

بررسی عملکرد روش‌های کلاسیک و هوش مصنوعی در تخمین ضریب زبری در پیچان‌رودها

کیومرث روشننگر^{۱*}، رقیه قاسم‌پور^۲

تاریخ دریافت: ۱۳۹۶/۱۰/۱۴ تاریخ پذیرش: ۱۳۹۷/۲/۱۷

چکیده

برآورد دقیق ضریب زبری رودخانه‌ها همواره از مسایل مهم و اساسی در مدل‌سازی هیدرولیک رودها می‌باشد. در تحقیق کنونی از روش‌های هوشمند ماشین‌بردار پشتیبان (SVM) و سیستم استنتاج تطبیقی عصبی-فازی (ANFIS) جهت تخمین زبری هیدرولیکی پیچان‌رودها استفاده گردید و تأثیر پارامترهای مختلفی از قبیل شیب کانال، میزان سینوسی بودن کانال و هم‌چنین پارامترهای هیدرولیکی مانند عدد رینولدز جریان در تعیین زبری این نوع کانال‌ها مورد بررسی قرار گرفت. از طرف دیگر، نتایج حاصل با روش‌های کلاسیک مقایسه گردید. جهت مدل‌سازی ضریب زبری از دو سری داده آزمایشگاهی مربوط به کانال‌های سینوسی شکل استفاده گردید. نتایج حاصله نشان داد که روش‌های هوشمند SVM و ANFIS در تخمین ضریب زبری مانینگ در رودخانه‌های طبیعی نسبت به فرمول‌های نیمه‌تجربی دقیق‌تر و قابل‌اعتمادتر می‌باشند. ملاحظه گردید که در تخمین ضریب زبری مانینگ مدل با پارامترهای ورودی α (ضریب شکل)، Sr (ضریب مارپیچی)، S_0 (شیب کانال) و Re (عدد رینولدز) منجر به جواب‌های دقیق‌تری می‌گردد. نتایج به‌دست آمده نشان داد که در تخمین ضریب زبری در پیچان‌رودها، تأثیر پارامتر ضریب شکل در افزایش دقت مدل‌ها از ضریب سینوسی بیش‌تر است. هم‌چنین نتایج تحلیل حساسیت نشان داد که شیب کانال تأثیرگذارترین پارامتر در تخمین ضریب زبری در پیچان‌رودها است.

واژه‌های کلیدی: رودخانه، روش‌های هوش مصنوعی، ضریب مانینگ، ANFIS

مقدمه

علاوه بر دانه‌بندی ذرات بستر مشخصات هیدرولیکی جریان نیز در تخمین ضریب زبری موثر می‌باشد. روش‌شنی و همکاران (۱۳۹۵) با انجام آزمایشاتی به بررسی ضریب زبری در رودخانه‌های دارای فرم بستر پرداختند. در این آزمایشات دبی، شیب و عمق جریان چندین بار تغییر کرده و تأثیر آن‌ها بر روی مقاومت جریان مطالعه شد. نتایج نشان داد که با تشدید پارامترهای جریان و در نتیجه تشدید ایجاد تلاطم در پایین دست فرم بستر، مقاومت جریان افزایش می‌یابد. چنانچه با استفاده از آنالیز ابعادی فرمولی را برای کانال‌های مارپیچی با درجه سینوسی کم ارائه داد (Jena., 2006). خاتو و پاترا نشان دادند که ساختار جریان در کانال‌های مارپیچی در مقایسه با کانال‌های مستقیم بسیار پیچیده‌تر است (Patra and Khatua., 2006). یانگ و همکاران به‌صورت تجربی مقاومت جریان در کانال‌های مارپیچی را مورد بررسی قرار دادند (Yang et al., 2007). ژنگ و همکاران کاربرد روش‌های تحلیلی را در تعیین مقاومت جریان در کانال‌های ترکیبی دوزنقه‌ای بررسی نمودند (Zeng et al., 2010). خاتو و همکاران ضریب زبری در رودخانه‌های مارپیچی و مستقیم را مورد بررسی قرار دادند. نتایج تحقیق نشان داد که در رودخانه‌های مارپیچی میزان تغییر در ضریب زبری به ازای تغییر در هندسه کانال، عمق جریان و شیب بستر بیش‌تر از رودخانه مستقیم می‌باشد (Khatua et

رودخانه‌ها منبع اصلی آب برای آشامیدن، آبیاری و استفاده‌های صنعتی هستند. اطلاع دقیق از دبی جریان و میزان افت انرژی در مسیر رودخانه‌ها، اهمیت بسیاری در درک ویژگی‌های رودخانه، حفاظت آن و مدیریت سیلاب دارد. بنابراین، تخمین قابل‌قبول ضریب مقاومت جریان یک پارامتر کاربردی و پراهمیت در طرح‌های مرتبط با رودخانه‌ها است. با این حال، تخمین دقیق ضریب زبری به خاطر تأثیر ترکیبی پارامترهای مختلفی مانند شیب کانال، مقاومت سطح، تراز و هندسه‌ی کانال دشوار است (Zeng et al., 2010). برای تعیین مقاومت جریان در رودخانه، مطالعات وسیعی توسط محققین مختلف صورت گرفته است. حسین‌زاده (۱۳۸۲) با بررسی دو روش سازمان حفاظت خاک آمریکا (SCS) و چاو بیان نمود که روش سازمان حفاظت خاک آمریکا نسبت به روش دیگر در تعیین ضریب مانینگ موفق‌تر است (Chaw., 1959). عباسی و ملک‌نژاد (۱۳۹۱) به بررسی ضریب زبری در رودخانه‌ها پرداختند. نتایج کار آن‌ها نشان داد که

۱- دانشیار گروه آب دانشکده عمران دانشگاه تبریز

۲- دانشجوی دکتری عمران مهندسی و مدیریت منابع آب دانشگاه تبریز

(Email: kroshangar@yahoo.com)

*- نویسنده مسئول:

پروژه‌های منابع آبی و سیستم‌های رودخانه‌ای دارد. از طرفی به خاطر پیچیدگی و عدم قطعیت موجود در پدیده ضریب زبری، روابط نیمه تجربی موجود از دقت کافی برخوردار نبوده و در بیش‌تر موارد نتایج حاصله با خطاهای بزرگی همراه است. مقاله حاضر روش‌های هوشمند SVM و ANFIS را جهت پیش‌بینی ضریب زبری مانینگ در پیچان‌رودها و درک بهتر مکانیزم مقاومت جریان در این نوع کانال‌ها به‌کار برده است. در این راستا، مدل‌های ورودی متفاوتی بر اساس دو سری داده آزمایشگاهی تعریف گردید و تاثیر مدل‌سازی متفاوت در تعیین ضریب زبری بررسی شد. با استفاده از آنالیز حساسیت پارامترهای موثر در تخمین این پارامتر شناسایی شد، در نهایت نتایج حاصل از این روش‌ها با روابط کلاسیک موجود مقایسه گردید.

