندی گروهی داده‌ها در مرحله صحت‌سنجی مدل یک مقدار جزئی بهتر است. نکته مهم در رابطه با توسعه مدل شبکه عصبی این است که در فرآیند مدلسازی پارامترهایی که بیشترین تأثیر را دارند مشخص نمی‌شوند و نیاز است که مدل توسعه داده شده آنالیز حساسیت شود.

### جدول ۴. خلاصه‌ای از طراحی مدل شبکه عصبی چند لایه

Table 4. Summary of the design of a multi-layer neural network model

آزمایش	آموزش			ردیف		
	ضریب تبیین	ریشه میانگین مربعات خطا	ضریب تبیین	تعداد نرون	تابع انتقال و تعداد نرون	در لایه پنهان
۰/۲۴۶	۰/۳۳۰	۰/۱۵۸	۰/۶۴۰	۱	5-Purelin	۱
۰/۰۸۶	۰/۸۴۵	۰/۰۹۳	۰/۸۶۵	۱	5-radbas	۲
۰/۱۵۳	۰/۶۹۸	۰/۱۲۵	۰/۷۴۱	۱	5-logsig	۳
۰/۰۸۴	۰/۷۹۰	۰/۰۷۸	۰/۸۸۹	۱	5-tansig	۴
۰/۰۶۵	۰/۸۲۰	۰/۰۵۹	۰/۹۱۳	۱	7-tansig	۵
۰/۰۶۱	۰/۸۲۰	۰/۰۵۳	۰/۹۲۳	۱	9-tansig	۶

و عملکرد آن دوباره مورد بررسی قرار می‌گیرد. هر پارامتری که بیشترین تأثیر را در کاهش دقت مدل‌سازی دارد تأثیر بیشتری در پدیده مورد نظر دارد. نتایج حاصل از آنالیز حساسیت مدل شبکه عصبی در جدول ۵ نشان داده شده است. بررسی نتایج آنالیز تحلیل حساسیت نشان می‌دهد که پارامترهای شیب طولی، عمق و مساحت نسبی بیشترین تأثیر را در دقت پیش بینی دبی جریان در کانال‌های مرکب دارند.

### ۳-۴- تحلیل حساسیت شبکه عصبی

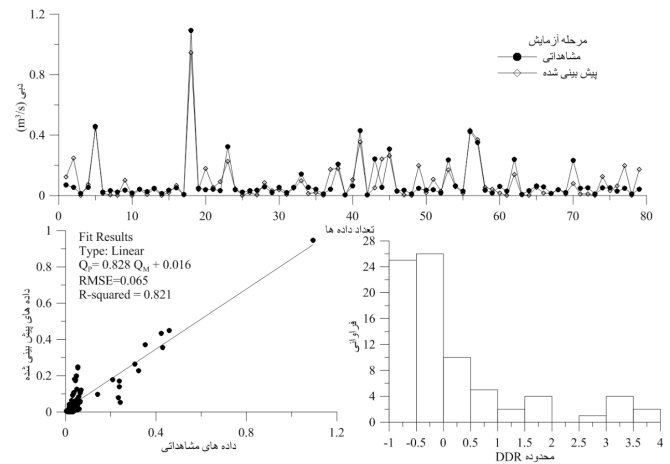
در این تحقیق برای آنالیز حساسیت مدل شبکه عصبی رهیافتی که توسط عظمت اله و همکاران [۳] پیشنهاد شده، مورد استفاده قرار گرفت. این روش بدین صورت است که با توجه به ساختار منتخب شبکه عصبی عملکرد مدل در مراحل توسعه و آزمایش مورد تحلیل قرار می‌گیرد. سپس یکی از متغیرهای ورودی حذف شده و دوباره مدل مورد ارزیابی قرار می‌گیرد

### جدول ۵. نتایج حاصل از آنالیز حساسیت

Table 5. he results of sensivity analysis

ردیف	پارامتر غایب	ورودی‌ها	خروجی	ضریب تعیین	ریشه میانگین مربعات خطا
۱	-	زبری نسبی	دبی جریان	۰/۸۲۱	۰/۰۶۵
		سطح مقطع نسبی			
		شعاع هیدرولیکی نسبی			
		شیب طولی			
		عمق نسبی			
۲	زبری نسبی	سطح مقطع نسبی	دبی جریان	۰/۷۹۳	۰/۰۸۷
		شعاع هیدرولیکی نسبی			
		شیب طولی			
		عمق نسبی			
		زبری نسبی			
۳	سطح مقطع نسبی	شعاع هیدرولیکی نسبی	دبی جریان	۰/۵۶۸	۰/۲۵۳
		شیب طولی			
		عمق نسبی			
		زبری نسبی			
		سطح مقطع نسبی			
۴	شعاع هیدرولیکی نسبی	زبری نسبی	دبی جریان	۰/۷۸۶	۰/۰۸۱
		سطح مقطع نسبی			
		شیب طولی			
		عمق نسبی			
		زبری نسبی			
۵	شیب طولی	زبری نسبی	دبی جریان	۰/۷۴۳	۰/۱۱۳
		سطح مقطع نسبی			
		شعاع هیدرولیکی نسبی			
		عمق نسبی			
		زبری نسبی			
۶	عمق نسبی	زبری نسبی	دبی جریان	۰/۶۲۵	۰/۱۹۸
		سطح مقطع نسبی			
		شعاع هیدرولیکی نسبی			
		شیب طولی			
		زبری نسبی			

