



برآورد ضریب زبری بستر کانال های خاکی با استفاده از روش های شبکه های عصبی مصنوعی و سیستم های استنباط فازی عصبی-تطبیقی

مرتضی زنگانه، عبدالمطلب رستگار

دانشکده فنی و مهندسی (عمران)، دانشگاه گلستان، گلستان، ایران.

تاریخچه داوری:

دریافت: ۱۳۹۷-۰۳-۰۹
بازنگری: ۱۳۹۷-۰۴-۲۹
پذیرش: ۱۳۹۷-۰۵-۱۸
ارائه آنلاین: ۱۳۹۷-۰۷-۲۹

کلمات کلیدی:

برآورد
ضریب زبری بستر
کانال های خاکی
شبکه های عصبی مصنوعی
سیستم استنباط فازی-عصبی

برآورد ضریب زبری در طراحی کانال های خاکی از اهمیت زیادی برخوردار می باشد. این مساله حتی در مدل سازی عددی پدیده انتقال رسوب دارای اهمیت به سزایی است. به همین منظور، تاکنون روش های تجربی زیادی برای برآورد ضریب زبری در کانال ها ارائه شده است که غالباً دارای خطای زیادی در برآورد پارامتر مورد نظر می باشند. بنابراین، در این مقاله با استفاده از روش های ابزار محاسبات نرم مبتنی بر شبکه های عصبی مصنوعی و سیستم استنباط فازی عصبی-تطبیقی به ارائه مدل هایی جهت برآورد میزان ضریب زبری در کانال های خاکی پرداخته میشود. در این مدل ها پارامتر بی بعد شده عمق آب با اندازه متوسط رسوبات (h/d_{50}) ، عدد رینولدز برشی (R^*) ، پارامتر شیلدز (θ) و پارامتر بی بعد شده سرعت سقوط ذرات با سرعت برشی جریان (w/U_f) ، به دست آمده از روش تحلیل ابعادی باکینگهام، به عنوان پارامتر ورودی روش های ابزار محاسبه نرم میباشند. پس از شبیه سازی و توسعه این مدل ها نتایج نشان میدهد که دقت روش های سیستم استنباط فازی عصبی-تطبیقی $(R^2 = 0.8433)$ و شبکه های عصبی $(R^2 = 0.8515)$ بالاتر از روابط تجربی متداول و روش های رگرسیونی خطی و غیرخطی برای برآورد این ضریب می باشد. همچنین، آنالیز حساسیت خطای برآورد در برابر حذف پارامترهای مختلف ورودی موثر بر ضریب زبری نشان میدهد پارامترهای دیگری مانند عدد رینولدز برشی و پارامتر عمق بی بعد آب در کانال نیز در میزان ضریب زبری بستر کانال های خاکی موثر است که در روابط تجربی ارائه شده این ضریب نادیده گرفته میشود. لازم به ذکر است که عدد رینولدز برشی به عنوان موثرترین پارامتر در مدل های مذکور شناخته شد. همچنین نتیجه گرفته شد که مدل های توسعه داده شده میتوانند به عنوان گزینه ای مناسب جهت برآورد ضریب زبری کانال ها خاکی باشند. این مساله با توجه به دامنه وسیع مکانیزم انتقال رسوب بیشتر اهمیت پیدا میکند.

۱- مقدمه

بررسی ها نشان می دهد که اکثر این روابط از دقت کافی جهت برآورد پارامتر مذکور برخوردار نمی باشند. نحوه استخراج این روابط به این ترتیب است که پژوهشگران با مطالعه آزمایشگاهی بر روی پارامترهای موثر بر آن موضوع، رابطه ای را برای آن ارائه می کنند. این روابط اغلب با هم اختلاف داشته که دلیل آن را شاید بتوان در تفاوت بین شرایط مختلف هیدرولیکی روی پدیده مورد نظر جستجو کرد که با شرایط آزمایشگاهی یکسان نمی باشد. پارامتر ضریب زبری بستر در کانال های خاکی با استفاده از زبری ماسه معادل یا پارامتر نیکورادزه (K_s) بیان می شود. به این صورت که ضریب زبری بستر در یک کانال با K_s برابر است با ضریب زبری کانالی که کف آن با

برآورد میزان ضریب زبری بستر کانال های خاکی با توجه به مکانیزم های مختلف انتقال ذرات رسوب غیر چسبنده مانند حرکت لایه ای رسوبات و پرش آن ها به داخل محیط آب ی کی از مسائل مهم در طراحی هیدرولیکی و مدل سازی عددی کانال های باز می باشد. این ضریب اثر زیادی بر روی نیمرخ سرعت جریان در کانال و همچنین میزان دبی عبوری از آن دارد [۱ و ۲]. جهت تعیین این ضریب تاکنون روابط تجربی مختلفی مبتنی بر فعالیت های آزمایشگاهی و با صرف هزینه و زمان زیادی، پیشنهاد شده است [۳].

* نویسنده عهده دار مکاتبات: m.zanganeh@gu.ac.ir



اگرچه تاکنون روابط زیادی برای محاسبه k_s ارائه شده است، به نظر می رسد که پارامترهای دیگری علاوه بر پارامترهایی که محققان تاکنون در تعیین ضریب زبری بستر استفاده کرده اند، در میزان ضریب زبری بستر دخیل باشند. از آنجایی که روابط تجربی روابطی هستند که با استفاده از تحقیق های آزمایشگاهی حاصل شده اند که انجام آن ها وقت و هزینه زیادی را طلب می کند. مطالعات میدانی کیم و همکارانش [۱۱] که برای تعیین ضریب مانینگ در یک رودخانه با بستر آبرفتی انجام گرفت و با استفاده از آنالیز عدم قطعیت مشخص گردید که با افزایش عمق آب و دبی عبوری ضریب مانینگ کاهش می یابد. این مساله مبین آن است که علاوه بر پارامترهای در نظر گرفته شده برای برآورد ضریب زبری پارامترهای دیگری نیز باید جهت برآورد ضریب زبری در کانال ها لحاظ گردند. روش های ابزار محاسبه نرم نیز به عنوان ابزاری قدرتمند در برآورد پارامترهای طبیعی می توانند در این راستا کارساز باشند. بنابراین، در این مقاله با استفاده از روش های ابزار محاسبات مبتنی بر شبکه های عصبی مصنوعی (ANNs) و سیستم استنباط فازی-عصبی تطبیقی (ANFIS) به محاسبه میزان ضریب زبری بستر در کانال های خاکی و هم چنین شناخت پارامترهای موثر بر آن پرداخته می شود.

در سال های اخیر ابزار محاسبات نرم مانند روش های شبکه های عصبی مصنوعی، سیستم های استنباط فازی، روش های برنامه ریزی ژنتیک، روش درخت های تصمیم گیری و روش ماشین بردار پشتیبانی به منظور پیش بینی پدیده های مختلف هیدرولیکی مورد استفاده قرار گرفته اند. نحوه کار در این نوع ابزار به این صورت بوده که با استفاده از برقراری رابطه ضمنی و یا صریح بین پارامترهای موثر بر یک پدیده، سعی در پیش بینی پدیده و یا برآورد پارامتر طبیعی مورد نظر می شود.

شبکه های عصبی مصنوعی تاکنون توسط پژوهشگرهای زیادی برای پیش بینی پدیده های هیدرولیکی به ویژه در کانال های باز مورد استفاده قرار گرفته است. یانگ و چنگ [۱۲] از روش ANNس به منظور برآورد نیم رخ سرعت و در نهایت برآورد دبی در کانال های باز استفاده کردند. یوهان و وناکسین [۱۳] از ANNس به منظور پیش بینی ضریب زبری در کانال های غیرخاکی استفاده کردند. در تحقیق دیگری شایا و سبلانی [۱۴] نیز به منظور برآورد ضریب زبری در لوله ها از روش ANNس استفاده کردند. در تحقیق دیگری عابدین

ماسه هایی به قطر k_s پوشیده شده باشد. k_s پارامتر مهمی بوده که محاسبه غیر دقیق آن منجر به خطای برآورد در تعیین توزیع سرعت در کانال های باز و در نتیجه خطا در برآورد تنش های برشی وارد بر دیواره کانال ها شده که در نهایت به طراحی نامناسب این کانال ها می انجامد [۲].

علیرغم اهمیت زیاد برآورد ضریب زبری بستر کانال ها، تاکنون محققان بر روی یک رابطه واحد برای محاسبه آن به اجماع نرسیده اند. محققان زیادی از جمله سیمونز و ریچادسون [۴]، ایگرز و وایت [۵]، هاموند و همکارانش [۶] و کلوسیمو و همکارانش [۷] برای محاسبه ضریب زبری بستر (k_s) رابطه زیر را ارائه کرده اند:

$$k_s = \alpha d_x \quad (1)$$

که در آن α ضریبی ثابت بوده و d_x اندازه ذره ای است که درصد از رسوبات بستر قطری کوچک تر از آن دارند. ویلسون [۸] و یالین [۹] پارامتر شیلدز (θ) را نیز در محاسبه k_s وارد کردند. نحوه محاسبه این پارامتر به صورت زیر می باشد:

$$\theta = \frac{U_f^2}{\sqrt{g(S-1)d_{50}}} \quad (2)$$

که در آن g شتاب ثقل، d_{50} میانگین اندازه قطر ذرات رسوب، s نسبت چگالی دانه های رسوب به چگالی آب (ρ_s/ρ_f) و U_f سرعت برشی بوده که طبق رابطه ی زیر محاسبه می شود:

$$U_f = \sqrt{gr_b I} \quad (3)$$

که در آن r_b شعاع هیدرولیکی کانال و I شیب کانال می باشند.