مواد و روش‌ها

ماشین بردار پشتیبان SVM

الگوریتم SVM، جزو الگوریتم‌های تشخیص الگو دسته‌بندی می‌شود که برای اولین بار توسط وپنیک در سال ۱۹۹۵ معرفی شد (Vapnik., 1995). نحوه کارکرد الگوریتم SVM به‌مانند اغلب روش‌های هوشمند به‌صورت آموزش (Train) و آزمون (Test) می‌باشد. مزیتی که SVM نسبت به سایر الگوریتم‌ها دارد این است که این الگوریتم مینی بر احتمالات نمی‌باشد و همواره جواب یک‌ای به همراه دارد و زمان کم‌تری را برای دستیابی به جواب بهینه به خود اختصاص می‌دهد. از الگوریتم SVM، در هر جایی که نیاز به تشخیص الگو یا دسته‌بندی اشیاء در کلاس‌های خاص باشد می‌توان استفاده کرد. در واقع مبنای کاری SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌شود خطی انتخاب شود که حاشیه اطمینان بیش‌تری داشته باشد (شکل ۱). در واقع هدف الگوریتم SVM این است که خطی را بیابد که از داده‌های موجود در دو کلاس دارای بیش‌ترین فاصله باشد و یا به عبارت دیگر دارای کم‌ترین ریسک عملیاتی باشد. در مرحله بعد دو صفحه مرزی موازی با صفحه تفکیک کننده رسم می‌شود و تا زمانی که به داده‌ها برخورد کنند از هم دور می‌شوند. صفحه تفکیک کننده‌ای که بیش‌ترین فاصله را از صفحات دسته‌بندی داشته باشد بهترین صفحه تفکیک کننده است. نزدیک‌ترین داده‌های آموزشی به صفحات تفکیک کننده، بردار پشتیبان نامیده می‌شود. در مسایل یک داده‌ها به‌صورت خطی جداپذیر نباشند، داده‌ها به فضایی با ابعاد بیش‌تر نگاشت پیدا می‌کنند تا بتوان آن‌ها را در این فضای جدید به‌صورت خطی جدا نمود. این کار با دخالت تابع کرنل $K(x)$ که وظیفه‌ی نگاشت داده‌ها از فضای غیرخطی به فضای خطی را بر عهده دارد، حاصل می‌شود. پس تابع K را نگاشتی است که داده‌های فضای X را به فضای Z خواهد برد.

al., 2011). مهاران و همکاران با انجام کار آزمایشگاهی به بررسی ضریب زبری در کانال‌های روباز سینوسی شکل پرداختند. در این تحقیق تأثیر پارامترهای مختلفی از قبیل شیب بستر، عدد رینولدز جریان و میزان سینوسی بودن کانال مورد بررسی قرار گرفت و نتایج نشان داد که با تغییر در مقدار این پارامترها، مقدار ضریب زبری نیز تغییر خواهد کرد (Moharana et al., 2013). روشنگر و همکاران با استفاده از داده‌های آزمایشگاهی به مطالعه ضریب زبری در کانال‌های روباز پرداختند و به این نتیجه رسیدند که هر دو مشخصات جریان و ذرات بستر در پیش‌بینی این پارامتر موثر می‌باشند (Roushangar et al., 2018). نتایج حاصل از این مطالعات به دلیل آن که مقاومت جریان بستگی به پارامترهای متعددی دارد، عموماً باهم متفاوت بوده و گاهی با تفاوت‌های فاحشی همراه است. این امر حاکی از عدم قطعیت در پدیده مورد نظر و پیچیدگی ذاتی آن است.

بنابراین استفاده از روش‌هایی که بتوانند پارامتر ضریب زبری را با اطمینان بالاتری تخمین بزنند ضروری به‌نظر می‌رسد. در دهه‌های اخیر استفاده از روش‌های هوش مصنوعی در بسیاری از زمینه‌ها به‌ویژه در پروژه‌های مهندسی آب گسترش یافته است. روش‌های هوش مصنوعی می‌توانند برای پیش‌بینی هرگونه متغیری که در آن رابطه بین متغیرهای مربوطه به‌خوبی درک نمی‌شود، پیدا کردن اندازه و شکل راه‌حل نهایی دشوار است، و روش‌های تحلیلی ریاضی رایج قادر به حل آن‌ها نبوده و یا بسیار زمان‌بر هستند، استفاده شوند (Banzhaf et al., 1998). این روش‌ها که الهام گرفته از قوانین طبیعت می‌باشند به‌عنوان ابزاری توانمند در حل مسایل پیچیده به‌شمار می‌آیند. از جمله این روش‌ها می‌توان به شبکه‌های عصبی مصنوعی (ANN)، برنامه‌ریزی ژنتیک (GP)، ماشین بردار پشتیبان (SVM) و مدل‌های فازی (NF) اشاره کرد.

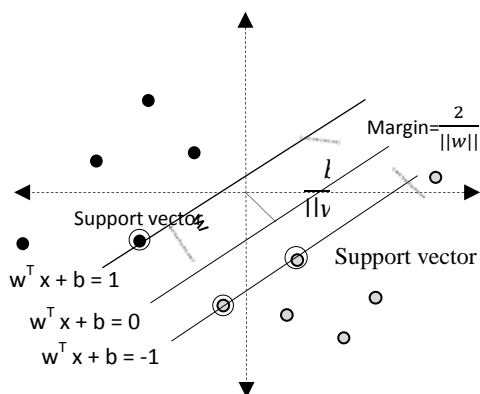
از روش ماشین بردار پشتیبان (SVM) که گزینه خوبی برای تکنیک‌های پیش‌بینی بر مبنای رگرسیون می‌باشد و هم‌چنین روش سیستم استنتاج فازی - عصبی انطباقی (ANFIS) که ترکیب شبکه‌های عصبی و سیستم فازی بر مبنای ریاضیات فازی بوده و قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد، برای پیش‌بینی پارامترهای هیدرولیکی و هیدرولوژی مختلف استفاده گردیده است که از آن جمله می‌توان به تخمین میزان بارش - رواناب (Kisi et al., 2013)، تخمین سطح آب دریاچه (Lan., 2014)، پیش‌بینی میزان تبخیر در ایستگاه‌های هواشناسی (Shiri et al., 2011)، بررسی جریان در لوله‌ها (Shau and Khatua., 2012)، تخمین عمق آبستگي (Najafzadeh et al., 2016)، تخمین بار بستر در مقاطع دایروی شکل (Roushangar and Ghasempour., 2017) و تخمین مشخصات پرش هیدرولیکی در کانال‌های واگرا (Roushangar et al., 2017) اشاره کرد. پیش‌بینی دقیق ضریب زبری در رودخانه‌ها نقش مهمی در برنامه‌ریزی، طراحی و بهره‌برداری

بسیار مهم می‌باشد و انتخاب آن به نوع و ماهیت مسئله بستگی دارد؛ بنابراین نمی‌توان تابعی را به‌طور قطعی به‌عنوان تابع مناسب برای SVM معرفی کرد. نسبت به شرایط این موضوع می‌تواند متغیر باشد. انواع مختلف توابع کرنل در جدول ۱ نمایش داده شده است. مطابق با جدول ۱ توابع کرنل SVM دارای پارامترهای مختلفی (γ, d, α, c) است که نحوه تنظیم آن‌ها در حصول جواب هرچه بهتر مسئله بسیار موثر است.

معادله کلی صفحه تفکیک کننده به‌صورت $W^T Z + b = 0$ بیان می‌گردد. که در آن b مقدار بایاس و بردار W فاکتور وزن نامیده می‌شود و W^T بیانگر ترانهاده بردار W است. با دخالت تابع کرنل $K(x)$ معادله‌ی تفکیک کننده به‌صورت رابطه ۱ تبدیل می‌شود:

$$K : X \rightarrow Z \quad Z = K(x) \quad W^T K(x) + b = 0 \quad (1)$$

می‌توان برای این تابع حالتی کلی‌تر به‌صورت $K(x_i, x_j)$ تعریف کرد که به‌وسیله‌ی آن بتوان به فضاهای پیچیده‌تر راه یافت. به فرآیند مذکور ترفند کرنل می‌گویند. در مسایل SVM انتخاب تابع کرنل



شکل ۱- جداسازی داده‌ها در SVM و بردارهای پشتیبان

جدول ۱- انواع تابع کرنل

نوع کرنل	تابع کرنل	پارامتر کرنل
Linear	$K(x_i, x_j) = (x_i, x_j)$	-
Polynomial	$K(x_i, x_j) = [(x_i, x_j) + 1]^d$	d
RBF	$K(x_i, x_j) = \exp\left[-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right]$	γ
Sigmoid	$K(x_i, x_j) = \tanh[-\alpha(x_i, x_j)] + c$	α, c