- [2] S. Atabay, D. Knight, 1-D modelling of conveyance, boundary shear and sediment transport in overbank flow, *Journal of Hydraulic Research*, 44(6) (2006) 739-754.
- [3] H.M. Azamathulla, A.H. Haghiabi, A. Parsaie, Prediction of side weir discharge coefficient by support vector machine technique, *Water Science and Technology: Water Supply*, 16(4) (2016) 1002-1016.
- [4] H. Bashiri-Atrabi, K. Qaderi, D.E. Rheinheimer, E. Sharifi, Application of harmony search algorithm to reservoir operation optimization, *Water Resources Management*, 29(15) (2015) 5729-5748.
- [5] D. Bousmar, Y. Zech, Momentum transfer for practical flow computation in compound channels, *Journal of hydraulic engineering*, 125(7) (1999) 696-706.
- [6] P. Conway, J.J. O'Sullivan, M.F. Lambert, Stage-discharge prediction in straight compound channels using 3D numerical models, *Proceedings of the Institution of Civil Engineers, Water*
- [7] Management, 166 (1) (2012) 3-15.
- [8] M. Filonovich, R. Azevedo, L. Rojas-Solórzano, J. Leal, Credibility analysis of computational fluid dynamic simulations for compound channel flow, *Journal of Hydroinformatics*, 15(3) (2013) 926-938.
- [9] F. Huthoff, P.C. Roos, D.C. Augustijn, S.J. Hulscher, Interacting divided channel method for compound channel flow, *Journal of hydraulic engineering*, 134(8) (2008) 1158-1165.
- [10] S. Ikeda, I.K. McEwan, Flow and sediment transport in compound channels: the experience of Japanese and UK research, CRC Press, 2009.
- [11] A.G. Ivakhnenko, Polynomial theory of complex systems, *IEEE transactions on Systems, Man, and Cybernetics*, 1(4) (1971) 364-378.
- [12] K. Khatua, K. Patra, P. Mohanty, Stage-discharge prediction for straight and smooth compound channels with wide floodplains, *Journal of hydraulic Engineering*, 138(1) (2011) 93-99.
- [13] D. Knight, J. Demetriou, M. Hamed, Stage discharge relationships for compound channels, in: *Channels and Channel Control Structures*, Springer Berlin Heidelberg, (1984) 445-459.
- [14] T. Koftis, P. Prinos, Reynolds stress modelling of flow in compound channels with vegetated floodplains, *Journal of Applied Water Engineering and Research*, (2016) 1-11.



شکل ۱۱. عملکرد مدل شبکه عصبی در مرحله آزمایش

Fig. 11. Performance of neural network model in testing stage

#### ۴- نتیجه گیری

در این تحقیق، دبی جریان در کانال مرکب مستقیم با استفاده از روش‌های تجربی، روش‌های رایانش نرم مانند روش دسته‌بندی گروهی داده‌ها و شبکه عصبی چند لایه مدل‌سازی و پیش‌بینی شد. نتایج نشان داد که روش تقسیم مقطع افقی بیشترین دقت را با شاخص خطای ریشه میانگین مربعات خطای ۰/۱۶۲ در میان روش‌های تجربی دارد. نتایج توسعه روش دسته‌بندی گروهی داده‌ها نشان داد که این مدل با ریشه میانگین مجذورات خطای ۰/۰۸۴ و ۰/۰۵۴ در مراحل توسعه (تهیه و اعتبارسنجی) دقت مناسبی در تخمین دبی جریان در کانال‌های مرکب دارد. ساختار روش دسته‌بندی گروهی داده‌های به کار گرفته شده نشان داد که عمق و سطح نسبی جریان بیشترین تأثیر را در مدل‌سازی ظرفیت کانال‌های مرکب دارند. نتایج به کارگیری شبکه عصبی چندلایه هم نشان داد که این مدل با داشتن شاخص خطای ریشه میانگین مجذورات خطای برابر با ۰/۰۵۹ و ۰/۰۶۵ در مراحل توسعه و صحت‌سنجی عملکرد مناسبی در تخمین دبی جریان در کانال مرکب دارد. مقایسه دو مدل هوش مصنوعی به کار گرفته شده نشان می‌دهد که دقت روش دسته‌بندی گروهی داده‌ها کمی بهتر است. نتایج تحلیل حساسیت مدل شبکه عصبی چندلایه نشان داد که پارامترهای شیب طولی، عمق و مساحت نسبی بیشترین تأثیر را در دقت پیش‌بینی دبی جریان در کانال‌های مرکب دارند که این ساختار به دست آمده برای روش دسته‌بندی گروهی داده‌ها را تأیید می‌نماید.