رابطه زیر به ارتباط بین سرعت متوسط و سرعت برشی در کانال های خاکی با ضریب زبری را بیان می کند.

$$\frac{U}{U_f} = 2.46 \ln \frac{14.8r_b}{k_s} \quad (4)$$

سومر و همکارانش [۱۰] در سال ۱۹۹۶ علاوه بر پارامتر شیلدز، دو پارامتر w/U_f و w^* را در محاسبه k_s موثر دانستند که w سرعت سقوط ذرات و w^* مطابق رابطه زیر تعریف می شود:

$$w^* = w / \sqrt{g(s-1)d_{50}} \quad (5)$$

[۲۶]. مازامیل [۲۷] و مازامیل و آن [۲۸] از FIS به منظور برآورد آب‌شستگی در پای آرمور کف استفاده کردند. این در حالی است که زنگانه و همکارانش [۲۹] به منظور برآورد میزان عمق تعادلی آب‌شستگی از FIS استفاده کردند. باطنی و جنگ [۳۰] از مدل استنباط فازی به منظور برآورد آب‌شستگی پای گروه‌های شمع استفاده کردند. اوزگیر نیز از مدل FIS جهت برآورد جریان رودخانه استفاده کرد [۳۱]. هم‌چنین عظمت الله و همکارانش [۳۲] از FIS جهت برآورد آب‌شستگی پای سرریز استفاده کردند. در همه این کاربردها مشخص شد که روش FIS نیز در مقابل روش‌های رگرسیونی خطی و غیرخطی از دقت مناسبی برخوردار می‌باشد. بنابراین با توجه به پیچیدگی مکانیزم انتقال رسوب در کانال‌های خاکی در این مقاله روش‌های ابزار محاسبه نرم جهت برآورد ضریب زبری بستر در این کانال‌ها استفاده می‌شوند.

به منظور توسعه روش‌های مبتنی بر روش ابزار محاسبات نرم ANNs و ANFIS جهت برآورد میزان ضریب زبری در کانال‌های باز خاکی، در این مقاله پس از ارائه مقدمه‌ای در رابطه با اهمیت برآورد پارامتر ضریب زبری و کاربردهایی از روش ابزار محاسبه نرم مورد نظر، در گام دوم داده‌های مورد استفاده در توسعه این مدل‌ها تحت عنوان مطالعه موردی مورد بررسی قرار می‌گیرد. در بخش سوم و چهارم نیز به ترتیب مبانی هر یک از روش‌های ANNs و ANFIS مورد بررسی قرار می‌گیرند. در بخش پنجم از مقاله به توسعه مدل‌های مربوطه جهت برآورد میزان ضریب زبری بستر و هم‌چنین آنالیز حساسیت پارامترهای موثر بر ضریب زبری بستر کانال‌های خاکی پرداخته می‌شود. هم‌چنین در این مرحله کارایی روش‌های توسعه داده شده در مقابل روابط تجربی ارائه شده توسط محققان مختلف مورد ارزیابی قرار می‌گیرد.

۲- مطالعه موردی

در این مقاله به منظور توسعه ابزار محاسبات نرم جهت برآورد ضریب زبری بستر و مقایسه آن با روابط تجربی موجود، از داده‌های آزمایشگاهی جمع‌آوری شده توسط سومر و همکارانش [۱۰] استفاده می‌شود. این داده‌ها از موسسه تحقیقات هیدرودینامیک و هیدرولیک (ISVA) دانشگاه صنعتی دانمارک تهیه شده‌است. این آزمایش‌ها در کانالی به طول ۱۰ متر، عرض ۳۰ سانتی‌متر و ارتفاع ۳۰ سانتی‌متر انجام

[۱۵] از ANNs به منظور بررسی کارایی کانال‌های باز انشعابی تحت تاثیر سازه‌های هیدرولیکی استفاده کرد. زهیری و دهقانی [۱۶] از ANNs به منظور برآورد دبی کانال‌های مرکب استفاده کردند. در تحقیق آن‌ها دامنه وسیعی از داده‌های آزمایشگاهی و هندسی به منظور ارائه یک مدل جامع تر مورد استفاده قرار گرفت. عظمت‌الله [۱۷] از روش برنامه‌ریزی ژنتیک به منظور برآورد ضریب زبری مانینگ در رودخانه‌های ایتالیا استفاده کرد و سپس با استفاده از ضریب زبری برآوردی میزان دبی عبوری از کانال را با دقت مناسبی برآورد کرد. آرپان و کیشانجیت نیز از روش برنامه‌ریزی ژنتیک به منظور برآورد ضریب زبری مانینگ و برآورد دبی در رودخانه‌های پیچ دار استفاده کردند [۱۸]. نکته‌ای که وجود دارد این است که در تمامی موارد بالا ضریب مانینگ مورد برآورد می‌شود. این مساله نیز عامل دیگری در تشویق نویسندگان این مقاله جهت برآورد میزان ضریب زبری در کانال‌های خاکی می‌باشد.

استفاده از ابزار محاسبه نرم تاکنون در برآورد پدیده‌های هیدرولیکی مختلفی مورد توجه بوده است. در برآورد میزان آب‌شستگی پای پل‌های در اثر جریان، باطنی و همکارانش [۱۹] و بگوم و همکارانش [۲۰] از ANNs به منظور برآورد میزان آب‌شستگی پای پل‌ها استفاده کردند. کاظمی‌نژاد و همکارانش [۲۱] از ANNs به منظور برآورد میزان آب‌شستگی زیر لوله‌ها تحت اثر امواج استفاده کردند. هم‌چنین در آب‌شستگی پای گروه شمع‌ها در اثر امواج در دریا نیز غضنفری [۲۲] هاشمی و همکارانش از ANNs و ماشین بردار پشتیبانی استفاده کردند. در زمینه برآورد سرعت در طول کانال‌های باز، زجی و بنکداری [۲۳] از ANNs و برنامه‌ریزی ژنتیک استفاده کردند. شیخ‌خوزانی و همکارانش [۲۴] نیز از ANNs تصادفی جهت برآورد و توزیع تنش برشی در کانال‌های دایره‌ای استفاده کردند و نتایج نشان از تاثیر زیاد عدد رینولدز و عمق بی‌بعد شده با پیرامون مرطوب روی تنش برشی دارد. از روش ANNs صادق صفری [۲۵] به‌منظور برآورد سرعت جریان در کانال‌های باز پرداختند. در تمامی موارد فوق دقت روش‌های شبکه عصبی در برآورد پارامترهای مورد نظر قابل توجه بوده که این مساله استفاده از این ابزار را برای موارد مشابه مانند برآورد ضریب زبری در کانال‌های خاکی توجیه می‌کند. در بحث استفاده از FIS یوهانسون و ایوب به منظور تعیین عدم قطعیت آب‌شستگی پای لوله‌ها از این روش استفاده کردند

خاکی پیشنهاد گردید:

$$\frac{k_s}{d_{50}} = 2 + 0.6\theta^{0.25} \quad w/U_f > 0.8-1 \quad (8)$$

$$\frac{k_s}{d_{50}} = 4.5 + 1.8 \exp(0.6w_*^4) \theta^{0.25} \quad w/U_f < 0.8-1 \quad (9)$$

که در آن f ، تابع بیان کننده رابطه بین پارامترهای موثر بر ضریب زبری بستر می باشد. در روابط بالا برآورد پارامتر نیکورادزه با تقسیم بر قطر متوسط ذرات رسوب به صورت بی بعد ارائه شده است. همان طور که در رابطه بالا مشخص است سومر و همکارانش [۱۰] دو رابطه برای حالات $w/U_f < 0.8-1$ و $w/U_f > 0.8-1$ ارائه کردند. آن ها نتیجه گرفتند که برای جریان هایی با شرط $w/U_f < 0.8-1$ ذرات رسوب به حالت معلق در می آیند، این در حالی است که برای جریان هایی با $w/U_f > 0.8-1$ ذرات رسوب همچنان به حالت ته نشین باقی می مانند. عدم ارائه مقدار دقیق برای عبارت w/U_f ممکن است به دلیل عدم قطعیت در مکانیزم تعیین جابجایی ذرات رسوب و چگونگی آرایش آن ها باشد. علت اینکه در مطالعه آن ها دو بازه برای w/U_f بین 0.8 تا 1 دارای هم پوشانی می باشد را می توان در شکل و اندازه متفاوت ذرات رسوبات جستجو کرد. این مساله نیز در کنار موارد یاد شده از عوامل تعیین کننده در انگیزه نویسندگان این مقاله در به کارگیری روش های ابزار محاسبه نرم مورد نظر جهت برآورد میزان ضریب زبری بستر کانال های خاکی می باشد. لازم به ذکر است که داده های آزمایشگاهی مورد نظر که برای ارائه رابطه سومر و همکارانش به کار گرفته شده است به عنوان داده های مورد استفاده در توسعه ابزار محاسبه نرم به کار گرفته می شوند.