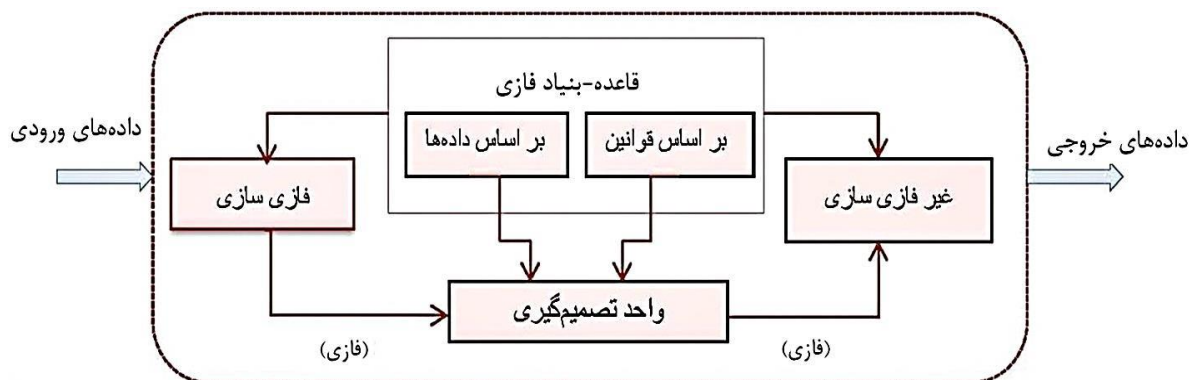
عصبی - انطباقی روشی را برای ایجاد یک رویه مدل‌سازی فازی در راستای یادگیری اطلاعات از یک مجموعه داده فراهم می‌آورند. جعبه‌ابزار منطق فازی پارامترهای تابع عضویت را طوری محاسبه می‌کند که سیستم استنتاج فازی بر مجموعه داده‌های ورودی - خروجی منطبق گردد. چنین فرآیندی به‌وسیله منطق فازی و ابزارهای آن انجام می‌شود. مجموعه‌های فازی، توابع عضویت، عملگرهای منطقی و قوانین اگر - سپس، مولفه‌های فرآیند سیستم استنتاج فازی است. روش سیستم استنتاج عصبی - فازی انطباقی (ANFIS) روشی ترکیبی است که در آن بخش فازی رابطه بین متغیرهای ورودی و خروجی را برقرار می‌نماید و مشخصه‌های مربوط به توابع عضویت بخش فازی نیز به‌وسیله شبکه عصبی تعیین می‌شود (Jang., 1993).

سیستم استنتاج عصبی - فازی انطباقی ANFIS

شبکه‌های عصبی (ANN) از شمار زیادی عناصر پردازش شیبه بهم پیوسته به نام نرون ساخته شده‌اند که به‌صورت موازی در کنار هم عمل می‌کنند. این عناصر، تقلیدی بسیار ساده از فرآیندی است، که توسط شبکه عصبی بیولوژیکی انجام می‌پذیرد. در طبیعت، عملکرد شبکه‌های عصبی از طریق نحوه اتصال بین اجزا تعیین می‌شود. شبکه‌های عصبی مصنوعی می‌توانند نگاشت یا تبدیل از فضای چندبعدی به فضای چندبعدی دیگر را انجام دهند و قابلیت‌هایی مانند شناسایی الگو، تفکیک الگو، نگاشت غیرخطی، حافظه انجمنی، خود سازمان‌دهی و کنترل را دارا هستند. یادگیری عصبی - انطباقی دارای عملکردی مشابه با شبکه‌های عصبی است. تکنیک‌های یادگیری

مربعات تنظیم می‌شوند. این عملیات تنظیم، به سیستم‌های فازی اجازه می‌دهد تا ساختار خود را از مجموعه داده‌ها فراگیرد. در این مدل شبکه عصبی و سیستم فازی در یک ساختار هماهنگ با یکدیگر ترکیب می‌شوند. در واقع این مدل را می‌توان شبکه عصبی با پارامتر فازی و یا یک سیستم فازی با یادگیری توزیع شده دانست. بنابراین با ترکیب این دو، سیستم‌های فازی قالب قدرتمندی برای نمایش دانش متخصص فراهم می‌نمایند و سبب افزایش توان یادگیری شبکه عصبی می‌گردند. در شکل ۲ شماتیک الگوریتم سیستم استنتاج فازی نشان داده شده است. نحوه‌ی توسعه سیستم استنتاج عصبی-فازی انطباقی بدین صورت است: تعریف متغیرهای ورودی و خروجی، تصمیم‌گیری درباره بخش‌های فازی فضاهای ورودی و خروجی، انتخاب توابع تعلق برای متغیرهای ورودی و خروجی، تصمیم‌گیری درباره نوع قوانین کنترلی فازی، طراحی مکانیسم استنتاج و انتخاب یک روش غیرفازی سازی.

روند کار به این صورت است که ابتدا ساختار مدل با مشخصه‌های مشخص، که متناسب با ورودی‌ها، درجه عضویت و قوانین و توابع درجه عضویت خروجی است، انتخاب می‌شود. سپس بخشی از داده‌های موجود به عنوان ورودی-خروجی که قابل استفاده برای آموزش این سیستم باشد، انتخاب می‌شود. در مرحله آموزش، با اصلاح مشخصه‌های درجه عضویت بر اساس میزان خطای قابل قبول، مشخصه‌های مدل به مقادیر واقعی نزدیک می‌شوند. مدل سیستم استنتاج عصبی انطباقی شبکه‌ای چندلایه، متشکل از گره‌های فازی و کمان‌های اتصال دهنده گره‌ها است. سیستم فازی با مجموعه‌ای شامل N قاعده فازی بیان می‌گردد و شامل پنج لایه: گره‌های ورودی، گره‌های قاعده، گره‌های متوسط، گره‌های نتیجه و گره‌های خروجی است. ANFIS، که از الگوریتم‌های آموزشی شبکه عصبی سود می‌برد به کمک مجموعه‌ای از داده‌های ورودی و خروجی، یک سیستم استنتاج فازی (FIS) ایجاد می‌کند. پارامترهای توابع عضویت این سیستم از طریق الگوریتم پس انتشار یا ترکیب آن با روش حداقل



شکل ۲- شماتیک الگوریتم سیستم استنتاج فازی (Tayfur et al., 2003)

$$n = (n_0 + n_1 + n_2 + n_3 + n_4)m \quad (2)$$

که در آن n_0 ضریب زبری پایه است که با توجه به جنس کانال برای کانال یکنواخت، صاف و مستقیم انتخاب می‌شود. ضرایب اصلاحی n_1, n_2, n_3, n_4 و m به ترتیب در برگزیده‌ی اثرات نامنظمی سطح مقطع، چگونگی تغییرات سطح مقطع، وجود موانع در مسیر کانال، پوشش گیاهی و درجه‌ی ماریچی بودن مسیر می‌باشد. جدول ۲ بیان‌گر روابط نیمه تجربی به کار رفته در این تحقیق است.

روش‌های کلاسیک تخمین مقاومت جریان

تلاش‌های بسیاری جهت تعیین ضریب زبری در کانال‌های طبیعی روباز صورت گرفته است. در توسعه و استخراج روابط مقاومت جریان از فرضیات متفاوتی استفاده گردیده و در نتیجه فرمول‌های متعددی جهت تعیین این پارامتر وجود دارد که اغلب نتایج حاصل از آن‌ها متفاوت از یکدیگر می‌باشد. معمولاً در تخمین ضریب زبری مانینگ (n) از رابطه‌ی ۲ استفاده می‌شود (Cowan., 1956):

جدول ۲- روابط نیمه تجربی به کار رفته در تحقیق

شماره فرمول	محدودیت‌ها	رابطه	محقق
(۳)	$0.002 < S_0 < 0.04$ $0.15 < R < 2.1$	$n = (0.32 \times S_0^{0.38}) / R^{0.16}$	Jarrett (1984)
(۴)	$S_r < 1.6$	$n = 0.1 \times S_r \times R^{1/6} / (g^{0.5})$	Shiono et al. (1999)
(۵)	-	$n = S_r \times b^{1/6} / (94.32 \times \alpha \times S_0^{0.25})$	Jena (2006)

n : ضریب مانینگ، S_0 : شیب کانال، R : شعاع هیدرولیکی، g : شتاب گرانش، S_r : ضریب ماریچی، b : عرض کانال، α : ضریب شکل.