#### مراجع

- [1] P. Ackers, Flow formulae for straight two-stage channels, *Journal of Hydraulic Research*, 31(4) (1993) 509-531.

- [24] A. Parsaie, S. Najafian, H. Yonesi, Flow discharge estimation in compound open channel using theoretical approaches, *Sustainable Water Resources Management*, 2(4) (2016) 359-367.
- [25] A. Parsaie, H. Yonesi, S. Najafian, Prediction of flow discharge in compound open channels using adaptive neuro fuzzy inference system method, *Flow Measurement and Instrumentation*, 54 (2017) 288-297.
- [26] A. Parsaie, H.A. Yonesi, S. Najafian, Predictive modeling of discharge in compound open channel by support vector machine technique, *Modeling Earth Systems and Environment*, 1(1-2) (2015) 1.
- [27] M. Sahu, K. Khatua, S. Mahapatra, A neural network approach for prediction of discharge in straight compound open channel flow, *Flow Measurement and Instrumentation*, 22(5) (2011) 438-446.
- [28] K. Shiono, D.W. Knight, Turbulent open-channel flows with variable depth across the channel, *Journal of Fluid Mechanics*, 222 (1991) 617-646.
- [29] G. Seckin, A comparison of one-dimensional methods for estimating discharge capacity of straight compound channels, *Canadian Journal of Civil Engineering*, 31(4) (2004) 619-631.
- [30] X. Tang, D.W. Knight, Lateral distributions of streamwise velocity in compound channels with partially vegetated floodplains, *Science in China Series E: Technological Sciences*, 52(11) (2009) 3357-3362.
- [31] P. Wormleaton, D. Merrett, An improved method of calculation for steady uniform flow in prismatic main channel/flood plain sections, *Journal of Hydraulic Research*, 28(2) (1990) 157-174.
- [32] H.A. Yonesi, M.H. Omid, S.A. Ayyoubzadeh, The hydraulics of flow in non-prismatic compound channels, *J Civil Eng Urban*, 3(6) (2013) 342-356.
- [33] C.L. Yen, D.E. Overton, Shape Effects on Resistance in Flood Plain Channels, *Journal of the Hydraulics Division, ASCE*, 99 (HY1) (1973) 21 9-238.
- [15] H. Kordi, R. Amini, A. Zahiri, E. Kordi, Improved Shiono and Knight method for overflow modeling, *Journal of Hydrologic Engineering*, 20(12) (2015) 04015041.
- [16] A. Mohanta, K. Khatua, K. Patra, Flow Modeling in Symmetrically Narrowing Flood Plains, *Aquatic Procedia*, 4 (2015) 826-833.
- [17] M. Najafzadeh, G.-A. Barani, H.M. Azamathulla, GMDH to predict scour depth around a pier in cohesive soils, *Applied ocean research*, 40 (2013) 35-41.
- [18] M. Najafzadeh, M.R. Balf, E. Rashedi, Prediction of maximum scour depth around piers with debris accumulation using EPR, MT, and GEP models, *Journal of Hydroinformatics*, 18(5) (2016) 867-884.
- [19] M. Najafzadeh, A.M. Sattar, Neuro-fuzzy GMDH approach to predict longitudinal dispersion in water networks, *Water Resources Management*, 29(7) (2015) 2205-2219.
- [20] M. Najafzadeh, A. Tafarojnoruz, Evaluation of neuro-fuzzy GMDH-based particle swarm optimization to predict longitudinal dispersion coefficient in rivers, *Environmental Earth Sciences*, 75(2) (2016) 157.
- [21] M. Najafzadeh, A.R. Zahiri, Neuro-fuzzy GMDH-based evolutionary algorithms to predict flow discharge in straight compound channels, 20(12) (2015) 04015035.
- [22] A. Parsaie, A.H. Haghiabi, Predicting the longitudinal dispersion coefficient by radial basis function neural network, *Modeling earth systems and environment*, 1(4) (2015) 34.
- [23] A. Parsaie, S. Najafian, M.H. Omid, H. Yonesi, Stage discharge prediction in heterogeneous compound open channel roughness, *ISH Journal of Hydraulic Engineering*, 23(1) (2017) 49-56.

Please cite this article using:

A. Parsaie, Sh. Najafian, A. Zahiri, Prediction of flow discharge in compound open channels using group method of data handling, *Amirkabir J. Civil Eng.*, 51(4) (2019) 645-656.

DOI: 10.22060/ceej.2018.13841.5488

برای ارجاع به این مقاله از عبارت زیر استفاده کنید:

