

پیش‌بینی ضریب زبری کانال‌های روباز با بستر فرسایشی با استفاده از سیستم‌های عصبی مصنوعی

کیومرث روشنگر*^۱ و سعید محمدپور^۲

^۱دانشیار دانشکده مهندسی عمران، دانشگاه تبریز

^۲دانشجوی کارشناسی ارشد عمران-سازه‌های هیدرولیکی، دانشگاه آزاد اهر

چکیده

در هیدرولیک رودخانه‌ها، بستر متحرک بوده و مقاومت در برابر جریان یا ضریب زبری متغیر است. در این حالت، نمی‌توان رابطه مقاومت را به طور مستقیم و بدون آگاهی از نحوه تغییر ضریب مقاومت در شرایط مختلف جریان و رسوب، به کار برد. با توجه به تأثیر پارامترهای متعدد در ضریب زبری، تاکنون رابطه قطعی جهت محاسبه ضریب زبری ارائه نشده است. در این تحقیق، ابتدا آزمایشات لازم در کانالی در حالت فرم بستر دوقطبی جهت به دست آوردن داده‌های هیدرولیکی مورد نیاز ترتیب داده شد. سپس با استفاده از شبکه‌های عصبی پیش‌خور و شعاع مینا از یک سو و نیز شبکه‌های عصبی-فازی از سوی دیگر، مقدار ضریب زبری مانینگ برای هر دو حالت با بعد و بی‌بعد پیش‌بینی گردید. نتایج حاصله نشان داد که شبکه عصبی قابلیت و کارایی بالایی در شبیه‌سازی ضریب زبری بستر داشته و مدل عصبی-فازی با وجود کارایی بهتر نسبت به شبکه‌های شعاع مینا دارای عملکرد ضعیف‌تری در مقایسه با شبکه پیش‌خور است. با توجه به نتایج حاصل از تحلیل حساسیت مشخص شد که پارامتر مستقل Re برای ضریب زبری با بعد و پارامتر مستقل $R/D50$ برای ضریب زبری بی‌بعد بیشترین تأثیر را بر روی ضریب زبری دارند. به لحاظ کمی نیز در بهترین حالت ارزیابی آزمون نرم-افزار Matlab، برای شبکه پیش‌خور در حالت با تابع هدف بی‌بعد $R=0.935$ و $MNE=1/908$ و در حالت با تابع هدف با بعد $R=0.941$ و $MNE=2/04$ ، برای شبکه شعاع مینا با تابع هدف بی‌بعد $R=0.8$ و $MNE=0.29$ و در حالت تابع هدف با بعد $R=0.83$ و $MNE=0.229$ و نهایتاً برای شبکه عصبی-فازی در حالت با تابع هدف بی‌بعد $R=0.912$ و $MNE=2/662$ و برای حالت با تابع هدف با بعد $R=0.922$ و $MNE=2/472$ مشاهده گردید که دقت بالای پیش‌بینی‌ها را نشان می‌دهد.

واژگان کلیدی: ضریب زبری مانینگ، بستر متحرک، شبکه‌های عصبی پس انتشار، شعاع مینا، شبکه‌های عصبی-فازی.

۱- مقدمه

زبری مشاهده کردند که رابطه Strickler با وجود سادگی، جواب‌های نسبتاً قابل قبولی می‌دهد. افضلی مهر و Anctil [۴] مقاومت جریان را در رودخانه‌های با بستر سنگریزه مورد مطالعه قرار دادند. آن‌ها به این نتیجه رسیدند که معادلات موجود مقاومت جریان را دقیق تخمین نمی‌زنند؛ زیرا مقاومت جریان علاوه بر استغراق نسبی تابع پارامترهای حرکت رسوب و عدد فرود جریان نیز می‌باشد. Yuhong و Wenxin [۵] در مطالعه خود کارایی شبکه عصبی را در پیشگویی ضریب دارسی-وایسباخ با استفاده از شبکه پیش‌خور^۱ و الگوریتم لونیگ-مارکوت با دو ورودی عدد رینولدز و زبری وابسته‌اش، برای تعدادی از داده‌های آزمایشگاهی بررسی کردند و پس از مقایسه نتایج با داده‌های مشاهداتی به این نتیجه رسیدند که شبکه عصبی قادر است ضریب زبری را در حد قابل قبولی پیش‌بینی

ضریب زبری بستر در دبی، سرعت، تنش برشی مرزی و بسیاری دیگر از پارامترهای هیدرولیکی نقش مؤثری دارد بنابراین این شناخت دقیق این پارامتر در مهندسی رودخانه و طراحی جریان‌های روباز ضروری است. برای تعیین ضرایب زبری در بسترهای متحرک، مطالعات وسیعی توسط محققین مختلف صورت گرفته است که نتایج آن‌ها غالباً با یکدیگر متفاوت‌اند. بسیاری از این مطالعات بر اساس داده‌های محدود آزمایشگاهی استوار بوده‌اند [۱]. محمودیان شوشتری و نیسی [۲] در پژوهشی تخمین ضریب مانینگ با روش‌های مختلف را در بازه‌ای از رودخانه کارون بررسی کردند و به این نتیجه رسیدند که روابط Peter, Meyer and Muller دقت قابل قبولی در مقایسه با داده‌های اندازه‌گیری مستقیم دارند. حاتمی و لشته‌نشایی [۳] عوامل مؤثر بر روابط تعیین‌کننده ضریب زبری را مورد بررسی قرار دادند و پس از مقایسه نتایج روابط مختلف تخمین ضریب

1- Feed Forward Neural Network

در روش‌های غیر خطی تفکیک ضریب مقاومت به دو بخش مقاومت دانه‌ها و مقاومت شکل بستر همانند روش‌های تجمعی خطی انجام نمی‌پذیرد. در اکثر روش‌های غیر خطی با انتخاب پارامترهای مؤثر در پدیده، ضریب مقاومت بستر با استفاده از تحلیل ابعادی و روش‌های برازش آماری به صورت روابط تابعی^۹ استخراج می‌شوند مطابق آن‌چه در جدول (۱) آورده شده این روش‌ها را می‌توان به چهار گروه تقسیم کرد:

۱- ضریب مقاومت به صورت متغیر وابسته در تحلیل در نظر گرفته می‌شود.

۲- مقاومت جریان بر اساس تنش برشی و نیز سرعت برشی محاسبه می‌شود.

۳- مقاومت جریان به معادلات سرعت متوسط و ضرائب آن مربوط می‌شود.

۴- مقاومت جریان با کمک مفهوم قدرت جریان به کمک روش‌های انرژی و اندازه حرکت محاسبه می‌شود.

در بین روش‌های مذکور، تنها در روش اول مقدار مقاومت به طور صریح و مستقیم^{۱۰} به دست می‌آید. در حالی که، ضرائب مقاومت، در سه روش بعدی به طور غیر مستقیم و ضمنی قابل محاسبه می‌باشد.

۲-۲- داده‌های مورد استفاده

در این مطالعه برای به دست آوردن داده‌های لازم به عنوان ورودی شبکه‌های عصبی و مدل‌سازی ضریب زبری مانینگ در یک بستر متحرک، داده‌های حاصل از مطالعات آزمایشگاهی ترتیب داده شده توسط مؤلف در مدت فرصت مطالعاتی در آزمایشگاه هیدرولیک موسسه تحقیقاتی CNRS متعلق به دانشگاه کان فرانسه مورد استفاده قرار گرفته است. بدین منظور، کانالی به طول مفید ۸ متر و عرض ۰/۱۵ متر و عمق ۰/۴ متر مورد استفاده قرار گرفت. بدنه کانال از جنس شیشه بوده و کف آن نیز با ورق پلاکسی گلاس پوشانده شده بود.

کند. Şamandar [۶] در مطالعه خود کارایی سیستم استنتاج فازی را با سه ورودی عدد رینولدز، سرعت و دبی، برای تعدادی از داده‌های آزمایشگاهی بررسی کرد و به این نتیجه رسید که مدل استنتاج فازی جهت تخمین ضریب زبری حاصل از داده‌های آزمایشگاهی مناسب می‌باشد.