معیارهای ارزیابی

به منظور ارزیابی کارایی روش‌های به کار رفته در این تحقیق از سه معیار ارزیابی مدل استفاده گردید که عبارتند از: ضریب همبستگی بین مقادیر مشاهداتی و محاسباتی، (DC) ضریب تبیین و (RMSE) ریشه میانگین مربعات خطاها. هرچه مقدار R و DC به یک نزدیک‌تر و مقدار RMSE برای یک مدل کوچک‌تر باشد به معنی مطلوب بودن آن مدل می‌باشد. این پارامترهای آماری به صورت روابط ۶ تا ۸ می‌باشند.

$$R = \frac{\sum_{i=1}^N (l_{mi} - \bar{l}_{mi}) \times (l_{pi} - \bar{l}_{pi})}{\sqrt{\sum_{i=1}^N (l_{mi} - \bar{l}_{mi})^2 \times \sum_{i=1}^N (l_{pi} - \bar{l}_{pi})^2}} \quad (6)$$

$$DC = 1 - \frac{\sum_{i=1}^N (l_{mi} - l_{pi})^2}{\sum_{i=1}^N (l_{mi} - \bar{l}_{mi})^2} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (l_{mi} - l_{pi})^2}{N}} \quad (8)$$


l_{mi} : ضریب زبری مانینگ اندازه‌گیری شده، \bar{l}_{mi} : متوسط ضریب زبری مانینگ اندازه‌گیری شده، l_{pi} : ضریب زبری مانینگ پیش‌بینی شده، \bar{l}_{pi} : متوسط ضریب زبری مانینگ پیش‌بینی شده، N: تعداد داده‌ها.

مدل‌سازی

تعیین مدل‌های ورودی

با توجه به این که انتخاب مدل‌های ورودی در سیستم‌های هوشمند می‌تواند بر روی جواب‌های حاصل از تحلیل تأثیر گذارد، بنابراین سعی گردید در مدل‌سازی مقاومت جریان در پیچان رودها، پارامترهای مناسب و موثر انتخاب گردد. آزمایش‌های تجربی انجام گرفته توسط چندین محقق (Khatua et al., 2011; Shiono et al.,

1999) نشان می‌دهد که پارامترهای مهمی که می‌توانند بر ضریب زبری در رودخانه‌های طبیعی تأثیر بگذارد شامل شیب کانال S_0 ، ضریب سینوسی یا ماریچی S_r ، ضریب شکل α و عدد رینولدز Re می‌باشند. بنابراین در این تحقیق نیز از این پارامترهای بی‌بعد که وابسته به شرایط جریان و کانال هستند به عنوان ورودی مدل‌ها استفاده گردید و ضریب زبری مانینگ نیز به عنوان پارامتر مقاومت جریان و خروجی مدل‌ها در نظر گرفته شد. ضریب سینوسی نسبت طول کانال ماریچی به طول دره بوده و مربوط به بخش ماریچ کانال است. ضریب شکل بیان‌گر نسبت عرض کانال ماریچی (b) به عمق جریان (h) است. عدد رینولدز نیز به صورت $Re = (VR/v)$ تعریف می‌گردد که در آن V سرعت جریان، R شعاع هیدرولیکی و v ویسکوزیته جریان است. جهت تجزیه و تحلیل مدل‌ها از داده‌های آزمایشگاهی انجام گرفته توسط خاتو و همکاران سال ۲۰۱۱ و ویلتس و هاردویک در سال ۱۹۹۳ استفاده گردید (Khatua et al., 2011; Willetts and Hardwick., 1993). محدوده‌ی برخی از پارامترهای استفاده شده در این آزمایش‌ها مطابق جدول ۳ است. در شکل ۳ جزئیات کانال آزمایشی خاتو و همکاران نشان داده شده است (Khatua et al., 2011). این آزمایش‌ها در کانال ماریچی با درجه سینوسی و شرایط جریان متفاوت انجام گرفت. کانال ماریچی داخل یک فلوم با دیواره‌های شیشه‌ای و به طول ۱۵ متر، عرض ۴ متر و عمق ۰/۵ متر قرار داشت. از تعدادی پمپ موازی برای پمپاژ آب از مخزن زیرین (sump) به مخزن بالایی (overhead tank) با سرعت ۲۰۰ لیتر بر ثانیه استفاده شد. در انتهای کانال آزمایشی، آب از طریق یک دریچه کشویی به مخزن زیرین منتقل شده و این چرخه دوباره ادامه یافت. اندازه‌گیری شیب سطح آب با استفاده از گیج نقطه‌ای که بر روی ریل متحرک قرار داشت انجام گرفت. دبی جریان نیز با استفاده از مخازن اندازه‌گیری در پایین دست کانال آزمایش انجام گرفت. آزمایش‌ها برای عمق‌های مختلف جریان و تحت شرایط پایدار و یکنواخت انجام گرفت. لازم به توضیح است که در این تحقیق برای تمامی حالات از ۷۵٪ داده‌ها برای آموزش و ۲۵٪ دیگر برای آزمودن مدل‌های ورودی استفاده گردید.



شکل ۳- جزئیات کانال ماریچی آزمایشگاهی با تجهیزات اندازه‌گیری، (Khatua et al., 2011)

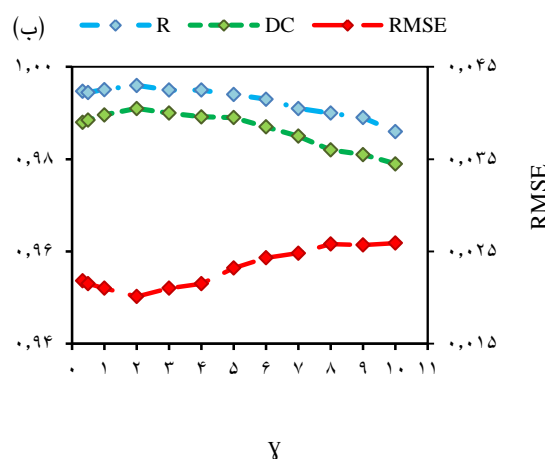
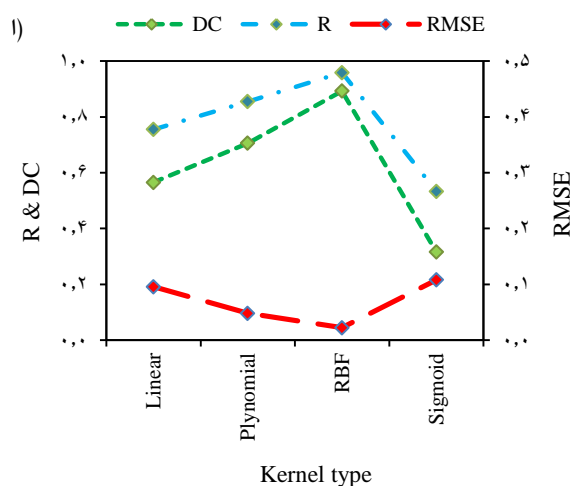
جدول ۳- محدوده داده‌های مورد استفاده در آزمایش‌ها

تعداد داده‌ها	پارامترها						محقق
	S_0	S_r	a	Re	$b(m)$	$h(m)$	
۸۷	۰/۰۰۱۹-۰/۰۲۱	۱-۱/۹۱	۱/۰۴-۱۰/۹۱	۲۳۶۶۵-۳۴۹۵۱۶	۱۲/۰	۱۲/۰-۰/۰۱۱	(Khatua et al., 2011)
۵۵	۰/۰۰۰۶۳۱	۲/۰۴	۲/۷۸	۲۰۳۴۷۷-۶۵۴۲۳۱	۰/۱۲	۰/۰۹-۰/۱۴	(Willets and Hardwick., 1993)

یافتن بهینه‌ترین پارامترهای تابع کرنل از روش سعی و خطا استفاده شد و با آزمودن مقادیر مختلف مقدار بهینه این پارامترها انتخاب گردید. نحوه کار به این صورت بود که به ازای مقدار ثابت γ ابتدا مقادیر بهینه ϵ و C به دست آمد، سپس مقدار γ تغییر پیدا کرد و با محاسبه پارامترهای آماری مقدار بهینه آن محاسبه گردید. در شکل ۴ (ب) نمودار پارامتر γ در برابر پارامترهای آماری DC ، $RMSE$ و R برای مدل (II) نشان داده شده است.

انتخاب تابع کرنل مناسب

در این تحقیق برای انتخاب تابع کرنل مناسب ماشین بردار پشتیبان مدل (II) با کرنل‌های مختلف مورد ارزیابی قرار گرفت. مطابق با شکل ۴ (الف) نتایج نشان داد که تابع کرنل (RBF) در تخمین میزان مقاومت جریان در کانال‌های طبیعی بهتر عمل می‌کند؛ و کرنل (Sigmoid) ضعیف‌ترین جواب را ارائه می‌دهد. بنابراین برای مدل‌های دیگر نیز از کرنل (RBF) استفاده گردید. هم‌چنین برای



شکل ۴- پارامترهای آماری مدل SVM با (الف) توابع کرنل متفاوت و (ب) تعیین بهینه پارامتر γ

دوم تعداد گره‌ها از ۲ شروع شد و به تدریج بر مقدار آن افزوده شد. مشاهده گردید با افزایش تعداد گره‌ها دقت مدل ابتدا افزایش یافته و سپس در گره ۴ تقریباً ثابت می‌ماند. بنابراین تعداد گره‌ها در لایه دوم برای تمامی مدل‌ها برابر ۴ انتخاب گردید. در شکل ۵ ساختار مدل ANFIS به کار رفته نشان داده شده است. همان‌طور که ملاحظه می‌گردد شبکه دارای یک لایه ورودی، سه لایه مخفی و یک لایه خروجی است.

نتایج و بحث

نتایج مدل‌های SVM و ANFIS


با در نظر گرفتن پارامترهای مربوط به مشخصات جریان و کانال، مدل‌هایی به صورت جدول ۴ تعریف گردید و با استفاده از روش‌های هوشمند ANFIS و SVM اجرا گردیدند. نتایج حاصل از تحلیل

ساختار مدل ANFIS

نکته اصلی در طراحی مدل ANFIS انتخاب سیستم استنتاج فازی است. این شبکه براساس یادگیری نظارت شده آموزش داده می‌شود. بنابراین هدف دادن آموزش به شبکه تطبیقی است تا بتواند توابع غیرمعیین داده شده توسط داده‌های آموزش را تخمین زده و مقادیر دقیق پارامترهای فوق را بیابد. در این تحقیق جهت توسعه مدل ANFIS از نرم‌افزار MATLAB استفاده شد. برای آموزش مدل، الگوریتم آموزش ترکیبی با تعداد تکرار $epoch=30$ به کار رفت. در این روش، ANFIS یک الگوریتم آموزش ترکیبی شامل روش کاهش شبیه و روش حداقل مربعات را به کار می‌گیرد تا پارامترها را بهینه نماید. نوع سیستم استنتاج فازی به کار رفته در تحقیق، سیستم سوگنو با توابع عضویت گوسین (gauss2mf) بوده و روش آموزش از نوع هیبرید با تعداد ۴ قانون است. در طی آموزش شبکه، برای لایه

معیارهای ارزیابی برای هر دو روش به کار رفته نتایج قابل قبولی به دست آمده است.

مدل‌های هوش مصنوعی به کار رفته در جدول ۵ و شکل ۶ نشان داده شده است. نتایج آرایه شده نشان دهنده آن است که با توجه به



شکل ۵- ساختار مدل ANFIS توسعه داده شده

تغییر در ضریب زبری به ازای تغییر در هندسه رودخانه، مشخصات جریان و شیب بستر، ضریب زبری نیز تغییر خواهد کرد، نتایج تحقیق کنونی نیز با توجه به معیارهای ارزیابی به دست آمده برای مدل‌های تعریف شده حاکی از آن است که مشخصات جریان، شکل و شیب بستر کانال در تخمین ضریب زبری موثر می‌باشند.

همچنین با بررسی نتایج آرایه شده در جدول ۵ و با در نظر گرفتن معیارهای ارزیابی مدل، مشاهده می‌گردد که ANFIS دارای R و DC بزرگ‌تر و خطای (RMSE) کوچک‌تر در مقایسه با SVM بوده و این امر بیان‌گر آن است که نتایج مدل ANFIS تا حدودی دقیق‌تر از مدل SVM است. با این وجود، هر دو روش از کارایی مطلوبی جهت تخمین ضریب زبری مانینگ در کانال‌های با جریان روباز برخوردار هستند. در شکل ۶ نمودار پراکنش داده‌های آموزش و آزمون مدل برتر برای هر دو روش آرایه شده است. همان‌طور که مشاهده می‌گردد همبستگی مناسبی بین مقادیر مشاهداتی و محاسباتی دیده می‌شود که این امر حاکی از عملکرد مناسب روش‌های هوش مصنوعی به کار رفته در تحقیق است.

مقایسه نتایج مدل‌های SVM و ANFIS با مدل‌های کلاسیک

قابلیت و کارایی چندین فرمول نیمه تجربی موجود جهت تخمین ضریب زبری مانینگ در رودخانه‌های طبیعی مورد ارزیابی قرار گرفت و نتایج حاصله با روش‌های به کار رفته در این تحقیق مقایسه گردید. نتایج مقایسه در جدول ۶ و شکل ۷ نشان داده شده است.

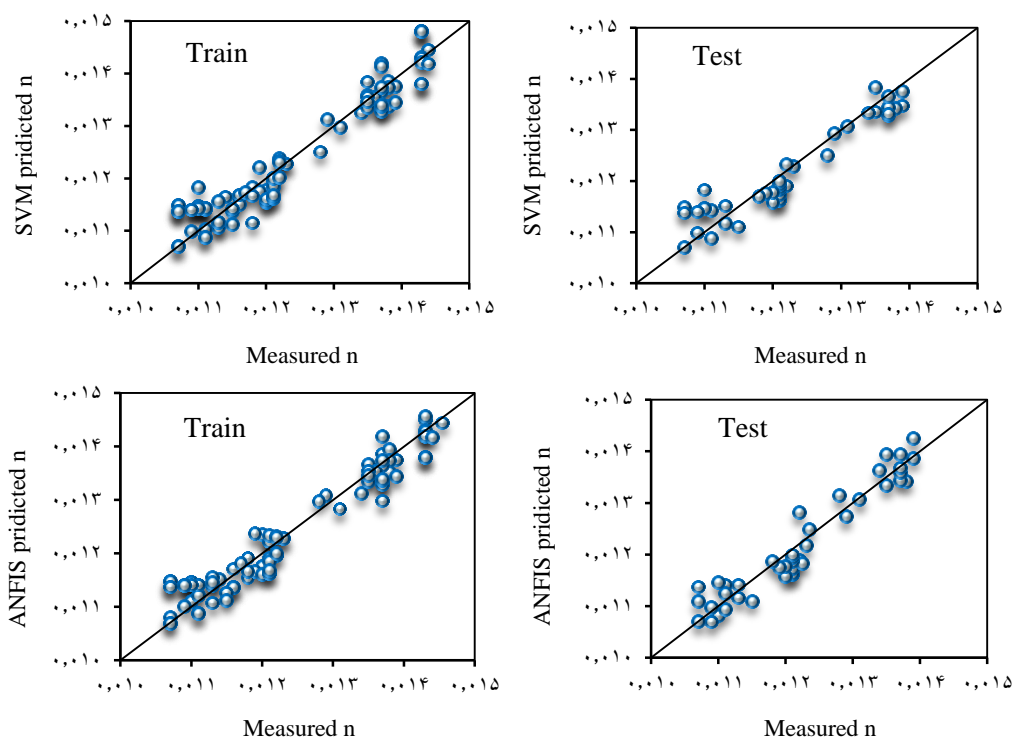
با استفاده از هر دو روش ANFIS و SVM، مدل (I) با پارامترهای α , Sr , S_0 و Re به عنوان متغیرهای ورودی، بیش‌ترین دقت و کارایی را با داشتن بیش‌ترین ضریب همبستگی و ضریب تبیین (R و DC) و کم‌ترین خطا (RMSE) در بین سایر مدل‌ها دارا می‌باشد. برای این مدل مقادیر معیارهای ارزیابی برای سری داده‌های آزمون با استفاده از روش ماشین بردار پشتیبان مقادیر $R=0.961$, $DC=0.902$ و $RMSE=0.003$ و با استفاده از روش سیستم استنتاج عصبی- فازی انطباقی مقادیر $R=0.973$, $DC=0.916$ و $RMSE=0.0029$ به دست آمده است. با مقایسه مدل‌های (I) و (II) مشاهده شد که اضافه کردن عدد رینولدز به پارامترهای ورودی باعث بهبود دقت مدل‌ها گردیده است. همچنین مشاهده می‌گردد مدل (III) با پارامترهای ورودی α , Sr و Re در بین تمامی مدل‌ها نتایج ضعیف‌تری آرایه داده است. مقایسه این مدل با مدل اول بیان‌گر آن است که حذف پارامتر S_0 که معرف شیب کانال می‌باشد منجر به کاهش دقت مدل‌ها گردیده است. مطالعات شینو نشان می‌دهد که در کانال‌های ماریپچی، درجه سینوسی در تخمین ضریب زبری موثر است (Shiono et al., 1999). با توجه به نتایج حاصله از مدل‌های (II)، (VI) و (V) نیز می‌توان به این نتیجه رسید که در تخمین ضریب زبری در پیچان‌رودها، ضریب ماریپچی در تخمین ضریب زبری پارامتر تأثیرگذار می‌باشد. با این حال، اثر پارامتر ضریب شکل در افزایش دقت مدل‌ها از ضریب ماریپچی بیش‌تر می‌باشد. با توجه به نتایج حاصل از مطالعات محققان دیگر مانند (Moharana et al., 2013)، (Khatua et al., 2011)، که به بررسی ضریب زبری در رودخانه‌های ماریپچی پرداخته‌اند و بدین نتیجه رسیده‌اند که میزان

جدول ۴- مدل‌های استفاده شده در تحقیق

مدل	پارامترهای ورودی	پارامتر خروجی
Model (I)	$n=f(Re, Sr, S_0, \alpha)$	n
Model (II)	$n=f(Sr, S_0, \alpha)$	n
Model (III)	$n=f(Re, Sr, \alpha)$	n
Model (VI)	$n=f(Sr, S_0)$	n
Model (V)	$n=f(S_0, \alpha)$	n

جدول ۵- پارامترهای ارزیابی مدل‌های تعریف شده

روش	مدل	مرحله آزمون			مرحله آموزش		
		R	DC	RMSE	R	DC	RMSE
روش ماشین بردار پشتیبان							
SVM	Model (I)	۰/۹۰۲	۰/۹۶۱	۰/۰۰۰۳۱	۰/۹۳۵	۰/۹۶۸	۰/۰۰۰۲۶
SVM	Model (II)	۰/۹۰۱	۰/۹۱۱	۰/۰۰۰۴۵	۰/۹۰۸	۰/۹۲۱	۰/۰۰۰۴۳
SVM	Model (III)	۰/۶۱۱	۰/۷۰۸	۰/۰۰۰۸۱	۰/۶۳۱	۰/۷۲۱	۰/۰۰۰۶۸
SVM	Model (VI)	۰/۷۱۶	۰/۸۱۲	۰/۰۰۰۶۶	۰/۷۴۸	۰/۸۲۵	۰/۰۰۰۵۵
SVM	Model (V)	۰/۸۰۸	۰/۹۰۴	۰/۰۰۰۴۹	۰/۸۲۴	۰/۹۱۱	۰/۰۰۰۴۶
روش سیستم استنتاج عصبی- فازی انطباقی							
ANFIS	Model (I)	۰/۹۱۶	۰/۹۷۳	۰/۰۰۰۲۸	۰/۹۴۷	۰/۹۸۳	۰/۰۰۰۳۴
ANFIS	Model (II)	۰/۹۰۹	۰/۹۲۲	۰/۰۰۰۴۴	۰/۹۱۲	۰/۹۳۲	۰/۰۰۰۴۱
ANFIS	Model (III)	۰/۶۳۲	۰/۷۴۶	۰/۰۰۰۷۸	۰/۶۶۸	۰/۷۷۴	۰/۰۰۰۶۵
ANFIS	Model (VI)	۰/۷۲۷	۰/۸۲۲	۰/۰۰۰۶۳	۰/۷۵۸	۰/۸۳۷	۰/۰۰۰۵۱
ANFIS	Model (V)	۰/۸۲۰	۰/۹۱۳	۰/۰۰۰۴۶	۰/۸۳۵	۰/۹۱۵	۰/۰۰۰۴۴



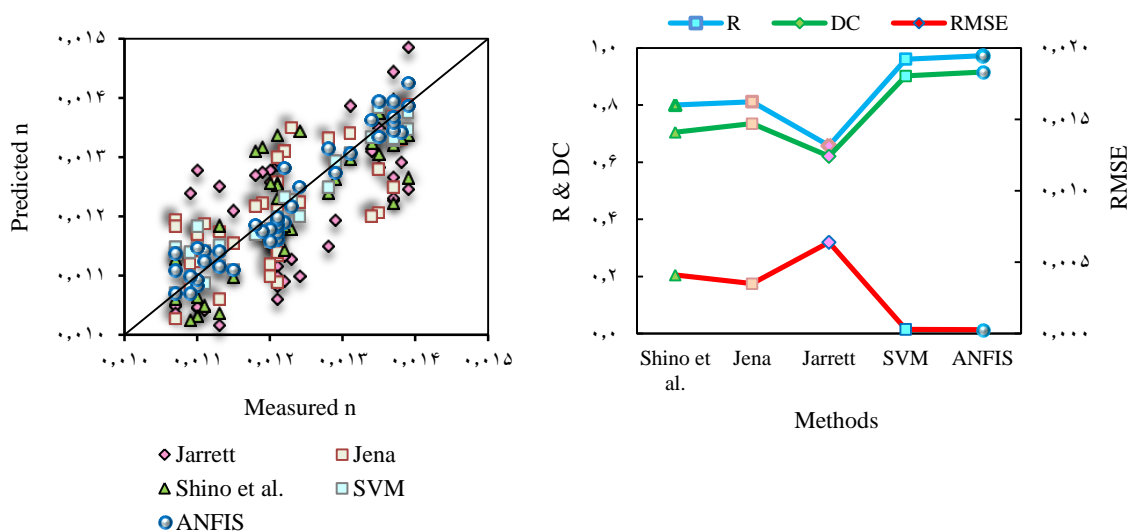
شکل ۶- نمودار پراکنش داده‌های آموزش و آزمون مدل برتر

می‌گردد که با مقدار کمینه و یا بیشینه ضریب زبری مانینگ روبرو هستیم. مطابق با پارامترهای آماری ارایه شده در جدول ۶، روش‌های هوش مصنوعی دارای بیش‌ترین R، DC و کم‌ترین RMSE بوده و این امر حاکی از کارایی بالای این روش‌ها در پیش‌بینی ضریب زبری نسبت به مدل‌های کلاسیک است. لازم به توضیح است که روابط کلاسیک رگرسیونی موجود با توجه به شرایط خاص جریان، با استفاده از داده‌های محدود و تحت فرضیات متفاوت توسعه داده شده‌اند و قابلیت تعمیم دادن به همه شرایط را ندارند در حالی‌که مشاهده می‌گردد روش‌های هوش مصنوعی جواب‌های قابل‌قبولی را ارایه داده‌اند و این امر حاکی از عملکرد مناسب آن‌ها است.

نتایج حاصل بیان‌گر آن است که در بین تمامی روابط فرمول (2006) Jena جواب‌های دقیق‌تری را ارایه داده است. مدل برتر به- دست آمده با استفاده از روش‌های هوش مصنوعی شامل پارامترهای S_0 ، Sr و α می‌باشد و فرمول جنا (2006) (Jena) که شامل پارامترهای S_0 ، Sr و α است در مقایسه با دو فرمول دیگر در پیش‌بینی ضریب زبری کارایی بالاتری دارد. فرمول (Jarrett, 1984) با داشتن پارامترهای R و S_0 ضعیف‌ترین نتایج را ارایه داده است. این امر بیانگر آن است که پارامترهای مربوط به هندسه کانال، شیب بستر و مشخصات جریان در تخمین ضریب زبری موثر می‌باشند. در حالت کلی، مدل‌های کلاسیک در مقایسه با مدل‌های ANFIS، SVM، ضعیف‌تر عمل کرده‌اند. استفاده از اکثر روابط کلاسیک مشاهده

جدول ۶- پارامترهای ارزیابی مربوط به روابط کلاسیک و روش‌های SVM و ANFIS

معیارهای ارزیابی			روش
مرحله آزمون			
R	DC	RMSE	
۰/۹۶۱	۰/۹۰۲	۰/۰۰۰۳۱	SVM
۰/۹۷۳	۰/۹۱۶	۰/۰۰۰۲۸	ANFIS
۰/۸۰۱	۰/۷۰۵	۰/۰۰۴۱	(Shino et al., 1999)
۰/۸۱۲	۰/۷۳۵	۰/۰۰۳۵	(Jena, 2006)
۰/۶۵۸	۰/۶۲۱	۰/۰۰۶۴	(Jarrett, 1984)



شکل ۷- نتایج مقایسه روابط کلاسیک با SVM و ANFIS

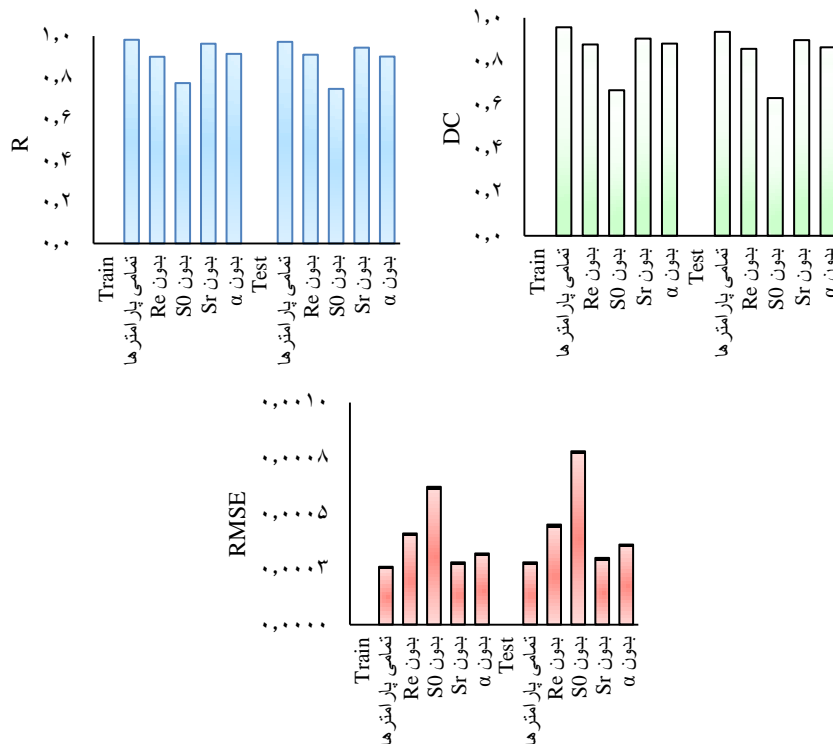
بود، انجام شد. بدین منظور در مدل برتر، با حذف تک‌تک پارامترها از سری پارامترهای ورودی، مدل دوباره اجرا گردید و میزان تأثیر پارامتر حذف شده در کاهش دقت مدل با استفاده از معیارهای ارزیابی مدل مورد ارزیابی قرار گرفت. نتایج حاصله مطابق شکل ۸ ارایه شده

تحلیل حساسیت مدل برتر هر حالت

جهت درک بهتر میزان تأثیر هر یک از متغیرهای مستقل روی مقاومت جریان در رودخانه‌های طبیعی، تحلیل حساسیت با استفاده از روش سیستم استنتاج عصبی- فازی تطبیقی که بهترین نتایج را دارا

بیشترین کاهش را داراست؛ بنابراین می‌توان نتیجه گرفت که S_0 تأثیرگذارترین پارامتر در تخمین ضریب زبری مانینگ بوده و بعد از این پارامتر عدد رینولدز تأثیرگذار است.

است. با توجه به این شکل مشاهده می‌گردد که با حذف پارامتر ورودی S_0 که بیانگر شیب کانال است خطا (RMSE) به مقدار زیادی افزایش یافته است و مقادیر R و DC نیز نسبت به سایر پارامترها



شکل ۸- نمودار مقادیر خطاهای آزمون تحلیل حساسیت مدل برتر ANFIS

خطا (RMSE) نشان داد. به لحاظ کمی در بهترین حالت ارزیابی آزمون، با استفاده از روش ماشین‌بردار پشتیبان مقادیر $R=0.961$ ، $DC=0.902$ و $RMSE=0.0003$ و با استفاده از روش سیستم استنتاج عصبی-فازی انطباقی مقادیر $R=0.973$ ، $DC=0.916$ و $RMSE=0.00029$ به دست آمده است. با مقایسه نتایج حاصل از مدل‌ها مشاهده گردید که اضافه کردن عدد رینولدز به پارامترهای ورودی باعث بهبود دقت مدل‌ها می‌گردد و حذف پارامتر S_0 که معرف شیب کانال است منجر به کاهش دقت مدل‌ها گردید. همچنین ملاحظه گردید که در تخمین ضریب زبری در پیچان‌رودها، تأثیر پارامتر ضریب شکل در افزایش دقت مدل‌ها از ضریب سینوسی بیشتر است. نتایج حاصل از تحلیل حساسیت نیز نشان داد که شیب کانال تأثیرگذارترین پارامتر در مدل‌سازی ضریب زبری در کانال‌های مارپیچی است. بررسی نتایج بیان‌گر آن است که نتایج ANFIS نسبت به نتایج SVM تاحدودی بهبود یافته است. با این وجود، هر دو روش از کارایی مطلوبی جهت تخمین ضریب زبری مانینگ در کانال‌های طبیعی با جریان روباز برخوردارند.

نتیجه‌گیری

تخمین قابل قبول ضریب زبری در رودخانه‌های طبیعی یک پارامتر کاربردی و پراهمیت در طرح‌های مرتبط با رودخانه‌ها است و برای اتخاذ تصمیمات مناسب در حوزه رودخانه‌ها جزو مهم‌ترین مسایل مهندسی است. در این تحقیق، کارایی روش‌های هوش مصنوعی و کلاسیک جهت پیش‌بینی ضریب زبری مانینگ در پیچان‌رودها مورد ارزیابی قرار گرفت. جهت مدل‌سازی از دو سری داده آزمایشگاهی مربوط به کانال‌های سینوسی شکل استفاده گردید. نتایج حاصله نشان داد که روش‌های هوشمند SVM، ANFIS از قابلیت بالایی نسبت به فرمول‌های نیمه‌تجربی در تخمین ضریب زبری برخوردار بوده و قابل اعتمادتر می‌باشند. مشاهده گردید که در استفاده از اکثر روابط کلاسیک با مقدار کمینه و یا بیشینه روبرو می‌شویم و این روش‌ها در تعیین پارامتر ضریب زبری مانینگ دقیق نمی‌باشند. با استفاده از هر دو روش ANFIS و SVM، مدل (I) با پارامترهای S_0 و Sr بیشترین دقت و کارایی را با داشتن بیشترین ضریب همبستگی و ضریب تبیین (R و DC) و کم‌ترین

منابع

- Patra, K.C and Khatua, K.K. 2006. Selection of interface plane in the assessment of discharge in two stage meandering and straight compound channels. In proceedings of the international conference on fluvial hydraulics. 8 Sep, pp. 379-387.
- Roushangar, K., Ghasempour, R. 2017. Prediction of non-cohesive sediment transport in circular channels in deposition and limit of deposition states using SVM. *Water Science and Technology: Water Supply*. 17.2: 537-551.
- Roushangar, K., Valizadeh, R., Ghasempour, R. 2017. Estimation of hydraulic jump characteristics of channels with sudden diverging side walls via SVM. *Water Science and Technology*. 76.7: 1614-1628.
- Roushangar, K., Alami, M.T and Saghebian, S.M. 2018. Modeling open channel flow resistance with dune bedform via heuristic and nonlinear approaches. *Journal of Hydroinformatics*. 20.2: 356-75.
- Sahu, M and Khatua, K.K. 2012. Prediction of entrance length for low Reynolds number flow in pipe using neuro-fuzzy inference system. *Expert Systems with Applications*. 39: 4545-4557.
- Shiono, K., Al-Romaih, J. S and Knight, D.W. 1999. Stage-discharge assessment in compound meandering channels. *Journal of Hydraulic Engineering*. 125.1: 66-77.
- Shiri, J., Dierickx, W., Pour-Ali Baba, A., Neamati, S. and Ghorbani, M.A. 2011. Estimating daily pan evaporation from climatic data of the State of Illinois, USA using adaptive neuro-fuzzy inference system (ANFIS) and artificial neural networks (ANN). *Hydrology Research*. 42.6: 491-502.
- Tayfur, G., Ozdemir, S and Singh, V.P. 2003. Fuzzy logic algorithm for runoff-induced sediment transport from bare soil surfaces. *Advanced Water Resource*. 26: 1249-1256.
- Vapnik, V. 1995. *The Nature of Statistical Learning Theory*. Data Mining and Knowledge Discovery. Springer Verlag, New York. 47p.
- Willets, B.B and Hardwick, S.R.I. 1993. Stage dependency for overbank flow in meandering channels. Willets, B.B. and Hardwick, R.I., 1993. Stage dependency for overbank flow in meandering channels. *Proceedings of the Institution of Civil Engineers-Water Maritime and Energy*. 101: 45-54.
- Yang, K., Cao, S and Liu, X. 2007. Flow resistance and its prediction methods in compound channels. *Acta Mechanica Sinica*. 21: 353-361.
- Zeng, Y.H., Guymer, I., Spence, K.J and Huai, W.X. 2010. Application of analytical solutions in trapezoidal compound channel flow. *River Research and Applications*. 28.1: 53-61.
- الهام روشنی، ر.، حسین‌زاده دلیر، ع.، فرسادی‌زاده، د و سلماسی، ف. ۱۳۹۵. ارزیابی مقاومت جریان در رودخانه‌های رسوبی با فرم بستر ریپل در شرایط هیدرولیکی مختلف. نشریه دانش آب و خاک. ۲۵: ۳. ۶۳-۷۳.
- حسین‌زاده، م. ۱۳۸۳. پهنه‌بندی سیل با استفاده از HEC-RAS در محیط سیستم اطلاعات جغرافیایی (رودخانه لاین سو). پایان‌نامه کارشناسی ارشد، گروه آبیاری دانشکده علوم کشاورزی ساری.
- عباسی، ع.ا و ملک‌نژاد، م. ۱۳۹۱. بررسی عوامل موثر بر ضریب مانینگ در رودخانه‌ها و ارایه‌ی رابطه‌ای جدید جهت تخمین آن (مطالعه‌ی موردی: رودخانه‌ی فریزی). نشریه آب و خاک (علوم و صنایع کشاورزی). ۲۶: ۵. ۱۳۰۸-۱۳۱۷.
- Banzhaf, W., Nordin, P., Keller, P. E and Francone, F. D. 1998. *Genetic Programming*. Morgan Kaufmann, San Francisco, CA, 512p.
- Cowan, W.L. 1956. Estimating hydraulic roughness coefficients. *Agricultural Engineering*. 37: 473-475.
- Jang, J.R. 1993. ANFIS: adaptive network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*. 23.3: 665-685.
- Jarrett, R.D. 1984. *Hydraulics of high gradient streams*. *Journal of Hydraulic Engineering*. ASCE. 110: 1519-1539.
- Jena, S. 2006. Stage-discharge relationship in simple meandering channels. Master's Thesis, Indian Institute of Technology (IIT), Kharagpur, India.
- Khatua, K.K., Patra, K and Nayak, C.P. 2011. Meandering effect for evaluation of roughness coefficients in open channel flow. In *Sixth International Conference on River Basin Management*, 15th-17th September, Algarve-Portugal, 8 page.
- Kisi, O., Shiri, J and Tombul, M. 2013. Modeling rain fall-runoff process using soft computing techniques. *Journal of Computers and Geosciences*. 51: 108-117.
- Lan, Y. 2014. Forecasting performance of support vector machine for the Poyang Lake's water level. *Journal of Water Science and Thecnology*. 70.9: 1488-1495.
- Moharana, S., Khatua, K.K and Sahu, M. 2013. Friction factor of a meandering open channel flow. *River Basin Management*. 172: 75-86.
- Najafzadeh, M., Etemad-Shahidi, A and Lim, S.Y. 2016. Scour prediction in long contractions using ANFIS and SVM. *Ocean Engineering*. 111: 128-135.

Investigation of the Performance of Classical and Artificial Intelligence Approaches in Prediction of Roughness Coefficient in Meanders

K. Roushangar^{1*}, R. Ghasempour²

Received: Jan.04, 2018

Accepted: May.07, 2018

Abstract

Accurate prediction of the river's roughness coefficient is always one of the most important and substantial issues in the hydraulic modeling of open channels. In the current research, the Support Vector Machine (SVM) and Adaptive Neuro-Fuzzy Inference System (ANFIS) intelligent approaches were used to estimate the hydraulic roughness of meandering rivers, and the impacts of different variables including: channel slope, channel sinuosity and also, hydraulic parameters such as Reynolds number on prediction of the roughness coefficient in these types of channels were investigated. On the other hand, the obtained results were compared with classical methods. In order to model the roughness coefficient, two experimental data series related to the sinusoidal shaped channels were used. The obtained results showed that the SVM and ANFIS intelligent methods are more accurate and reliable in estimating the Manning roughness coefficient in natural rivers than semi-experimental formulas. It was observed that in estimation of the Manning roughness coefficient, the model with input variables of α (shape factor), S_r (sinusoidal coefficient), S_0 (channel slope) and Re (Reynolds number) leads to the more accurate results. The results showed that in estimating the roughness coefficient in the meandering rivers, the effect of the shape factor on increasing the accuracy of the models is more than the sinusoidal coefficient. Also, the results of sensitivity analysis indicated that the channel slope is the most effective parameter in estimating the roughness coefficient in the meandering rivers.

Keywords: ANFIS, Artificial intelligence approaches, Manning's coefficient, River

1- Associate Professor, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

2- Ph.D. student, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

(* - Corresponding Author Email: kroshangar@yahoo.com)