روابط دیگری نیز تاکنون برای محاسبه ضریب زبری بستر k_s در کانال های خاکی ارائه شده است. از جمله آن ها می توان به روابط یالین اشاره کرد که به صورت زیر آورده شده است. [۹]:

$$\frac{k_s}{d_{50}} = 2 \quad \text{if } (\theta < 1) \quad (10)$$

$$\frac{k_s}{d_{50}} = 5\theta + (\theta - 4)^2 (0.043\theta^3 - 0.289\theta^2 - 0.203\theta + 0.125) \quad \text{if } (1 < \theta < 4) \quad (11)$$

جدول ۱. مشخصات آماری پارامترهای ورودی داده های آزمایشگاهی سومر و همکارانش [۱۰]

Table 1 . Statistical characteristics of data sets used for developing models to estimate roughness coefficient inerodible channels

مشخصه	k_s / d_{50}	w/U_f	w_*	θ	R_*	h/d_{50}
حداقل	۱/۴۳	۰/۱۷۴	۰/۲۶۲	۰/۳۸	۵۴۳۴	۲۵
حداکثر	۲۱/۷	۱/۷۰	۱/۳۳	۵/۶۷	۴۳۶۲۰۰	۸۰۸/۴۶
میانگین	۶/۷۲	۰/۷۳۴	۱/۰۰۷	۲/۰۴	۱۷۷۵۶۴	۱۶۴/۵۱

شده است. آزمایش های مذکور در تعداد ۱۵۸ بار بر روی ۴ نوع رسوب انجام گرفته است. جدول ۱ مشخصات آماری پارامترهای اندازه گیری شده توسط سومر و همکارانش را نمایش می دهد. هم چنین تمامی داده های انتخابی از کار آن ها به صورت پارامترهای بی بعد درآمده تا بدین وسیله بتوان رابطه ضمنی تعمیم پذیری جهت برآورد ضریب زبری بستر در کانال های خاکی توسط ابزار محاسبات نرم مذکور ارائه داد. همان طور که در جدول مورد نظر مشاهده می شود داده ها دامنه وسیعی از جریان های مختلف را با شرایط هیدرولیکی متنوعی شامل می شود. این مساله مبین این است که داده های ذکر شده نماینده مناسبی جهت ارائه یک مدل نسبتا تعمیم پذیر برای برآورد میزان ضریب زبری در کانال های باز خاکی می باشند. جدول پیوست نیز تعداد ۱۵۸ داده مورد استفاده در مقاله مورد نظر را نمایش می دهد. در جدول مورد نظر h/d_{50} نسبت عمق آب در کانال به قطر ذرات رسوب، R_* عدد رینولدز برشی که به صورت زیر محاسبه می شود:


$$R_* = \frac{\rho_f d_{50} U_f}{\mu_f} \quad (6)$$

U_f سرعت برشی جریان، h عمق آب در کانال، d_{50} اندازه میانگین قطر ذرات رسوب و μ_f لزجت دینامیکی آب بوده که معادل 10^{-6} kg/(s.m) می باشد.

بر اساس آزمایش های سومر و همکارانش [۱۰]، محاسبه ضریب زبری بستر به صورت رابطه زیر تبیین شد:

$$\frac{k_s}{d_{50}} = f\left(\theta, \frac{w}{U_f}, w_*\right) \quad (7)$$

و در نهایت رابطه زیر را برای محاسبه ضریب زبری بستر کانال های



شکل ۱. ساختار شبکه عصبی مصنوعی [۳۳]

Fig. 1. Structure of ANNs model

همه مهم تر میزان پیچیدگی رابطه بین پارامترهای ورودی و خروجی بستگی دارد. در این روش ابتدا باید با استفاده از تعدادی داده موسوم به داده های آموزش، شبکه را آموزش داد. به این صورت که به طور مثال یک جفت الگوی (I_x, T_x) که I_x پارامتر ورودی و T_x پارامتر خروجی مطلوب است. در شبکه عصبی الگوی T_x در نرون های هر لایه یک خروجی تولید می کند و در لایه خروجی تفاوت بین خروجی مطلوب و خروجی واقعی یک سیگنال خطا را به وجود می آورد. این سیگنال باعث تغییر وزن خطوط واصل بین نرون ها می شود. این تغییر وزن ها (آموزش شبکه) تا حد رسیدن به حد مطلوب کاربر ادامه خواهد داشت. شبکه عصبی و نحوه آموزش آن ها انواع مختلفی دارد. شبکه ای که در این مقاله استفاده شده است از نوع تغذیه رو به جلو و با الگوریتم آموزش پس انتشار است که از متداول ترین الگوریتم های آموزشی می باشد. تعداد نرون های لایه ورودی برابر با تعداد پارامترهای ورودی است و تعداد نرون های لایه خروجی نیز به تعداد پارامترهای خروجی مورد نظر می باشد.

تعداد لایه های پنهان به طور متداول یکی در نظر گرفته می شود ولی تعداد نرون های لایه پنهان با سعی و خطا به دست می آید. افرادی مانند هک- نیلسن [۳۴]، راجر و دوولا [۳۵] به ترتیب رابطه های زیر را برای تعیین تعداد نرون های لایه پنهان پیشنهاد کرده اند:

$$N_H \leq 2N_I + 1 \quad (12)$$

$$N_H \leq \frac{2N_{TR}}{N_I + 1} \quad (13)$$

با توجه به رابطه فوق مشاهده می گردد که با افزایش عدد شیلدز ضریب زبری کانال به پارامتر شیلدز وابسته می شود، در حالی که در اعداد شیلدز پایین ضریب زبری کانال تنها به اندازه متوسط ذرات وابسته می باشد. ویلسون [۸] تنها رابطه ۱۱ را جهت محاسبه ضریب زبری کافی دانست.

روابط تجربی ذکر شده در این مقاله با دو رویکرد، مورد استفاده قرار می گیرند. رویکرد اول مربوط به مقایسه مدل ابزار محاسبات نرم مبتنی بر شبکه های عصبی و سیستم استنباط فازی با این روش ها بوده و رویکرد دوم نیز مربوط به استفاده از این روش ها به منظور شناخت بیشتر اثر پارامترهای مختلف بر ضریب زبری بستر کانال های خاکی می باشد. به همین منظور، ۲ پارامتر موجود در روابط سومر و همکارانش به علاوه پارامترهای دیگر موثر بر روی k_s که از روش تحلیل ابعادی به دست آمده، به عنوان پارامترهای ورودی روش های ابزار محاسبه نرم مذکور در نظر گرفته می شوند. این پارامترها شامل عدد رینولدز برشی (R_*) و نسبت عمق آب در کانال مورد نظر به قطر ذرات رسوب (h/d_{s0}) می باشند. یکی از مباحث بسیار مهم در تعیین ضرایب زبری در کانال ها با استفاده از پارامترهای هیدرولیکی خاص وابستگی سرعت جریان به ضریب زبری است که فرایند چرخشی آزمون و تکرار را به سیستم برآورد تحمیل می کند. به منظور حل این مساله، در این مقاله سعی می شود با استفاده از پارامترهای فیزیکی بستر ضریب زبری محاسبه گردد.

۳- روش شبکه های عصبی مصنوعی (ANNs)

ANNs یکی از زیرشاخه های هوش مصنوعی بوده که به منظور پیش بینی یک پدیده و یا به عبارت دیگر برآورد رفتار حاکم بر آن ابداع شده است. همان طور که در شکل ۱ نمایش داده شده است یک شبکه عصبی از چندین لایه با نام های لایه ورودی، لایه(ها)ی پنهان و لایه خروجی تشکیل شده است و در هر لایه تعدادی نرون که عملی مشابه نرون های بیولوژیکی انجام می دهند، قرار دارند. این نرون ها به شکل های مختلف می توانند با هم ارتباط داشته باشند و هر خط واصل بین دو نرون دارای مقداری وزن است. در واقع شبکه های عصبی برگرفته شده از مقاله مکالوچ و پیترس [۳۳] بوده که از طریق ارتباطات داخلی بین نرون ها سعی در برآورد یک تابع می کند. ساختار شبکه عصبی به تعداد داده ها ورودی، تعداد پارامترهای ورودی و از

زیر مشخص می‌شود:

$$\begin{aligned} O_i^1 &= \mu_{A_i}(x), & i=1,2 \\ O_i^1 &= \mu_{B_{i-2}}(y), & i=3,4 \end{aligned} \quad (14)$$

که در این روابط x و y مقادیر ورودی به گره i ام و A_i و B_{i-2} عبارات زبانی فازی (مانند کوچک، بزرگ و دیگر موارد) می‌باشند. هر نوع تابع عضویتی می‌تواند به‌عنوان $\mu_{A_i}(x)$ و $\mu_{B_{i-2}}(y)$ استفاده شود، مانند تابع عضویت گوسی شکل که به‌صورت زیر نمایش داده می‌شود:

$$\mu_{A_i}(x) = \exp\left[-\left(\frac{x-c_i}{a_i}\right)^2\right] \quad (15)$$

که در آن a_i و c_i پارامترهای تابع عضویت گوسی بوده که با تغییر این پارامترها شکل توابع عضویت نیز تغییر می‌کند.

لایه دوم: گره‌های این لایه از نوع گره ثابت می‌باشند که با Π نشان داده شده‌است. تعداد گره‌ها در این لایه با تعداد قوانین اگر-آنگاه فازی برابر می‌باشند و ورودی به هر گره بیان‌کننده یک قاعده فازی می‌باشد. خروجی هر گره نیز حاصل ضرب جبری درجه عضویت توابع می‌باشد. در حقیقت خروجی این لایه، توان‌های آتش (ω_i) هر قاعده می‌باشد که به t -نرم لارسن معروف می‌باشد.


$$\omega_i = \mu_{A_i}(x) \wedge \mu_{B_i}(y), \quad i=1,2 \quad (16)$$

لایه سوم: گره‌های این لایه نیز از نوع گره‌های ثابت بوده که با N نمایش داده شده‌است. i امین گره این لایه، نسبت توان آتش i امین قاعده را به مجموع توان‌های آتش قواعد محاسبه می‌کند.

$$O_i^3 = \bar{w}_i = \frac{\omega_i}{\omega_1 + \omega_2}, \quad i=1,2 \quad (17)$$

خروجی‌های این لایه توان‌های آتش نرمال شده نامیده می‌شوند. لایه چهارم: هر گره i در این لایه، یک گره تطبیقی می‌باشد و با تابع زیر مشخص می‌شود:

$$\begin{aligned} O_i^4 &= \varpi_i z_i = \varpi_i (p_i x + q_i y + r_i) \\ i &= 1,2 \end{aligned} \quad (18)$$



شکل ۲. ساختار شماتیک سیستم استنباط فازی [۳۶].
Fig. 2. Structure of the ANFIS model

که در آن N_H تعداد نرون‌های لایه پنهان، N_I تعداد نرون‌های لایه ورودی و N_R تعداد داده‌های مورد استفاده برای آموزش شبکه است. البته تعیین بهتر این پارامترها می‌تواند با استفاده از فرآیند سعی و خطا و تاثیر آن‌ها بر نتایج آموزش انجام می‌شود.

۴- سیستم‌های استنباط فازی-عصبی تطبیقی (ANFIS)

۴-۱- ساختار FIS

سیستم‌های استنباط فازی رفتار یک پدیده را در قالب یک سری قواعد اگر-آنگاه فازی و با استفاده از دانش خبره و یا داده‌های مشاهداتی از آن پدیده پیش‌بینی می‌کند. به‌طور کلی اجزای سیستم‌های استنباط فازی را می‌توان به پنج بخش زیر تقسیم کرد:

- واحد فازی‌ساز برای تبدیل ورودی‌های قطعی به داده‌های فازی
- پایگاه قواعد که شامل یک سری قواعد اگر-آنگاه می‌باشد.
- پایگاه داده برای تعیین توابع عضویت و ساخت قواعد فازی
- واحد تصمیم‌گیری برای اعمال عملگرهای مختلف روی قواعد فازی
- واحد غیرفازی‌ساز برای تبدیل نتایج فازی به نتایج قطعی و غیرفازی

شکل ۲ اجزای یک سیستم استنباط فازی و نحوه تعامل بین آن‌ها را نشان می‌دهد که با توجه به موارد گفته شده پنج بخش سیستم استنباط فازی توضیح داده شده در بالا را می‌توان به پنج لایه نشان داده شده در شکل تقسیم‌بندی کرد.

لایه اول: هر گره i در این لایه، یک گره تطبیقی بوده و با تابع

پتانسیل هر نقطه داده به وسیله رابطه کاهشی زیر اصلاح می‌شود:

$$PV'_k = PV_k - PV_1^* \exp\left(-4\sqrt{\sum_{i=1}^D \left(\frac{x_k^i - x_{C1}^i}{r_{ai}}\right)^2}\right) \quad (21)$$

در رابطه بالا γ ضریب ثابت مثبت (ضریب کواش)، PV'_k به‌عنوان پتانسیل اصلاحی k امین مرکز خوشه و PV_k هم به‌عنوان پتانسیل k امین مرکز خوشه و x_{C1}^i ، مرکز خوشه انتخابی می‌باشند. γ ، ضریب کواش عددی ثابت بزرگتر از یک می‌باشد. فرآیند تعیین مرکز خوشه‌ها به پارامترهایی مانند آستانه پذیرش (ε)، آستانه رد ($\underline{\varepsilon}$) و شعاع همسایگی (r_{ai}) بستگی دارد. نقطه ای با پتانسیل بزرگتر از $\underline{\varepsilon}$ به‌طور مستقیم به‌عنوان مرکز خوشه در نظر گرفته شده و شرط پذیرش نقطه ای با پتانسیل PV_k ($\underline{\varepsilon} \leq \frac{PV_k}{PV_m^*} \leq \varepsilon$) منوط به حاکم شدن رابطه زیر می‌باشد.

$$d_{min} + \frac{PV_k^*}{PV_1^*} \geq 1 \quad (22)$$

که در این رابطه، d_{min} ، کمترین فاصله بین نقطه نامزد شده برای مرکز خوشه با مراکز خوشه قبلی می‌باشد. پس از اینکه پتانسیل هر نقطه داده اصلاح شد، مرکز خوشه بعدی انتخاب می‌شود. این فرآیند تا زمان تولید تعداد کافی مراکز خوشه تکرار می‌شود. معیار توقف برنامه زمانی است که پتانسیل کاهشی تمام نقاط به صفر برسد. پس از خوشه‌بندی کامل داده‌ها، هر یک از مراکز خوشه نشانگر الگویی می‌باشند که نمایانگر صفات خاصی از سیستم مورد نظر می‌باشند. در این مقاله از توابع گوسی دومتغیره به‌منظور تابع عضویت مورد نظر استفاده می‌شود. پارامتر اول آن مرکز خوشه‌ها و پارامتر دوم آن نیز بیان‌کننده انحراف‌معیار بوده که به‌صورت زیر می‌باشد:

$$a = r_a (X_{max} - X_{min}) / \sqrt{\lambda} \quad (23)$$

در رابطه بالا، X بردار داده‌ها است که شامل داده‌های ورودی و خروجی و همچنین عبارات min و max به‌ترتیب بیانگر کمترین و بیشترین مقدار آن‌ها می‌باشند. در این مقاله همان‌طور که گفته شد، این قوانین مبتنی بر روش خوشه‌بندی تفریقی و بر اساس داشتن کمترین شباهت به یکدیگر تعیین می‌شوند. نمونه ای از این قوانین برای برآورد ضریب زبری بستر به صورت

که در آن p_i ، q_i و r_i پارامترهای بخش نتیجه این لایه می‌باشند.

لایه پنجم: تنها گره این لایه، یک گره ثابت است که با \sum نشان داده شده و خروجی نهایی آن را به‌صورت جمع مقادیر ورودی مطابق رابطه زیر محاسبه می‌کند.

$$O_1^5 = \sum_i \overline{\omega_i} f_i = \frac{\sum_i \omega_i f_i}{\sum_i \omega_i}, \quad i = 1, 2 \quad (19)$$

۲-۴- استخراج قوانین اگر-آنگاه فازی در مدل ANFIS

روش‌های گوناگونی جهت استخراج قوانین اگر-آنگاه فازی استفاده می‌شود که به‌طور کلی این روش‌ها را می‌توان به روش‌های بر مبنای دانش خبره و روش‌های مبتنی بر روش‌های خوشه‌بندی تقسیم‌بندی کرد. در روش اول دسترسی به افراد با تجربه به ویژه با افزایش پیچیدگی پدیده‌ها امکان‌پذیر نیست. روش دوم می‌تواند گزینه‌ای مناسب برای استخراج قوانین اگر-آنگاه فازی در پدیده‌های پیچیده مانند برآورد زبری بستر کانال‌های خاکی باشد. یکی از روش‌های مرسوم خوشه‌بندی، روش خوشه‌بندی تفریقی ارائه‌شده توسط چپو [۳۷] می‌باشد. در این روش ابتدا پتانسیل هر داده جهت انتخاب به‌عنوان مرکز خوشه محاسبه شده و داده‌ای که دارای بیشترین پتانسیل باشد به‌عنوان مرکز خوشه در نظر گرفته می‌شود. پتانسیل هر داده به وسیله رابطه زیر محاسبه می‌شود:

$$PV_k = \sum_{j=1}^K \exp\left(-4\sqrt{\sum_{i=1}^D \left(\frac{x_k^i - x_j^i}{r_{ai}}\right)^2}\right) \quad (20)$$

که در آن PV_k ، پتانسیل k امین داده، n ، برابر تعداد پارامترهای ورودی و خروجی، x_k^i و x_j^i به ترتیب بردارهای داده‌ها ورودی و خروجی در j امین و k امین داده می‌باشند، r_{ai} عدد ثابت مثبت i امین داده به‌عنوان تعریف‌کننده محدوده همسایگی یک خوشه (شعاع خوشه بندی) و N ، تعداد کل داده‌ها می‌باشند. با توجه به رابطه بالا، داده‌ای که نقاط زیادی در مجاورت خود داشته باشد، دارای پتانسیل بیشتری بوده (PV_m^*) و به‌عنوان مرکز خوشه در نظر گرفته می‌شوند. در هر مرحله که مرکز خوشه‌ای به‌دست می‌آید

$$\alpha_m(k+1) = \alpha_m(k) - \eta \frac{\partial E_u}{\partial \alpha_m} \quad (25)$$

در رابطه بالا α_m ، مربوط به پارامترهای موثر در خطا (شامل پارامترهای غیرخطی توابع عضویت یا پارامترهای بخش فرض قوانین اگر-آن‌گاه فازی و پارامترهای بخش نتیجه) k ، گام آموزش و η ، ضریب یادگیری بوده که از رابطه زیر به دست می‌آید.

$$\eta = \frac{k}{\sqrt{\sum_{\alpha} \left(\frac{\partial E_u}{\partial \alpha_m} \right)^2}} \quad (26)$$

k ، در رابطه بالا گام یادگیری و E_u میزان خطا می‌باشد.