با توجه به لزوم بررسی میزان صحت پیش‌بینی پارامتر مهم ضریب زبری رودخانه‌های با بستر متحرک با استفاده از روش‌های مختلف، در این پژوهش تلاش گردید با استفاده از نرم‌افزار Matlab میزان مؤثر بودن شبکه‌های عصبی مصنوعی مختلف در پیش‌بینی صحیح پارامتر فوق‌الذکر بررسی گردیده و نتایج به صورت تحلیلی جهت استفاده در اختیار دیگر محققین قرار گیرند.

۲- مواد و روش‌ها

۲-۱- مقاومت جریان در بستر متحرک

بر اساس روابط و مطالعات موجود، مقاومت جریان در بسترهای متحرک به دو دسته تقسیم‌بندی می‌شوند.

۲-۱-۱- روش‌های خطی

این روش‌ها مبتنی بر اصل جمع آثار قوا بوده و در آن مقاومت جریان حاصل جمع مقاومت حاصل از زبری ذرات و مقاومت ناشی از شکل بستر می‌باشد. تاکنون روش‌های فراوانی مبتنی بر این دیدگاه برای محاسبه مقاومت جریان رسوبی ارائه شده که یکی از مشهورترین آن‌ها جداسازی تنش برشی وارد بر بستر به صورت خطی براساس مفهوم اندازه حرکت است. از محققینی که با این روش کار کرده اند می‌توان به انیشتن و بارباروسا^۱ (۱۹۵۲)، ونونی و بروکس^۲ (۱۹۵۷)، شن^۳ (۱۹۶۲)، انگلاند و هانسن^۴ (۱۹۶۶، ۱۹۶۷)، سیمونز و ریچاردسون^۵ (۱۹۶۶)، ونونی و هوانگ^۶ (۱۹۶۷)، کندی و همکاران^۷ (۱۹۶۹) و آکاراوغلو^۸ (۱۹۷۲) اشاره کرد [۷].

۲-۱-۲- روش‌های غیر خطی


- 1- Enistein & Barbarossa (1952)
- 2- Vanoni & Brooks (1957)
- 3- Shen (1962)
- 4- Englund & Hansen (1966, 1967)
- 5- Simons & Richardson (1966)
- 6- Vanoni & Hwang (1967)
- 7- Kennedy et al. (1969)
- 8- Acaroglu (1972)

جدول ۱- طبقه بندی عملکرد محققین مختلف براساس روش غیر خطی [۷]

وجود اطلاعات مربوط به فرم بستر	داده‌های مورد استفاده	متغیر مستقل	متغیر وابسته	محقق
نوع پارامتر تأثیرگذار بر مقاومت بستر				
خیر	آزمایشگاهی و صحرائی	d_s	n (ضریب زبری مانینگ)	استریکلر (۱۹۲۳)
خیر	آزمایشگاهی	$Fr, \frac{d_{50}}{R}, Re$	f (ضریب دارسی- وایسباخ)	ین و لیو (۱۹۶۹)
خیر	آزمایشگاهی و صحرائی	$Fr, \frac{d_{50}}{\delta}$	$c_m = \frac{\sqrt{gn}}{K_n d_{50}^{1/6}}$	مصطفی و مک درمید (۱۹۷۱)
بلی (متحرک بودن یا نبودن بستر)	-	$\frac{V}{\sqrt{gd_{50}}}, \frac{d_{50}}{R}$ or	f	قریفتس (۱۹۸۱)
خیر	آزمایشگاهی و صحرائی	$T^* = S_w \frac{R/d_{50}}{\Delta\rho_s/\rho}$ or $Re, Fr, \frac{d_{50}}{R}$	f	کاماچو و ین (۱۹۸۹)
بر پایه تنش برشی				
بلی (اندازه ذرات رسوب)	-	$\frac{u_*^2}{\Delta\rho_s \rho} gd_{50}$	$\frac{V}{\sqrt{u_*^2 - u_{*c}^2}}$	رادکیوی (۱۹۶۷)
خیر	آزمایشگاهی	$\frac{u_*^2}{\Delta\rho_s \rho} gd_s, \frac{u_*^2 h}{gd_s^2}$	$\frac{C}{\sqrt{g}}$ (C: ضریب شزی)	یالین (۱۹۷۷)
بلی	آزمایشگاهی و صحرائی	$\frac{VR}{\sqrt{gd_{50}^3}}, S, \sigma_g$	$\frac{RS}{d_{50}}$	براونلی (۱۹۸۳)
بلی	آزمایشگاهی و صحرائی	$\frac{d_{90}}{R}, \frac{h_{bedform}}{R}, \frac{h_{bedform}}{L_{bedform}}$	$\frac{C}{\sqrt{g}}$	ون راین (۱۹۸۴)
بر پایه سرعت				
بلی	آزمایشگاهی و صحرائی	$\frac{R}{d_{50}}, \frac{S}{\Delta\rho_s/\rho}$	$\frac{V}{\sqrt{\frac{\Delta\rho_s}{\rho} gd_{50}}}$	گراد و رانقا راجو (۱۹۶۶)
بر پایه ترکیب ممنتوم و انرژی				
خیر	آزمایشگاهی	$\frac{u_*}{\sqrt{\frac{\Delta\rho_s}{\rho} gd_s}}, \frac{\Delta\rho_s}{\rho} \frac{g}{v^2} d_{35}^3$	f	وایت و همکاران (۱۹۸۰، ۱۹۸۸)

Surfer8 پارامترهای مستقل y (عمق)، R (شعاع هیدرولیکی)، Re (عدد رینولدز)، Fr (عدد فرود) و SW (شیب سطح آب) برای هر آزمایش اندازه‌گیری شد و از معادله مانینگ جهت محاسبه n (ضریب زبری مانینگ) به عنوان پارامتر وابسته استفاده گردید.


مواد رسوبی مورد استفاده شامل سه نوع ماسه کاملاً یکنواخت از جنس کوارتز با قطرهای $D=0.15mm$ ، $D=0.2mm$ ، $D=0.4mm$ و با وزن مخصوص نسبی $2/65$ در نظر گرفته شد. ۱۰۴ آزمایش تحت شرایط هیدرولیکی متفاوت در حالت فرم بستر دون متعادل انجام پذیرفت (شکل (۱)). سپس با استفاده از پردازش تصویر (Image processing) و نرم‌افزار



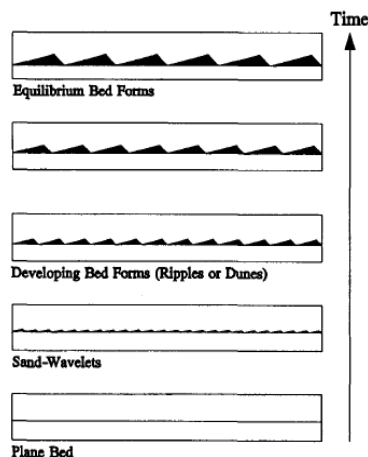
شکل ۲- اندازه‌گیری عمق و شیب سطح به کمک پردازش تصویر و سیستم دقیق الکترونیکی با استفاده از نرم‌افزار Surfer

۲-۳-۲- شبکه‌های شعاع مبنا (RBNN)

شبکه‌های شعاع مبنا از نوع شبکه‌های پیش‌خور بوده و دارای سه لایه می‌باشند: لایه ورودی، لایه پنهان (RB)، و لایه خروجی. شبکه‌های شعاع مبنا نسبت به سایر شبکه‌ها نرون‌های بیشتری احتیاج دارد. با این حال در کسری از زمان لازم برای آموزش سایر شبکه‌ها، طراحی می‌شود. مزیت اصلی این نوع شبکه به صفر رساندن خطا، روی داده‌های ورودی است. از سوی دیگر در این نوع شبکه نیازی به تعیین تعداد نرون‌های لایه مخفی نمی‌باشد؛ چرا که تعداد نرون‌های آن برابر با تعداد بردار-های ورودی است. در شکل (۲) شبکه شعاع مبنا با R ورودی نشان داده شده است.



شکل ۳- شبکه عصبی پیش‌خور^۳



شکل ۱- نمونه‌ای از شکل‌های فرم بستردون متعادل^۱ و تل‌ماسه^۲ ماسه^۲

۲-۳-۳- مدل شبکه عصبی مصنوعی (ANN)

یک شبکه عصبی مصنوعی بنا به تعریف، یک سیستم پردازش اطلاعات موازی است که عملکرد اجرایی مشخصی بر گرفته از ساختار بیولوژیکی شبکه مغز انسان دارد [۹] ساختار شبکه‌های عصبی مصنوعی به گونه‌ای است که نرون‌ها (واحدهای پردازش اطلاعات) در دسته‌هایی که لایه نامیده می‌شوند، مرتب می‌شوند. معماری معمول شبکه عصبی متشکل از سه لایه است: لایه ورودی (داده‌ها را در شبکه توزیع می‌کند)، لایه پنهان (داده‌ها را پردازش می‌کند) و لایه خروجی (نتایج را به ازای ورودی‌های مشخص استخراج می‌کند). شکل زیر شبکه عصبی پیش‌خور را نشان [۱۰].

۲-۳-۱- شبکه‌های عصبی پیش‌خور چند لایه (FFNN)

شبکه‌های عصبی پیش‌خور کاربردی‌ترین نوع شبکه‌های عصبی مصنوعی می‌باشند. چرا که می‌توان ثابت کرد شبکه‌های عصبی پیش‌خور با یک لایه پنهان، تابع فعال‌سازی لجستیک در لایه پنهان، تابع فعال‌سازی خطی در لایه خروجی و تعداد نرون-های کافی در لایه پنهان، قادرند هر تابعی را با دقت دلخواه تقریب بزنند. به عبارت دیگر، با تعداد کافی از واحدهای پنهان، شبکه تقریباً می‌تواند هر تابع خطی یا غیر خطی را با یک سطح دلخواه از دقت، تقریب بزند.

$$X = (0.5 + 0.95 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}) \quad (1)$$

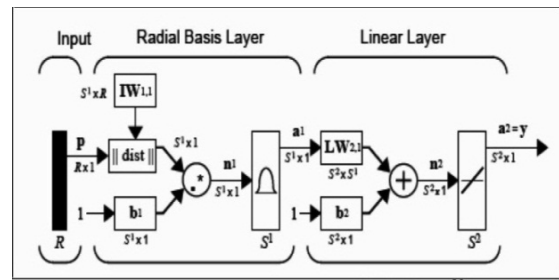
که در آن X_i ، X_{\max} و X_{\min} به ترتیب نشانگر داده نرمال شده، داده اصلی نام، مینیمم داده و ماکسیمم داده می‌باشند.

۲-۵- تعیین ساختار شبکه‌های عصبی و آموزش آن‌ها

برای این منظور کلیه پارامترهای آموزشی، تعداد نرون‌ها و لایه‌ها، تابع انتقال و الگوریتم آموزش با استفاده از سعی و خطا استفاده شدند. به طوری که برای داده‌های تمام مدل‌ها، شبکه با یک لایه پنهان و ۴-۶ نرون برای شبکه پیش‌خور استفاده شد. ضمناً بردارهای ورودی برای شبکه پیش‌خور به صورت تصادفی توسط نرم‌افزار Matlab به سه مجموعه به شرح زیر تقسیم می‌شوند: ۶۰٪ داده‌ها در مجموعه آموزشی، ۲۰٪ داده‌ها در مجموعه ارزیابی در راستای جلوگیری از بیش‌برازش شبکه و ۲۰٪ داده‌ها در مجموعه آزمون برای بررسی کارایی شبکه نهایی. با توجه به این که مجموعه بالا تصادفی انتخاب می‌شود، برای رسیدن به نتایج بهتر و با دقت بالاتر، روند آموزش چند بار تکرار شد تا خروجی هر سه مجموعه نزدیک به هم باشد. برای شبکه شعاع مینا، ۴۰٪ داده‌ها جهت آزمون و ۶۰٪ داده‌ها جهت آموزش شبکه انتخاب شدند. نکته مهم در انتخاب داده‌های آزمون آن است که گستره وسیع از انواع داده‌ها را در بر گیرد. بدین منظور در گزینش داده‌های آزمون سعی شده اولاً مقادیر حداکثر و حداقل را در بر نگیرد و ضمناً سری داده‌های آزمون و آموزش به لحاظ پارامترهای میانگین و انحراف معیار به هم نزدیک باشند.

۳-۱- شبیه‌سازی نتایج و بحث

در گام نخست (مطابق جداول (۲) و (۳))، ۱۱ مدل به عنوان مدل‌های اولیه با ورودی‌های مختلف با دو نوع تابع هدف با بعد و بی‌بعد به شبکه‌های عصبی معرفی شدند. در این مطالعه جهت تنظیم شبکه پیش‌خور از تابع trainlm با توجه به کارایی بالا و سرعت آن به عنوان تابع آموزش شبکه و از تابع MSE به عنوان تابع خطا استفاده شد. تعداد لایه‌ها، دو بود که تابع انتقال لایه اول tansig (تانژانت سیگموئید) و تابع انتقال لایه دوم purline (غیر خطی)، تعداد نرون‌ها با آزمون و خطا ۶-۴ و تعداد گام‌های آموزش شبکه روی ۱۰۰۰ تنظیم شد. جهت آموزش سریع‌تر شبکه، الگوریتم لوونبرگ - مارکوورت^۱ که سعی در کاهش




شکل ۴- نمایش شبکه عصبی پایه شعاعی

۲-۳-۳- مدل استنتاجی تطبیقی عصبی- فازی (ANFIS)

این مدل که توسط یانگ در سال ۱۹۹۶ بسط یافت، اجازه می‌دهد که سیستم‌های فازی در مباحث آموزش پارامترها، از الگوریتم آموزش انتشار خطا به عقب تطبیقی استفاده نمایند [۱۱]

از یک ساختار ANFIS، که از مجموعه‌ای از قواعد IF-THEN فازی نوع TSK (فقط برای یک قانون) تشکیل گردیده است، می‌توان جهت مدل‌سازی و نگاشت داده‌های ورودی- خروجی استفاده کرد. 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.



شکل ۵- شبکه عصبی- فازی

۲-۴- نرمالیزه کردن داده‌ها

آموزش شبکه‌های عصبی در صورت اعمال یک‌سری پیش‌پردازش‌ها بر روی ورودی‌ها و هدف می‌تواند کارایی بالاتری داشته باشد. با این حال در مواردی که تعداد داده‌ها افزایش یابد، نرمال‌سازی داده‌ها چندان مفید نمی‌باشد. در این مطالعه، هم از داده‌های خام و هم از داده‌های پیش‌پردازش شده لگاریتمی و نیز داده‌های پیش‌پردازش شده به فرم زیر استفاده شد:

جدول ۳- مدل‌های دارای تابع هدف با بعد

سناریو	پایانه‌ها و متغیرهای مستقل
ANN1	S_w
ANN2	F_r
ANN3	R_e
ANN4	S_w, F_r
ANN5	S_w, R_e
ANN6	S_w, F_r, R_e
ANN7	$S_w, F_r, R_e, R/D50$
ANN8	$S_w, R_e, R/D50$
ANN9	$S_w, F_r, R/D50$
ANN10	F_r, R_e
ANN11	$F_r, R_e, R/D50$

در جداول (۲) و (۳) به ترتیب، توابع هدف برای تعیین ضریب زبری، در دو حالت بدون بعد به صورت $n\sqrt{g/R^{1/6}}$ و با بعد n (فرم اصلی رابطه مانینگ)، تعریف شده‌اند تا نقش تابع هدف به عنوان ورودی در روش‌های جعبه سیاه^۲ مشخص گردد. تمام ورودی‌های مستقل به صورت بی‌بعد و ترکیبی از شیب سطح آب (S_w)، شعاع هیدرولیکی بر قطر متوسط ذرات رسوب ($R/D50$)، عدد فرود (Fr) و عدد رینولدز (Re)، می‌باشند.