۵- مدل های ابزار محاسبه نرم برای برآورد ضریب زبری بستر کانال های خاکی

۵-۱- توسعه مدل های مورد نظر

پس از معرفی داده های مورد استفاده در توسعه روش های ابزار محاسبه نرم ANFIS، ANNs و توضیح درباره ویژگی های این ابزار، در این بخش به توسعه مدل های مربوطه به منظور برآورد میزان ضریب زبری بستر در کانال های خاکی با استفاده از جعبه های ابزار این روش ها در نرم افزار متلب پرداخته می شود. در توسعه مدل های ابزار محاسبه نرم معمولاً سه دسته داده مورد استفاده قرار می گیرند که به عنوان داده های آموزش، کنترل و آزمون معرفی می شوند. دو دسته اول به منظور توسعه مدل ها مورد استفاده قرار می گیرند که در آن باید خطای برآورد داده های آموزش و کنترل در برآورد پدیده مورد نظر در یک فرآیند آموزشی کمینه گردند. داده های آزمون نیز به منظور بررسی شرایط تعمیم پذیری مدل های توسعه داده شده مورد استفاده قرار می گیرند. در این مقاله هر یک از داده های مورد نظر، با توجه به تجارب گذشته (حدود ۸۰ درصد کل داده ها مربوط به داده های آموزش و کنترل بوده و حدود ۲۰ درصد آن نیز به عنوان داده های آزمون که به طور تصادفی انتخاب می شوند) برگزیده می شوند. بر همین اساس، ۴۰ داده از مجموع ۱۵۸ داده جمع آوری شده توسط سومر و همکارانش [۹] به عنوان داده آزمون و ۱۱۸ داده دیگر مجموعاً به عنوان داده های آموزش و کنترل در نظر

$$\left. \begin{array}{l} \text{Rule 1: IF } h/d_{50} \text{ is } A_1 \ \& \ R_* \text{ is } B_1 \ \& \ \theta \text{ is } C_1 \ \text{ THEN} \\ D_1 \\ k_s / d_{50} = p_1 + q_1(h / d_{50}) + r_1 R_* + s_1 \theta + t_1 (w / U_f) \\ \text{Rule 2: IF } h/d_{50} \text{ is } A_2 \ \& \ R_* \text{ is } B_2 \ \& \ \theta \text{ is } C_2 \ \text{ THEN} \\ D_2 \\ k_s / d_{50} = p_2 + q_2(h / d_{50}) + r_2 R_* + s_2 \theta + t_2 (w / U_f) \\ \text{Rule } i: \text{ IF } h/d_{50} \text{ is } A_i \ \& \ R_* \text{ is } B_i \ \& \ \theta \text{ is } C_i \ \text{ THEN} \\ D_i \\ k_s / d_{50} = p_i + q_i(h / d_{50}) + r_i R_* + s_i \theta + t_i (w / U_f) \end{array} \right\} \quad (24)$$

که در آن به ترتیب A_i, B_i, C_i, D_i ، مقادیر فازی مربوط به $h/d_{50}, R_*, \theta$ و w/U_f می باشند. همچنین p_i, q_i, r_i, s_i, t_i و به ترتیب پارامترهای بخش نتیجه قوانین اگر-آنگاه فازی متناسب با هر خروجی می باشند. لازم به ذکر است که تعداد قوانین اگر-آنگاه فازی با تعداد دسته داده ها حاصل شده از فرآیند خوشه بندی یکسان می باشد. همچنین در قوانین اگر-آنگاه فازی این مقاله هر متغیر زبانی مربوط به یک پارامتر ورودی با هم سطح خود قانون مورد نظر را تشکیل می دهد. به طور مثال همان گونه که در رابطه ۲۲ نمایش داده شده A_1 از h/d_{50} با B_1 از R_* و C_1 از θ با D_1 از w/U_f تأمین قانون اگر-آنگاه را تشکیل می دهد. این نوع از استخراج قوانین اگر-آنگاه فازی مبتنی بر نوار ابزار فازی در نرم افزار متلب می باشد.

۴-۳- تطبیق و تنظیم پارامترها در مدل ANFIS

در روش خوشه بندی داده ها الزاماً پارامترهای انتخاب شده برای توابع عضویت مورد نظر بهینه نمی باشند. به همین منظور، برای بهینه سازی پارامترهای توابع عضویت مجموعه های فازی و پارامترهای بخش نتیجه یک سیستم استنباط فازی، از شبکه های عصبی می توان استفاده نمود که به این نوع سیستم استنباط فازی، سیستم استنباط فازی-عصبی تطبیقی (ANFIS) گفته می شود. در مدل ANFIS پارامترهای شکل توابع عضویت (عبارت های زبانی) و پارامترهای بخش نتیجه توسط الگوریتم آموزش ترکیبی که شامل دو روش تندترین شیب و کمترین مربعات بوده تنظیم می شوند. در فرآیند آموزش پارامترهای توابع عضویت می بایست طوری تعیین شوند که خطا در سیستم در هر مرحله نسبت به مراحل قبل کاهش پیدا کند. رابطه زیر چگونگی تعیین پارامترها را در هر گام آموزشی نمایش می دهد.

بعد از شناخت پارامترهای بی بعد ورودی در این مرحله با توجه به داده های انتخاب شده مدل های ابزار محاسبه نرم مبتنی بر روش های ANNs و ANFIS توسعه داده می شوند. در روش ANNs مطابق با جدول ۲ تعداد لایه های پنهان ۲ عدد بوده و تعداد نرون های آن نیز به ۵ عدد تنظیم می شود. تابع فعال سازی آن ها تانسیک که به صورت عبارت ذیل می باشد.

$$y = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (29)$$

تابع فعال سازی نرون لایه خروجی نیز خطی خالص می باشد. به منظور توسعه مدل ANNs برای برآورد پارامتر k_s/d_5 ، همه ۴ پارامتر موثر بر پدیده مورد نظر به عنوان ورودی شبکه انتخاب شده و شبکه مورد نظر با تعداد گام محاسباتی ۱۰۰۰ آموزش داده شد که روند آموزش توسط شبکه عصبی در شکل ۳ نمایش داده شده است. هم چنین ریشه میانگین مربع خطاها (RMSE) حاصل شده در داده های آموزش و کنترل که به صورت زیر تعریف می گردد در جدول ۲ ارائه گردیده است:


$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (O^k - P^k)^2} \quad (30)$$

که در آن به ترتیب O^k مقدار مشاهداتی و P^k مقدار برآوردی داده k ام می باشند.

همان طور که در جدول ۲ و شکل ۳ نمایش داده شده است روند خطا در فرایند آموزش با شبکه عصبی به صورت کاهشی بوده که این مساله مبین کارایی روش شبکه عصبی (خطای داده های آموزش و کنترل به ترتیب ۰/۷۴۸ و ۰/۷۳۴) می باشد. هر چند ارزیابی نهایی این روش مربوط به کارگیری آن بر روی داده های آزمون می باشد. هم چنین مشاهده می گردد مدل مذکور در گام ۱۳ آموزش به جواب مطلوب می رسد که این مساله کارایی داده های کنترل را در فرایند آموزش به منظور جلوگیری از آموزش بیش از حد را نمایش می دهد. در توسعه مدل های سیستم استنباط فازی-عصبی تطبیقی (ANFIS) دو حالت در نظر گرفته می شود. حالت اول بدون نرمال سازی داده (مدل ANFIS) و با داده های اصلی می باشد. این در حالی است در حالت دوم به منظور تسهیل در فرایند آموزش مدل ANFIS و افزایش کارایی این مدل کل داده های آموزش، کنترل

جدول ۲. پارامترهای تعیین شده و خطای به دست آمده در توسعه مدل ANNs به منظور برآورد ضریب زبری بستر کانال
Table 2 . ANNs models parameters and errors obtained by ANNs

پارامتر	مقدار
بهترین گام جواب	۱۳
تعداد نرون های پنهان	۵
خطای داده های آموزش	۰/۷۴۸
خطای داده های کنترل	۰/۷۳۴



شکل ۳. فرایند آموزش در مدل ANNs به منظور برآورد ضریب زبری بستر کانالهای خاکی
Fig. 3 .The training process by ANN model to estimate roughness coefficient

گرفته می شوند.

در راستای هر چه تعمیم پذیرتر کردن مدل های ابزار محاسبه نرم از تحلیل ابعادی استفاده می شود که با توجه به پارامترهای موثر بر ضریب زبری کانال های خاکی به صورت ذیل بیان می شوند:

$$g(k_s, d_{50}, h, w, \rho_s, \rho_f, U_f, g, \mu_f) = 0 \quad (27)$$

و با استفاده از تئوری باکینگهام به صورت بی بعد ذیل تعریف می گردد:

$$\frac{k_s}{d_{50}} = f(h/d_{50}, R^*, \theta, w/U_f) \quad (28)$$

که در آن f تابع برآورد میزان ضریب زبری بستر توسط روش های ابزار محاسبه نرم به کار گرفته شده، می باشد.

جدول ۴. پارامترهای تعیین شده و نتایج حاصل شده در توسعه مدل FIS و ANFIS با داده های نرمال شده (مدل ANFIS)

Table 4 . ANFIS models parameters and errors obtained by the ANFIS model developed by normalized data (ANFIS model)

ANFIS	FIS	پارامتر
۰/۴۸۲	۰/۷۲۸	خطای داده‌های آموزش
۰/۹۴۲	۰/۸۸۲	خطای داده‌های کنترل
	۷	تعداد قوانین اگر-آنگاه فازی
	۳۴	شماره گام جواب مطلوب

و آزمون با استفاده از رابطه زیر و بر اساس مقادیر حداکثر و حداقل پارامترها در جدول ۱ در بازه ای بین ۰ و ۱ نرمال می شوند:

$$X_n = \frac{X_r - X_{min}}{X_{max} - X_{min}} \quad (31)$$

که در آن X_n و X_r به ترتیب مقدار نرمال و واقعی پارامتر مورد نظر، X_{min} حداقل مقدار پارامتر در بین کل داده های و X_{max} نیز حداکثر مقدار پارامتر در بین کل داده ها می باشند. بعد از آماده سازی داده ها در این مرحله اقدام به توسعه مدل های ANFIS در دو حالت بدون نرمال سازی داده‌ها (داده های اصلی) و با نرمال سازی جهت برآورد ضریب زبری بستر کانال های خاکی می شود. به این منظور، پارامترهای خوشه بندی در هر یک از مدل ها به صورت زیر انتخاب می شوند.


- در حالت با داده های اصلی (مدل ANFISR)

$$\left[R_{h/d50}, R_{R*}, R_{\theta}, R_{w/Uf}, R_{k_s/d50}, \gamma_{k_s/d50} \right] = [0.65, 0.5, 0.7, 0.7, 0.7, 2]$$

- در حالت با داده های نرمال شده (مدل ANFIS)


$$\left[R_{h/d50}, R_{R*}, R_{\theta}, R_{w/Uf}, R_{k_s/d50}, \gamma_{k_s/d50} \right] = [0.55, 0.69, 0.65, 0.8, 0.7, 2]$$

انتخاب پارامترهای خوشه بندی مذکور بر اساس کمینه خطای داده های آموزش و کنترل و فرآیندی همراه با سعی و خطا می باشد. پس از اجرای مدل های ابزار محاسبه نرم مذکور، روند آموزش در شکل های ۴ و ۵ به ترتیب برای هر یک از مدل های توسعه داده شده با استفاده از داده های اصلی و نرمال شده نمایش داده شده



شکل ۴. فرآیند آموزش در مدل ANFIS در حالت با داده های اصلی (بدون نرمال سازی) به منظور برآورد ضریب زبری بستر کانال های خاکی (مدل ANFISR)

Fig. 4 .The training process by the ANFIS model using real data (ANFISR model) to estimate roughness coefficient




شکل ۵. فرآیند آموزش در مدل ANFIS در حالت با داده های نرمال شده به منظور برآورد ضریب زبری بستر کانال های خاکی (مدل ANFIS)

جدول ۳. پارامترهای تعیین شده و نتایج حاصل شده در توسعه مدل FIS و ANFIS با داده های اصلی (مدل ANFISR)

Table 3 . ANFIS models parameters and errors obtained by the ANFIS model developed by real data (ANFISR model)

ANFIS	FIS	پارامتر
۱/۷۳۲	۰/۶۴۵	خطای داده‌های آموزش
۳/۷۰۶	۰/۶۸۳	خطای داده‌های کنترل
	۶	تعداد قوانین اگر-آنگاه فازی
	۶۱	بهترین گام جواب



شکل ۶. آنالیز حساسیت خطا در برابر حذف هر یک از پارامترهای ورودی در هریک از مدل‌های ابزار محاسبه نرم

Fig. 6. The sensitivity analysis of the models versus the elimination of any input variables

۵-۲- آنالیز حساسیت ضریب زبری کانال‌های خاکی در برابر

پارامترهای مختلف

پس از توسعه روش‌های مورد نظر در این مرحله از دو دیدگاه توسعه مدل با داده‌های اصلی (مدل ANFISR) و داده‌های نرمال (مدل ANFISN) کارایی روش‌های مورد نظر بر پایه شناخت تاثیر هر یک از پارامترهای ورودی بر خطای داده‌های آموزش و کنترل بررسی می‌شود. بر اساس این دیدگاه میزان تاثیر هر یک از پارامترها بر روی میزان زبری بستر کانال مشخص می‌گردد. آنالیز حساسیت پارامترهای ورودی مدل‌های ابزار محاسبه نرم را می‌توان در تاثیر روی خطای داده‌های آموزش و کنترل بررسی کرد. بدین منظور تغییرات خطای دو مدل توسعه داده شده ANNs و ANFIS در مقابل حذف هر یک از پارامترهای ورودی بررسی می‌شود که به ترتیب شکل ۶ این روند را در این مدل‌ها نمایش می‌دهند.

با توجه به شکل مشاهده می‌گردد که با حذف عدد رینولدز برشی (R_e) خطای شبکه مقدار زیادی افزایش می‌یابد. این درحالی است که حذف پارامتر h/d_{50} خطای شبکه مقدار کمی تغییر می‌کند. حذف پارامترهای θ و w/U_f نیز به ترتیب باعث افزایش خطا می‌شود. با توجه به نتایج این بخش می‌توان گفت تاثیرگذارترین عامل بر روی شبکه با داده‌های حالت اول، عدد رینولدز برشی می‌باشد. این درحالی است که در فرمول‌هایی که تاکنون برای محاسبه ضریب زبری بستر ارائه شده پارامتر عدد مورد نظر مشاهده نمی‌شود. با توجه به شکل ۶ همچنین مشخص می‌کند که در مدل ANFIS توسعه داده شده با داده‌های واقعی (مدل ANFISR) با حذف عدد رینولدز برشی خطای شبکه مقدار زیادی افزایش

است. با توجه به شکل‌های مورد نظر نتیجه گرفته می‌شود که مدل دوم دارای کارایی بیشتری در حین فرآیند آموزش با شبکه عصبی می‌باشد. همچنین میزان خطای داده‌های آموزش و کنترل نیز در جدول‌های ۳ و ۴ برای هر یک از حالات دوگانه نمایش داده شده است. علت افزایش خطا در مدل را می‌توان در یک سطح نبودن مقدار دامنه داده‌های ورودی (مشکل یکسان نبودن ابعاد) جستجو کرد که با نرمال‌سازی داده‌ها در مدل دوم بر طرف گردید. همچنین مشاهده می‌شود تعداد قوانین اگر-آنگاه فازی در حالت اول و دوم با هم متفاوت بوده که علت این مساله را می‌توان در تغییر ساختار داده‌ها با نرمال‌سازی آن‌ها جستجو کرد.

با مقایسه دو جدول مشخص می‌گردد که مدل ابتدایی (FIS) در حالت با داده‌های اصلی دارای خطای کمتری در داده‌های آموزش (۰/۶۴۵) و کنترل (۰/۶۸۳) می‌باشد. این در حالی است که در مدل ANFIS در حالت دوم (با نرمال‌سازی داده‌ها) خطای داده‌های آموزش (۰/۴۸۲) کمتر می‌باشد و خطای داده‌های کنترل (۰/۹۴۲) در این مدل بیشتر از حالت اول می‌باشد. این مساله نشان دهنده آن است که تبدیل داده‌ها به داده‌های حالت نرمال هر چند که منجر به از بین رفتن مشکل یکسان نبودن ابعاد در بین پارامترها ورودی می‌شود اما ممکن است ارتباط بین پارامترهای مختلف و یا به عبارت دیگر فیزیک مساله را دست‌خوش تغییر قرار دهد. با آنالیز حساسیت مدل‌های توسعه داده شده در گام بعدی می‌توان صحت این مساله را بررسی کرد.

به منظور ارزیابی دقیق‌تر روش‌های ابزار محاسبه نرم توضیح داده شد در بالا این روش‌ها با روش‌های رگرسیونی خطی و غیرخطی مقایسه می‌شود. پس از تعیین ضرایب آن‌ها به روش حداقل مربعات در نرم‌افزار متلب این روش‌ها به ترتیب به صورت زیر به دست می‌آیند:

- رگرسیون خطی

$$k_s / d_{50} = 2.7352 - 3.854 \times 10^{-4} (h / d_{50}) + 2.1499 \times 10^{-5} R_e - 2.2524 \theta - 5.7746 (w / U_f)$$

- رگرسیون غیرخطی

$$k_s / d_{50} = 0.0189 (h / d_{50})^{0.0348} (R_e)^{0.4436} (\theta)^{0.2601} (w / U_f)^{0.8361}$$

(مدل ANFIS) مشخص می کند که روند مورد نظر نسبت به دو حالت اول (ANNs و ANFIS با داده های اصلی) متفاوت می باشد. در این مدل پارامتر h/d_{50} از همه موثرتر می باشد. بنابراین این گونه می توان استنباط کرد که نرمال سازی داده ها بر روی ارتباط بین پارامترهای موثر بر ضریب زبری کانال تاثیرگذار باشد. لازم به ذکر است که منظور از عبارت no در این نمودار یعنی میزان خطا بدون حذف هر یک از پارامترهای موثر بر میزان ضریب زبری می باشد. جدول ۵ اولویت بندی پارامتر تاثیرگذار بر ضریب زبری را نمایش می دهد.

جدول ۵. اولویت بندی پارامترهای موثر بر ضریب زبری در کانال های خاکی
Table 5 . Ranking of effective parameters on roughness coefficient in erodible channels

پارامتر	اولویت
R_s	۱
θ	۲
h/d_{50}	۳
w/U_f	۴

۳-۵- ارزیابی مدل های ابزار محاسبه نرم و مقایسه آن با روابط تجربی و روش های رگرسیون خطی و غیر خطی

با توجه به اینکه توانمندی مدل های ابزار محاسبات نرم به ارزیابی کارایی آن ها در مقابل داده هایی که در فرآیند آموزش استفاده نشده، بستگی دارد، لذا در این قسمت به ارزیابی مدل های مورد نظر توسعه داده شده در مقابل داده هایی که در فرآیند آموزش استفاده نشده اند، پرداخته می شود. در همین راستا، از سه شاخص میانگین انحراف ($Bias$)، میانگین مربع خطا ($RMSE$) و ضریب هم بستگی (R^2) جهت ارزیابی کارایی این مدل ها استفاده می شود که فرمول آن ها به صورت زیر می باشد:

$$Bias = \frac{1}{N} \sum_{k=1}^N (O^k - P^k) \quad (32)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (O^k - P^k)^2} \quad (33)$$

$$R^2 = 1 - \frac{\sum_{k=1}^N (P^i - O^i)^2}{\sum_{k=1}^N (P^i - \bar{O})^2} \quad (34)$$

که در آن $Bias$ ، شاخص انحراف که نشان دهنده دست پایین و یا دست بالا بودن برآورد توسط مدل توسعه داده شده می باشد، R^2 نیز ضریب همبستگی که وابستگی مقادیر برآوردی را به مقادیر پیش بینی نشان می دهد، $RMSE$ خطای داده های آزمون، \bar{T} میانگین مشاهداتی پارامتر پیش بینی شده می باشد. به منظور نشان دادن کارایی مدل های مبتنی بر روش های

جدول ۶. خطای مدل های مختلف ابزار محاسبه نرم جهت برآورد میزان ضریب زبری بستر کانال های خاکی

Table 6 . Soft computing-based models errors to estimate roughness coefficient

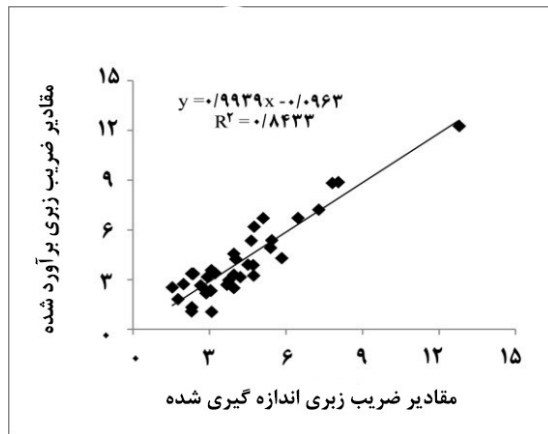
ANNs	ANFIS	FIS	معیار
۰/۱۲۱	۰/۱۴۱	۰/۱۱۱	$Bias$
۱/۰۲۱	۱/۱۱۱	۰/۹۴۱	$RMSE$
۰/۸۵۱۹	۰/۸۴۳۳	۰/۸۶۵۸	R^2

جدول ۷. خطای روش های مختلف جهت برآورد میزان ضریب زبری بستر کانال های خاکی


Table 7 . Multi-linear and multi-nonlinear regression models and empirical methods errors to estimate roughness coefficient

ویلسون (۱۹۸۹)	سومر و همکارانش (۱۹۹۶)	یالین (۱۹۹۲)	MNLR	MLR	معیار
۲/۹۵	۳/۳۵۰	-۰/۵۴۹	-۰/۵۲۳	۱/۳۲۱	$Bias$
۳/۴۶	۱/۷۵۰	۱/۵۳۱	۱/۸۹۸	۲/۳۳۰	$RMSE$
۰/۵۳۵۴	۰/۴۸۶۳	۰/۶۲۸۶	۰/۴۶۶۲	۰/۵۲۲۶	R^2


می یابد. این در حالی است که با حذف پارامتر h/d_{50} در این مدل نیز خطای شبکه افزایش پیدا می کند. حذف پارامترهای θ و w/U_f نیز به ترتیب باعث افزایش خطا می شود. با توجه به نتایج این بخش نیز می توان گفت تاثیرگذارترین عوامل بر روی خطای مدل ANFIS به ترتیب عدد رینولدز برشی می باشد. توجه به شکل ۶ که با استفاده از داده های نرمال شده مدل ANFIS توسعه داده شده



(ب)



(الف)




(ج)


شکل ۷. مقادیر زبری اندازه گیری شده در برابر مقادیر برآوردی توسط روش ANNs
Fig. 7. Measured roughness coefficients values versus estimated ones by ANNs model

پارامتر ارزیابی می باشد. همچنین بررسی مقادیر برآوردی ضریب زبری توسط روش های تجربی نیز از دقت کمتر این روش ها در برآورد پارامتر زبری حاکی است. علت این مساله را در مورد روش ویلسون و یالین در متفاوت بودن شرایط هیدرولیکی و در روش سومر و همکارانش در عدم قطعیت بازه استفاده از روابط ارائه شده در برآورد می توان جستجو کرد که در این مقاله مقدار $w/U_f = 0.9$ برای تفکیک دو حالت هیدرولیکی محتمل در نظر گرفته شد. هر چند در بین روش های تجربی رابطه یالین دارای دقت بالاتری است. همان طور که جدول ۷ نمایش داده شده است. روش های رگرسیون خطی و غیرخطی نیز دارای دقت کمتری نسبت به روش های ابزار محاسبه نرم می باشند.


ابزار محاسبه نرم این روش ها با فرمول های تجربی موجود و روش های رگرسیونی نیز مورد مقایسه قرار می گیرد. پس از ارزیابی مدل های مذکور نتایج در جدول های ۶ و ۷ و شکل های ۷ تا ۹ نمایش داده شده است. بر اساس این جداول مدل FIS بهترین کارایی را در بین مدل های توسعه داده شده جهت برآورد ضریب زبری بستر نشان می دهد. این درحالی است که مدل ANFIS دارای دقت کمتری نسبت به مدل FIS در هر سه پارامتر ارزیابی می باشد. علت این مساله را می توان در اجتناب ناپذیر بودن استفاده از داده های نرمال شده در مدل ANFIS جستجو کرد. روش ANNs نیز نسبت به روش ANFIS دارای جواب بهتری بوده در حالی که نسبت به روش FIS دارای خطای بیشتری در هر سه



(ب) روش یالین (1992)





(الف) روش ویلسون (1989)



(ج) سومر و همکارانش (1996)

شکل ۸. مقادیر زبری اندازه گیری شده در برابر مقادیر برآوردی توسط روشهای مبتنی بر سیستمهای استنباط فازی
 Fig. 8. Measured roughness coefficients values versus estimated ones by the FIS-based models



شکل ۹. مقادیر زبری اندازه گیری شده در برابر مقادیر برآوردی با استفاده از روشهای تجربی و روشهای رگرسیونی خطی و غیرخطی
 Fig. 9. Measured roughness coefficients values versus estimated ones by multi linear regression and nonlinear regression models and empirical methods

۶- نتیجه گیری

Data Mining	داده کاوی
Support Vector Machines (SVMs)	ماشین بردار پشتیبانی
Back Propagation	پس انتشار
Feed Forward	تغذیه رو به جلو
MATLAB	متلب
Nikuradze	نیکورادزه
Non-cohesive	غیر چسبنده
Sheet flow	جریان لایه‌ای
Saltation	پرش
TANSIG	تانسیگ
Epoch	گام محاسباتی
Over-training	آموزش بیش از حد
Saltation	پرش

برآورد میزان ضریب زبری بستر کانال‌ها در شرایط هیدرولیکی مختلف از اهمیت زیادی در طراحی و حتی مدل‌سازی‌های عددی برخوردار می‌باشد. این مقاله به منظور ارائه مدلی بهتر برای محاسبه‌ی زبری بستر کانال‌ها با استفاده از ابزار محاسبات نرم مبتنی بر شبکه‌های عصبی مصنوعی (ANNs) و سیستم‌های استنباط فازی (ANFIS) انجام گرفت. نتایج نشان از کارایی روش‌های مربوطه جهت برآورد پارامتر زبری بستر می‌باشد. علاوه بر آن، با بررسی پارامترهای موثر در میزان زبری بستر مشخص شد که عدد رینولدز برشی نیز پارامتر مهمی در برآورد زبری بستر کانال می‌باشند. اگرچه در هیچ یک از فرمول‌هایی که پیش از این برای محاسبه زبری بستر ارائه شده این پارامتر ذکر نشده‌است. همچنین نتایج نشان از دقت بیشتر روش سیستم استنباط فازی در تعیین ضریب زبری بستر نسبت به روش ANNs و روابط تجربی موجود می‌باشد. از آنجایی که روش‌های شبکه عصبی و سیستم استنباط فازی روش‌هایی نیستند که فرمول مشخصی برای برآورد ضریب زبری بستر کانال ارائه دهند استفاده از روش برنامه ریزی ژنتیک جهت ادامه کار قابل توصیه می‌باشد. علاوه بر آن با توجه به نرمال‌سازی داده‌ها در توسعه مدل‌ها ممکن است رفتار داده‌ها جهت نمایندگی پدیده مورد نظر دچار تغییر شود. بنابراین استفاده از مدل ترکیبی سیستم استنباط فازی با روش ابزار محاسبه نرم مانند الگوریتم ژنتیک قابل توصیه می‌باشد.