۳-۲- تخمین ضریب زبری برای داده‌های با بعد و بی‌بعد

نتایج حاصل از شبیه‌سازی نشان دادند که برترین مدل‌ها برای شبکه پیش‌خور، مدل ۶ در بین مدل‌های با تابع هدف با بعد شامل $R=0/94$ و $MARE=2/04$ و مدل ۵ در بین مدل‌های با تابع هدف بی‌بعد شامل $R=0/93$ و $MARE=1/908$ می‌باشند که همبستگی بالای خروجی مشاهداتی و پیش‌بینی شده برای شبکه پیش‌خور با تابع هدف با بعد و بی‌بعد در شکل‌های (۶) و (۸) مشهود است.

محاسبات با استفاده از عدم محاسبه ماتریس هسین^۱ (مشتقات دوم) دارد، به عنوان الگوریتم آموزش شبکه به کار رفت و در نهایت به منظور ارزیابی و بررسی کارایی روش‌های استفاده شده برای تخمین ضریب زبری، از توابع میانگین قدرمطلق نسبت خطاها (رابطه (۲))، ضریب همبستگی (رابطه (۳))، جذر میانگین مربعات خطاها (رابطه (۴)) و میانگین قدرمطلق خطاها (رابطه (۵)) استفاده شد.

$$MARE = \frac{1}{N} \sum \left| \frac{(n_m - n_p)}{n_m} \right| \times 100 \quad (2)$$

$$R = \frac{\sum_{l=1}^N (n_m - \bar{n}_m) \cdot (n_p - \bar{n}_p)}{\sqrt{\sum_{l=1}^N (n_m - \bar{n}_m)^2 \cdot (n_p - \bar{n}_p)^2}} \quad (3)$$

$$RMSE = \sqrt{\left[\sum_{i=1}^N \frac{(n_m - n_p)^2}{N} \right]} (m^{-\frac{1}{2}} \times \text{sec}) \quad (4)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |n_m - n_p| (m^{-\frac{1}{3}} \times \text{sec}) \quad (5)$$

که در آن‌ها:

N : تعداد داده‌ها

n_p : ضریب زبری پیش‌بینی شده توسط شبکه عصبی

n_m : ضریب زبری اندازه‌گیری شده توسط آزمایشات است.

جدول ۲- مدل‌های دارای تابع هدف بی‌بعد

سناریو	پایانه‌ها و متغیرهای مستقل
$\bar{ANN}1$	S_w
$\bar{ANN}2$	F_r
$\bar{ANN}3$	R_e
$\bar{ANN}4$	S_w, F_r
$\bar{ANN}5$	S_w, R_e
$\bar{ANN}6$	S_w, F_r, R_e
$\bar{ANN}7$	$S_w, F_r, R_e, R/D50$
$\bar{ANN}8$	$S_w, R_e, R/D50$
$\bar{ANN}9$	$S_w, F_r, R/D50$
$\bar{ANN}10$	F_r, R_e
$\bar{ANN}11$	$F_r, R_e, R/D50$

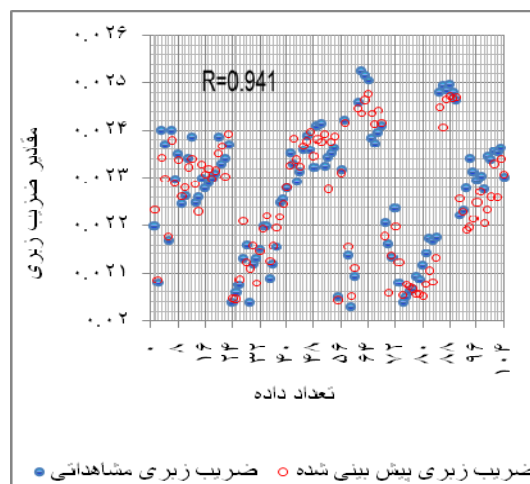
جدول ۴- رتبه‌بندی خطاهای تخمین ضریب زبری مانینگ با شبکه پیش‌خور برای آزمون مدل‌های با تابع هدف با بعد برای

بررسی عملکرد مدل‌ها


Model	NE	R	RMSE	MAE
ANN1	۸	۹	۸	۷
ANN2	۱۱	۱۱	۱۰	۱۰
ANN3	۹	۷	۷	۹
ANN4	۱۰	۱۰	۹	۸
ANN5	۲	۵	۳	۲
ANN6	۱	۱	۱	۱
ANN7	۳	۴	۴	۳
ANN8	۶	۳	۲	۶
ANN9	۷	۸	۱۱	۱۱
ANN10	۴	۲	۵	۴
ANN11	۵	۶	۶	۵

۳-۳- نتایج مدل‌های برتر شبکه‌های عصبی


نتایج شبیه‌سازی با شبکه‌های پیش‌خور و شعاع مبنا از یک سو و عصبی- فازی از سوی دیگر نشان دادند که مدل‌های مربوط به شبکه پیش‌خور به لحاظ همبستگی داده‌ها و نیز خطاهای دیگر مورد ارزیابی حائز بهترین شرایط هستند. در شبیه‌سازی با شبکه‌های عصبی، کمترین میانگین قدر مطلق نسبت خطاها و در عین حال بیشترین همبستگی داده‌ها، نشانگر کارایی بالاتر شبیه‌سازی می‌باشد. مطابق نتایج شبیه‌سازی با دو شبکه پیش‌خور، شعاع مبنا از یک سو و عصبی- فازی از سوی دیگر مشاهده شد که مدل‌های مربوط به شبکه پیش‌خور به لحاظ همبستگی داده‌ها و نیز خطاهای دیگر مورد ارزیابی حائز بهترین شرایط هستند. چنان که در شکل‌های (۷) و (۹) (نمودارهای پراکنش مدل‌های برتر شبکه پیش‌خور) مشاهده می‌شود، برترین مدل برای شبکه پیش‌خور در بین مدل‌های با تابع هدف با بعد، مدل ۶ شامل $R=0.94$ و $MARE=2/04$ و مدل ۵ در بین مدل‌های با تابع هدف بی‌بعد شامل $R=0.93$ و $MARE=1/908$ می‌باشند که کارایی بالای شبکه پیش‌خور را نشان می‌دهد. همچنین مدل‌های با یک متغیر مستقل ورودی نتایج ضعیفی نداشته‌اند. لذا در صورتی که حداقل ورودی وجود داشته باشد نیز می‌توان نتایج قابل قبولی را انتظار داشت، چرا که در این مطالعه نیز مطابق جداول (۴) و (۵)، مدل‌های ۱ و ۳ به نتایج قابل قبولی منجر گشته‌اند. نتایج شبیه‌سازی تخمین ضریب زبری با شبکه پیش‌خور با استفاده از داده‌های لگاریتمی نشان می‌دهند که خطای میانگین قدر مطلق نسبت خطاها، با



شکل ۶- نمودار ضریب زبری مدل ۶ شبکه پیش‌خور با تابع هدف با بعد



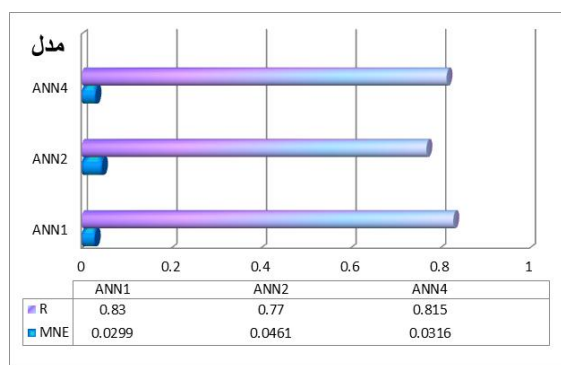
شکل ۷- نمودار پراکنش داده‌های آزمون ضریب زبری مدل ۶ شبکه پیش‌خور با تابع هدف با بعد




شکل ۸- نمودار ضریب زبری مدل ۵ شبکه پیش‌خور با تابع هدف بی‌بعد

همچنین همبستگی داده‌های تابع هدف و خروجی پیش‌بینی شده در هر دو گروه با تابع هدف با بعد و بی‌بعد مقدار بالا و نزدیکی دارد. اما مقدار خطای میانگین قدر مطلق نسبت خطاها در حالت با تابع هدف بی‌بعد کاهش یافته و این امر کارایی بالاتر در این گروه را نشان می‌دهد.

مطابق جداول (۴) و (۵)، مقایسه نتایج رتبه‌بندی عملکرد هر دو گروه مدل‌های با تابع هدف با بعد و بی‌بعد نشان می‌دهد که مدل‌های بدون شیب سطح آب (S_W) مانند مدل‌های ۲، ۳ و ۱۱ دارای خطای بیشتری نسبت به مدل‌های دارای این پارامتر مانند مدل‌های ۱، ۶، ۷، ۸ و ۹ (با پارامترهای مستقل مطابق جداول (۲) و (۳)) هستند و این امر نشان دهنده تأثیرگذاری بالای شیب سطح در تخمین ضریب زبری و ضرورت دخالت دادن این پارامتر مستقل در تخمین ضریب زبری مانینگ می‌باشد.

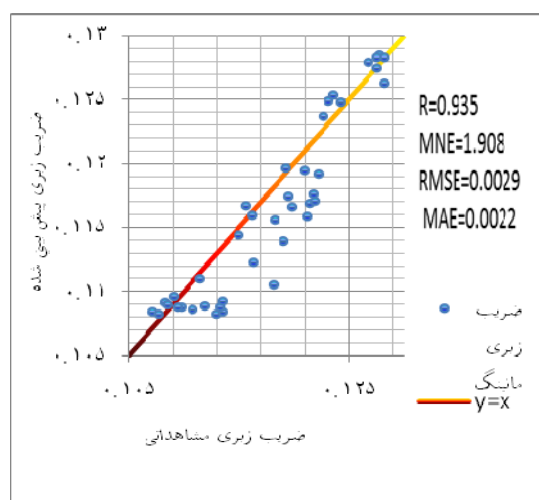


شکل ۱۰- نمودار خطاهای مدل‌های با تابع هدف با بعد شبکه شعاع مبنا



شکل ۱۱- نمودار خطاهای مدل‌های با تابع هدف بی‌بعد شبکه شعاع مبنا

مقدار $MARE=0.0552$ برای مدل ۶ و $MARE=0.0974$ برای مدل ۵، دارای بهبود عملکرد قابل ملاحظه‌ای نسبت به شبیه‌سازی با استفاده از داده‌های خام می‌باشد. مطابق جداول (۴) و (۵)، مدل دوم (با ورودی عدد فرود مطابق جداول (۲) و (۳))، ضعیف‌ترین نتایج را با استفاده از شبکه پیش‌خور در بین مدل‌های هر دو گروه مدل‌های با تابع هدف با بعد و بی‌بعد داشته است که این امر نشانگر تأثیر کمتر این پارامتر نسبت به بقیه پارامترهای مستقل ورودی در تخمین ضریب زبری مانینگ می‌باشد.



شکل ۹- نمودار پراکنش داده‌های آزمون ضریب زبری مدل ۵ شبکه

جدول ۵- رتبه‌بندی خطاهای تخمین ضریب زبری مانینگ با شبکه پیش‌خور برای آموزش مدل‌های با تابع هدف بی‌بعد برای

بررسی

Model	MNE	R	RMSE	MAE
A'NN1	۸	۹	۸	۷
A'NN2	۱۱	۱۱	۱۰	۱۰
A'NN3	۹	۷	۷	۹
A'NN4	۱۰	۱۰	۹	۸
A'NN5	۲	۵	۳	۲
A'NN6	۱	۱	۱	۱
A'NN7	۳	۴	۴	۳
A'NN8	۶	۳	۲	۶
A'NN9	۷	۸	۱۱	۱۱
A'NN10	۴	۲	۵	۴
A'NN11	۵	۶	۶	۵

۳-۴- تحلیل حساسیت

جهت درک بهتر میزان تأثیر هر یک از متغیرهای مستقل روی ضریب زبری به عنوان تابع هدف مطالعه، تحلیل حساسیت روی داده‌ها برای شبکه پیش‌خور که بهترین نتیجه از نظر خطاها را داشته است انجام شد. همان‌طور که در جداول (۶) و (۸) مشاهده می‌شود، مقادیر خطاها با حذف هر یک از پارامترهای مستقل، اختلاف کمی را نشان می‌دهند که این نکته نشانگر درستی انتخاب و تأثیر بالای هر چهار پارامتر مستقل مطالعه بر روی ضریب زبری می‌باشد. نهایتاً مطابق جدول (۷)، متغیر مستقل R_e در بین مدل‌های با تابع هدف با بعد و متغیر مستقل $R/D50$ در بین مدل‌های با تابع هدف بی‌بعد به عنوان تأثیرگذارترین متغیر روی ضریب زبری شناخته شدند.

شکل‌های (۱۴) و (۱۵)، رتبه‌بندی تحلیل حساسیت مدل‌های با تابع هدف با بعد و بی‌بعد برای چهار خطای مورد ارزیابی را نشان می‌دهند.

جدول ۶- تحلیل حساسیت آزمون مدل‌های با تابع هدف با بعد

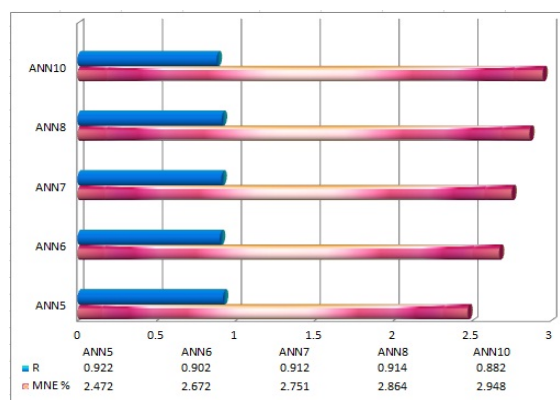
تحلیل حساسیت تست مدل‌های با تابع هدف با بعد برای شبکه پیش‌خور				
سناریو	MNE	R	RMSE	MAE
با تمام پارامترهای ورودی	۲/۲۳۴	۰/۹۲۹	۶/۳۲ E - ۰۴	۴/۱۰ E - ۰۴
R/D50 بدون	۲/۰۴	۰/۹۴۱	۵/۸۰ E - ۰۴	- ۰۴ ۴/۶۴ E
F_r بدون	۲/۳۳۳	۰/۹۳۲	۶/۰۶ E - ۰۴	۴/۲۹ E - ۰۴
R_e بدون	۲/۳۹۱	۰/۸۹۳	۰/۰۰۳۵	۰/۰۰۲۸
S_w بدون	۲/۲۹۱	۰/۹۱۷	۶/۸۹ E - ۰۴	۵/۲۳ E - ۰۴

جدول ۷- رتبه‌بندی تحلیل حساسیت مدل‌های با تابع هدف

با بعد

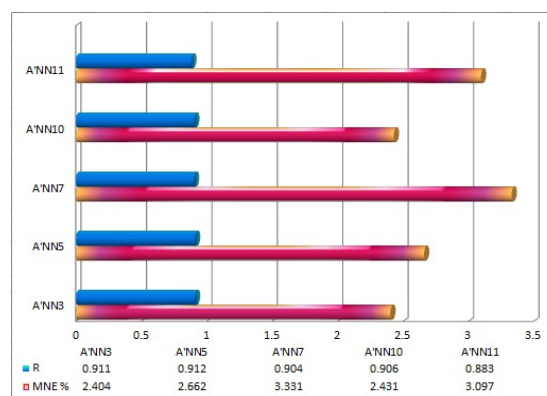
رتبه تحلیل حساسیت تست مدل‌های با تابع هدف با بعد برای شبکه پیش‌خور				
سناریو	MNE	R	RMSE	MAE
با تمام پارامترهای ورودی	۲	۳	۲	۲
R/D50 بدون	۱	۱	۱	۱
F_r بدون	۴	۲	۲	۴
R_e بدون	۵	۵	۵	۵
S_w بدون	۳	۴	۴	۳

مطابق شکل‌های (۱۰) و (۱۱)، برای شبکه شعاع مینا، برترین مدل در بین مدل‌های با تابع هدف با بعد، مدل ۱ شامل $R=۰/۸۳$ و $MARE=۰/۰۲۹۹$ و نیز مدل ۱ در بین مدل‌های با تابع هدف بی‌بعد شامل $R=۰/۸$ و $MARE=۰/۰۲۹$ می‌باشند که نشان می‌دهد در شبیه‌سازی با این شبکه، مدل‌های با تابع هدف با بعد دارای همبستگی بهتری بوده‌اند. مطابق شکل‌های (۱۲) و (۱۳)، در شبکه عصبی- فازی، برترین مدل در بین مدل‌های با تابع هدف با بعد و بی‌بعد به ترتیب، مدل ۵ شامل $R=۰/۹۲۲$ و $MARE=۲/۴۷۲$ و مدل ۳ شامل $R=۰/۹۱۱$ و $MARE=۲/۴۷۲$ می‌باشند که نشان می‌دهد در شبیه‌سازی با این شبکه، هر دو گروه مدل‌های با تابع هدف با بعد و بی‌بعد دارای عملکرد بالا و نزدیکی بوده‌اند.



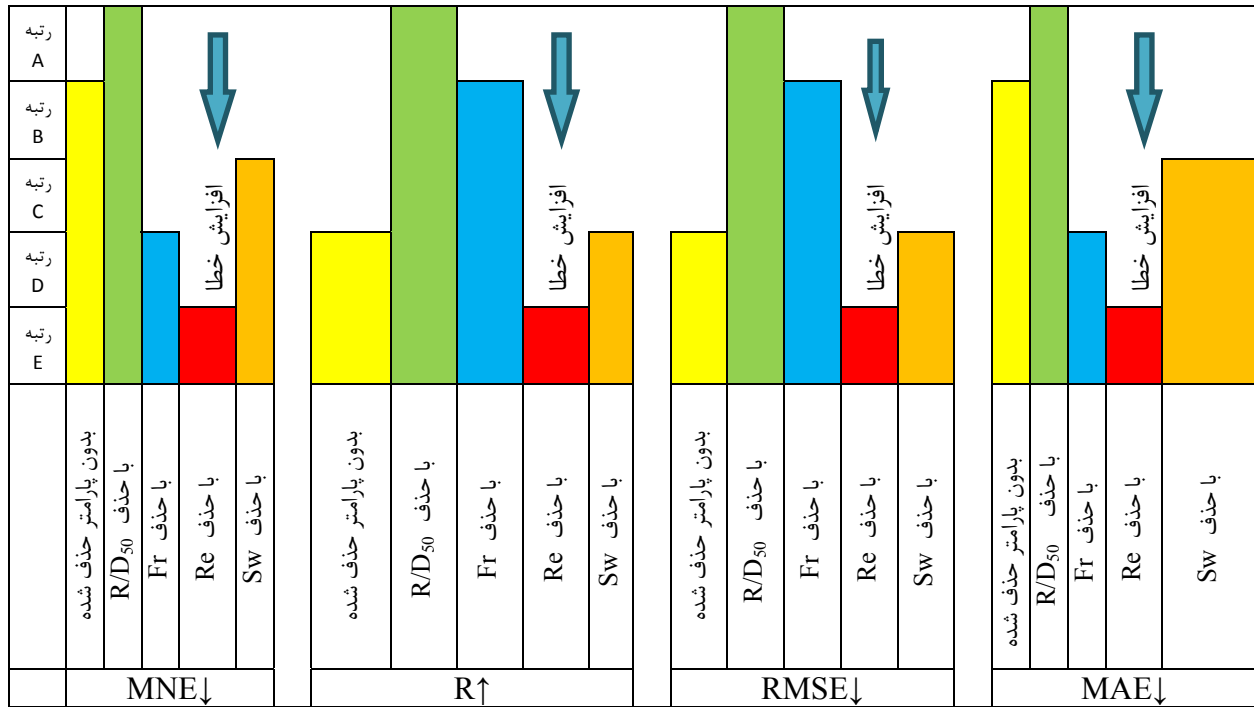
شکل ۱۲- نمودار خطاهای مدل‌های با تابع هدف با بعد شبکه

عصبی- فازی

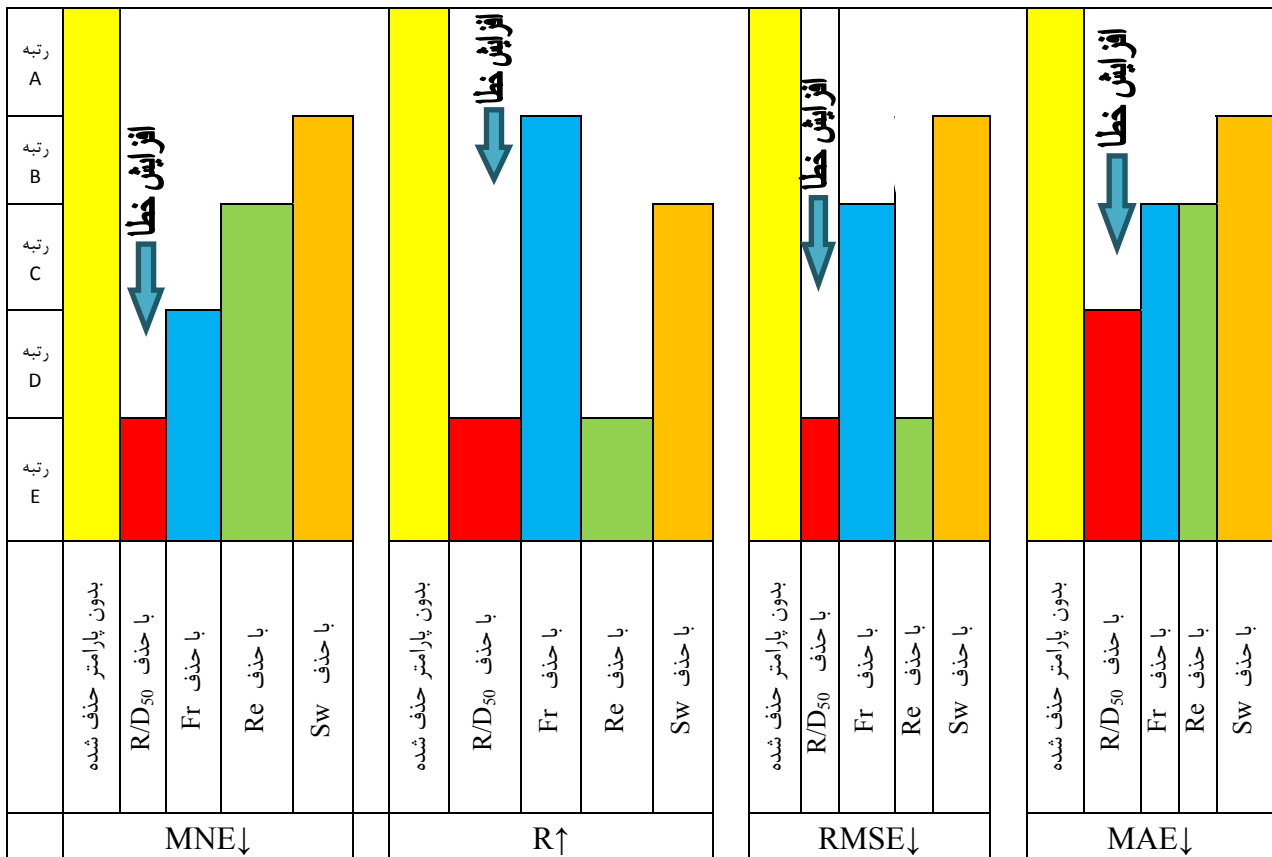


شکل ۱۳- نمودار خطاهای مدل‌های با تابع هدف بی‌بعد شبکه

عصبی- فازی



شکل ۱۴- نمودار رتبه‌بندی عملکرد تحلیل حساسیت آزمون مدل‌های شبکه پیش‌خور (با تابع هدف با بعد)



شکل ۱۵- نمودار مقادیر خطاهای آزمون تحلیل حساسیت شبکه پیش‌خور (با تابع هدف بی‌بعد)

بین مدل‌های هر دو گروه مدل‌های با تابع هدف با بعد و بی‌بعد داشته است که این امر نشانگر تأثیر کمتر این پارامتر نسبت به بقیه پارامترهای مستقل ورودی در تخمین ضریب زبری مانینگ می‌باشد.

۴- مقایسه نتایج نشان داد که مدل‌های بدون S_w مانند مدل‌های ۳ و ۱۱ دارای خطای بیشتری نسبت به مدل‌های دارای S_w مانند مدل‌های ۱، ۶، ۷، ۸ و ۹ هستند و این امر نشان دهنده اهمیت و تأثیرگذاری شیب سطح در تخمین ضریب زبری می‌باشد.

۵- مدل فازی- عصبی در هر چهار معیار مورد ارزیابی، کارایی بهتری نسبت به شبکه شعاع مبنا داشته ولی در مقایسه با شبکه‌های پیش‌خور، کارایی ضعیف‌تری دارد.

۶- شبکه شعاع مبنا در معیار ارزیابی MNE عملکرد مناسب‌تری نسبت به بقیه شبکه‌ها داشته، ولی نتایج نهایی آزمون این مدل در مورد همبستگی داده‌های هدف و خروجی شبکه نسبت به مدل‌های دیگر از دقت کافی برخوردار نیست.

۷- کارایی نهایی مدل با پیش پردازش با تابع لگاریتمی افزایش می‌یابد.

۵- مراجع

- [۱] شفاعة بجستان، م.، "هیدرولیک انتقال رسوب"، دانشگاه شهید چمران اهواز، ۱۳۸۷.
- [۲] محمودیان شوشتری، م. ونیسی، ق.، "تخمین ضریب زبری مانینگ در بازه‌ای از کارون بزرگ با روش‌های مختلف"، پنجمین کنفرانس هیدرولیک ایران، دانشگاه شهید باهنر کرمان، ۱۷-۱۹ آبان، ۱۳۸۴، ص ۱-۷.
- [۳] لشته‌نشایی، م. ا.، حاتمی، م.، "بررسی عوامل مؤثر بر برخی روابط تعیین کننده ضریب زبری"، ششمین کنفرانس هیدرولیک ایران، دانشگاه شهرکرد، ۱۳-۱۵ شهریور، ۱۳۸۶، ص ۱-۲.
- [4] Afzalimehr, H., Anctil, F., "Estimation of Gravel-Bed River Flow Resistance", Journal of Hydraulic Engineering, 1998, 124 (10), 1054-1058.
- [5] Yuhong, Z., Wenxin, H., "Application of Artificial Neural Network to Predict the Friction Factor of Open Channel Flow", Journal of Communication in Nonlinear Science and Numerical Simulation, 2009, 14, 2373-2378.

جدول ۸- تحلیل حساسیت آزمون مدل‌های با تابع هدف بی- بعد

تحلیل حساسیت تست مدل‌های با تابع هدف با بعد برای شبکه پیش‌خور				
سناریو	MNE	R	RMSE	MAE
با تمام پارامترهای ورودی	۱/۹۸۹	۰/۹۷۲	۰/۰۰۲۹	۰/۰۰۲۳
بدون R/D50	۲/۴۳۵	۰/۸۸۴	۰/۰۰۲۷	۰/۰۰۲۹
بدون F_r	۲/۳۱۸	۰/۹۰۵	۰/۰۰۳۳	۰/۰۰۲۷
بدون R_e	۲/۴۶	۰/۹۰۲	۰/۰۰۳۶	۰/۰۰۲۷
بدون S_w	۲/۰۶۸	۰/۹۰۳	۰/۰۰۳۱	۰/۰۰۲۵

جدول ۹- رتبه‌بندی تحلیل حساسیت مدل‌های با تابع هدف بی- بعد

رتبه تحلیل حساسیت تست مدل‌های با تابع هدف با بعد برای شبکه پیش‌خور				
سناریو	MNE	R	RMSE	MAE
با تمام پارامترهای ورودی	۲	۳	۲	۲
بدون R/D50	۱	۱	۱	۱
بدون F_r	۴	۲	۲	۴
بدون R_e	۵	۵	۵	۵
بدون S_w	۳	۴	۴	۳

۴- نتیجه‌گیری

نتایج به دست آمده در این مطالعه، حاکی از این است که:

- ۱- شبکه عصبی و عصبی- فازی به عنوان روش‌های هوش مصنوعی، در تخمین ضریب زبری عملکرد مطلوبی داشته‌اند.
- ۲- مطابق نتایج تحلیل حساسیت روی داده‌ها برای شبکه پیش‌خور که بهترین نتیجه از نظر خطاها را داشته است، متغیر مستقل Re در بین مدل‌های با تابع هدف با بعد و متغیر مستقل R/D50 در بین مدل‌های با تابع هدف بی‌بعد به عنوان تأثیرگذارترین متغیر روی ضریب زبری شناخته شدند.
- ۳- مدل‌های با یک متغیر مستقل ورودی نتایج ضعیفی نداشته‌اند؛ لذا در صورتی که حداقل ورودی وجود داشته باشد نیز می‌توان نتایج قابل قبولی را انتظار داشت. چرا که در این مطالعه نیز مدل‌های ۱ و ۳ به نتایج قابل قبولی منجر گشته‌اند.
- مدل ۲ با پارامتر مستقل عدد فرود ضعیف‌ترین نتایج را در تخمین ضریب زبری مانینگ با استفاده از شبکه پیش‌خور در

-
- [10] Karayiannis, N. B., Venetsanopoulos, A. N., "Artificial Neural Network: Learning Algorithms Performance Evaluation and Applications", Kluwer Academic Publishers, Boston, London, 1993.
- [11] Morgan, G. C., "Fuzzy Logic", First Edition, Routledge Encyclopedia of Philosophy, Craig, London, 1998.
- [6] Şamandar, A., "A model of Adaptive Neural-Based Fuzzy Inference System (ANFIS) For Prediction of Friction Coefficient in Open Channel Flow", Journal of Scientific Research and Essays, 2011, 6 (5), 1020-1027.
- [7] Yen, B. C., "Channel Flow Resistance; Centennial of Manning's Formula", Water Resources Publications, Colorado, US, 2006.
- [8] Kuan, C. M., "Artificial Neural Network: An Economic Perspective", Journal of Econometric Reviews, 1994, 13, 1-91.
- [9] Haykin, S., "Neural Network: a Comprehensive Foundation", New York, 1994.

EXTENDED ABSTRACT

Simulation of Open Channel Flow Resistance with Movable Bed Using Artificial Neural Network

Kiyoumars Roushangar ^{a,*}, Saeid Mohammad Pour ^b

*Faculty of Civil Engineering, Tabriz University, Tabriz, Iran
Azad University of Ahar, Ahar, Iran*

Received: 04 November 2014; **Accepted:** 02 June 2015

Keywords:

Manning Roughness coefficient, Movable bed, Back prop neural network, Radial Basis network, ANFIS

1. Introduction

Estimation of flow resistance in an alluvial channel with reasonable accuracy is of great interest to hydraulic engineers. However, the problem remains unsolved despite numerous investigations over the past decades. The difficulty arises because the bed form affects the flow resistance. In addition, the bed in an alluvial channel is not fixed but continually undergoes changes in its characteristic geometry and dimensions as a result of the interaction between the flow and bed.

2. Methodology

2.1. Experimental study

Sediment and flow variables like flow depth, flow velocity, water surface gradient, sediment diameter and its distribution and type, are the main parameters influencing the bed forms. A 5 m long, 0.15 m wide, and 0.25 m tall rectangular pollex glass flume located in the hydraulic laboratory of Caen University was utilized as shown in Fig. 1.

Sediment particles used in the experiments were natural quartz sand with a specific gravity of 2.65. Uniform sizes of sand with average diameters of 0.15 mm and 0.4 mm were chosen. The water flow was supplied by a pump which was re-circulated between the upstream and downstream tanks. At the beginning of each experiment, sediment particles were saturated to provide real natural conditions and prevent incipient motion of dry particles. They were then placed on the bed of the test section. Then, sediments were distributed and smoothed by a T-shaped device without any compaction to obtain 3 cm of sediment in height on the bed. In these experiments discharge rate controlled by a valve in the discharge pipe of the pump and sediment was recirculated and water depth and bed variations measured by using image processing. For this purpose, a digital camera is used for taking picture in different time and space and then surfer8 software is used for image processing and obtaining accurate data. Sand wavelets were generated within a few minutes (for example around four minutes according to Coleman [1]). Dune height was measured 15 to 30 minutes after commencement of the run (see Fig. 1). By changing the flow depth and discharge, different average velocities and Froude numbers could be obtained. The water depth and discharge rate were set in a manner so that dunes formed on the bed [2]. In these experiments, the difficulty lay in measuring water surface gradient S_w . Because the water surface had fluctuations over the space and time due to bed form shapes. For overcome to this problem, firstly a thin sensitive wire gauge (with high sensitivity to voltage variations) set to F shape instrument and by plotting a voltage-depth linear equation this instrument is calibrated and used for measuring water surface slope using special voltage meter and computer program with 200 data in second.

* Corresponding Author

E-mail addresses: roshangari@tabrizu.ac.ir (Kiyoumars Roushangar), saeed_smp@yahoo.com (Saeid Mohammad Pour)

2.2. ANN modeling

The approach of intelligence systems networks has the advantages of using field recorded data directly without simplification and is not like regression analysis, which needs to make an assumption of equation in advance. Furthermore, this method is capable of executing parallel computations, and can simulate a nonlinear system which is hard to describe by traditional physical modeling. This has allowed for a wide range of applications in water, hydraulic and hydrological engineering to be extensively published in recent years.

In rivers, hydraulic bed is movable, flow resistance varies, and determination of different effective parameters on friction factor of movable bed is complicated. In spite of many researches about flow resistance, there is no universal formula up to now. In this research, experimental data of movable bed Flume with dune bed form was used. Then FFNN (Feed Forward Neural Network), RBF (Radial Bases Neural Network) and ANFIS (Adaptive neuro-Fuzzy Inference System) used for predicting of roughness coefficients in both of dimensional and dimensionless roughness coefficient.

3. Results and discussion

The best configuration was determined by trial and error. Based on trial and error method, two combinations of data consisting of dimensional and non-dimensional parameters were considered as inputs to predict Manning roughness. These two input combinations were used to see which one leads to better results.

Run of 11 existing ANN and ANFIS models with different dimensional and non-dimensional parameters indicate that Model (VI) (Fr, Re, Sw) for both of dimensional and non-dimensional target function predicts the friction factor in all the networks with the lowest error and highest correlation operation. Table1 shows result of FFNN performance rank using different models.

Table 1. Ranking results of different models

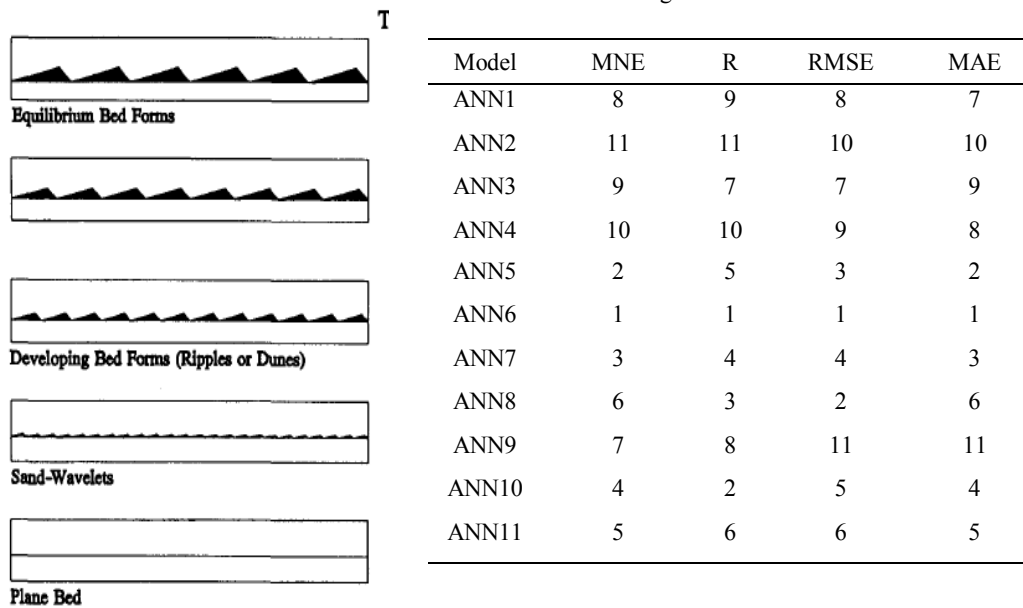


Fig. 1. schematic view of dune shape and equilibrium bed form

4. Conclusions

In rivers, hydraulic bed is movable, flow resistance varies, and determination of different effective parameters on friction factor of movable bed is complicated. In spite of many researches about flow resistance, there is no universal formula up to now. In this research, experimental data of movable bed Flume with dune bed form was used. Then FFNN (Feed Forward Neural Network), RBF (Radial Bases Neural Network) and ANFIS (Adaptive neuro-Fuzzy Inference System) were used for predicting of roughness coefficients in both of dimensional and dimensionless roughness coefficient. Results showed capability and workability of different neural networks in simulation of roughness coefficient. Numerical tests indicate that the ANFIS model leads to better results than the RBF model; but it is not as robust as FFNN. Also a sensitivity analysis showed that the Reynolds number (Re) for

dimensional variables and R/D50 in no dimensional variables are the most effective parameters on roughness coefficient.

5. References

- [1] Shafai-Bajestan, M., "Hydraulic of Sediment Transport", Ahvaz Chamran University, 1999.
- [2] Mahmoodian Shoshtari, M., Nissi, G., "Estimating Roughness Coefficients for Karun Large Range of Different Methods", The 5th Iranian Hydraulic Conference, Kerman, Iran, 8-10 November, 2005, pp 1-7.
- [3] Hatami, M., Neshaei, M. A. L., "The Factors Affecting the Determination of the Coefficient of Roughness", The 6th Iranian Hydraulic Conference, Shahre Kord, Iran, 4-6 September, 2007, pp 1-2.
- [4] Afzalimehr, H., Ancil, F., "Estimation of Gravel-Bed River Flow Resistance", Journal of Hydraulic Engineering, 1998, 124 (10), 1054-1058.
- [5] Yuhong, Z., Wenxin, H., "Application of Artificial Neural Network to Predict the Friction Factor of Open Channel Flow", Journal of Communication in Nonlinear Science and Numerical Simulation, 2009, 14, 2373-2378.
- [6] Şamandar, A., "A Model of Adaptive Neural-Based Fuzzy Inference System (ANFIS) for Prediction of Friction Coefficient in Open Channel Flow", Journal of Scientific Research and Essays, 2011, 6 (5), 1020-1027.
- [7] Yen, B. C., "Channel Flow Resistance; Centennial of Manning's Formula", Water Resources Publications, Colorado, US, 2006.
- [8] Kuan, C. M., "Artificial Neural Network: An Economic Perspective", Journal of Econometric Reviews, 1994, 13, 1-91.
- [9] Haykin, S., "Neural Network: A Comprehensive Foundation", New York, 1994.
- [10] Karayiannis, N. B., Venetsanopoulos, A. N., "Artificial Neural Network: Learning Algorithms Performance Evaluation and Applications", Kluwer Academic Publishers, Boston, London, 1993.
- [11] Morgan, G. C., "Fuzzy Logic", First Edition, Routledge Encyclopedia of Philosophy, Craig, London, 1998.