مراجع

- [1]. Ferguson, R., (2010). Time to abandon the Manning equation? *Earth Surf. Process. Landf.* 35.
- [2]. SUMER, B. MUTLU (2013). "LECT URE NOTES ON TURBULENCE.", Technical University of Denmark.
- [3]. Powell, D. M. (2014). Flow resistance in gravel-bed rivers: Progress in research. *Earth-Science Reviews*, 136, 301-338.
- [4]. Simons, D. B., & Richardson, E. V. (1996). Resistance to flow in alluvial channels. US Government Printing Office.
- [5]. Ackers, P. & White, W. R. (1973). «Sediment transport: new approach and analysis». *Journal of the Hydraulics Division*, 99 (hy11).
- [6]. Hammond, F. D., Heathershaw, A. D., and Langhorne, D. N. (1984). "A comparison between Shields' threshold criterion and the Henderson movement of loosely packed gravel in a tidal channel." *Sedimentology*, 31, 51-62.
- [7]. Colosimo, C., Copertino, V. A., & Veltri, M. (1986). «Average velocity estimation in gravel-bed rivers». In Proc., 5th IAHR-APD Congress (pp. 1-15).
- [8]. Wilson, K. C. (1989). Mobile-bed friction at high shear stress. *Journal of Hydraulic Engineering*, 115(6), 825-830.
- [9]. Yalin, M. S. "River Mechanics, 219 pp." (1992).

پانویس

ANFIS	سیستم استنباط فازی -عصبی تطبیقی
ANNs	شبکه‌های عصبی مصنوعی
FISs	سیستم‌های استنباط فازی
RMSE	ریشه میانگین مربع خطا
R^2	ضریب هم‌بستگی
Bias	میانگین انحراف
Artificial Neural Networks	شبکه‌های عصبی مصنوعی
Fuzzy Inference Systems	سیستم‌های استنباط فازی
Genetic Programing (GP)	برنامه ریزی ژنتیک
Denmark University of Technology	دانشگاه صنعتی دانمارک

- local scour depth around semicircular bridge abutments». 6th SASTech, Malaysia, Kuala Lumpur.
- [21]. Kazeminezhad, M. H., Etemad-Shahidi, A., & Bakhtiary, A. Y. (2010). «An alternative approach for investigation of the wave-induced scour around pipelines». *Journal of Hydroinformatics*, 12(1), 51-65.
- [22]. Ghazanfari-Hashemi, S., Etemad-Shahidi, A., Kazeminezhad, M. H., & Mansoori, A. R. (2011). «Prediction of pile group scour in waves using support vector machines and ANN». *Journal of Hydroinformatics*, 13(4), 609-620.
- [23]. Zaji, A. H., & Bonakdari, H. (2015). Application of artificial neural network and genetic programming models for estimating the longitudinal velocity field in open channel junctions. *Flow Measurement and Instrumentation*, 41, 81-89.
- [24]. Sheikh Khozani, Z., Hossein Bonakdari, H., Zaji, A.H. (2017). Estimating the shear stress distribution in circular channels based on the randomized neural network technique. *Applied Soft Computing*, 58, 441-448.
- [25]. Sadegh Safari M., Aksoy, H., & Mohammadi, M. (2016). Artificial neural network and regression models for flow velocity at sediment incipient deposition. *Journal of Hydrology*, 541, 1420-1429.
- [26]. Johnson, P. A. & Ayyub, B. M. (1996) «Modeling uncertainty in prediction of pier scour». *Journal of Hydraulic*.
- [27]. Muzzammil, M. (2000). «ANFIS approach to the scour depth prediction at a bridge abutment». *Journal of Hydroinformatics* 12 (4):474-485.
- [28]. Muzzammil, M., and J. Alam. (2011). «ANFIS-based approach to scour depth prediction at abutments in armored beds». *Journal of Hydroinformatics* 13 (4):699-713.
- [29]. Zanganeh, M., Yeganeh-Bakhtiary, A., & Bakhtyar, R. (2011). Combined particle swarm optimization and fuzzy inference system model for estimation of current-induced scour beneath marine pipelines. *Journal of Hydroinformatics*, 13(3), 558-573.
- [30]. Bateni, S. M., & Jeng, D. S. (2007). Estimation of pile group scour using adaptive neuro-fuzzy
- [10]. Sumer, B. M., Kozakiewicz, A., Fredsøe, J., & Deigaard, R. (1996). «Velocity and concentration profiles in sheet-flow layer of movable bed». *Journal of Hydraulic Engineering*, 122(10), 549-558.
- [11]. KIM J.S, LEE J., KIM W. , Yong J. K. (2010) Roughness coefficient and its uncertainty in gravel-bed river, *Water Science and Engineering*
- [12]. Yang, H. C., & Chang, F. J. (2005). «Modeling combined open channel flow by artificial neural networks». *Hydrological Processes*, 19 (18), 3747-3762.
- [13]. Yuhong, Z., & Wenxin, H. (2009). «Application of artificial neural network to predict the friction factor of open channel flow». *Communications in Nonlinear Science and Numerical Simulation*, 14(5), 2373-2378.
- [14]. Shayya, W. H., & Sablani, S. S. (1998). «An artificial neural network for non-iterative calculation of the friction factor in pipeline flow». *Computers and electronics in agriculture*, 21(3), 219-228.
- [15]. Abdeen, M. A. M. (2004). «Artificial neural network model for predicting the impact changing water structures' locations on the hydraulic performance of branched open channel system». *Mechanics and Mechanical Engineering*, 7(2), 179-192.
- [16]. Zahiri, A., & Dehghani, A. A. (2009). «Flow discharge determination in straight compound channels using ANN». *World Academy of Science, Engineering and Technology*, 58, 12-15.
- [17] Azamathulla H. Md., (2012), « Gene-expression programming to predict friction factor for Southern Italian rivers, *Journal of Neural Computing and Applications*, 23 (8), 1421-142
- [18]. Arpan P. & Kishanjit K. K., (2018) Gene expression programming to predict Manning's n in meandering flows, *Canadian Journal of Civil Engineering*, Vol. 45, No. 4 : pp. 304-313
- [19]. Bateni, S. M., Borghei, S. M., & Jeng, D. S. (2007). «Neural network and neuro-fuzzy assessments for scour depth around bridge piers». *Engineering Applications of Artificial Intelligence*, 20(3), 401-414.
- [20]. Begum, S. A., Fujail, A. M., & Barbhuiya, A. K. (2012). «Artificial neural network to predict equilibrium

networks with parallel solute transport modeling». Water Resources Research. 30 (2), 457–481.

[35]. Hecht-Nielsen, R. (1978). «Kolmogorov's mapping neural network existence theorem». In Proceedings of the international conference on Neural Networks (Vol. 3, pp. 11-13). New York: IEEE Press.

[36]. Jang JSR. (1993) «ANFIS Adaptive-Network-Based Fuzzy Inference systems». IEEE Trans System Man Cybern; 23(3): 665-685.

[37]. Chiu S.L (1994). «Fuzzy model identification based on cluster estimation. Intelligent Fuzzy Systems»; 2: 234-244. Engineering 122(2), 66–72.

approach. Ocean Engineering, 34(8), 1344-1354.

[31]. Ozger, M. (2009) «Comparison of fuzzy inference systems for stream flow prediction». Hydrological Sciences Journal 54(2), 261–273.

[32]. Azmathullah, H. Md., Ghani, A. A. & Zakaria, N. A. (2009) «ANFIS-based approach to predicting scour location of spillway». Water management.

[33]. McCulloch, W. S., & Pitts, W. (1943). «A logical calculus of the ideas immanent in nervous activity». The bulletin of mathematical biophysics, 5(4), 115-133.

[34]. Rogers, L.L. & Dowla, F.U. (1994) «Optimization of groundwater remediation using artificial neural

جدول ۱ پیوست: داده‌های مورد استفاده در توسعه مدل‌ها جهت برآورد ضریب زبری در کانال‌های خاکی

no	h/d_{50}	R_*	θ	w/U_f	k_s/d_{50}
46	33.46154	286780	3.41	0.661831	14.36
47	34.88462	296920	3.65	0.639229	17.76
48	34.61538	297440	3.66	0.638112	16.06
49	34.80769	290160	3.49	0.654122	15.07
50	34.23077	302900	3.8	0.626609	14.97
51	35.34615	302900	3.8	0.626609	17.17
52	35.65385	320580	4.26	0.592052	20.58
53	35.80769	309660	3.97	0.61293	18.49
54	35.5	311220	4.01	0.609858	17.04
55	39.23077	192400	1.55	0.986486	2.76
56	35.61538	328120	4.46	0.578447	20.36
57	39.61538	200200	1.64	0.948052	3.12
58	36.26923	333580	4.61	0.568979	21.07
59	40	213200	1.88	0.890244	4
60	41.15385	213200	1.89	0.890244	3.76
61	40.38462	228800	2.18	0.829545	5.1
62	41.15385	240500	2.4	0.789189	5.4
63	42.30769	247000	2.54	0.768421	6
64	190	12840	0.6	0.34188	4.73
65	188.3333	16140	0.95	0.322061	6.98
66	186	16740	1.02	0.333333	6.03
67	190.8333	15960	0.93	0.3367	4.35
68	185.8333	17460	1.1	0.337268	5.3
69	188.3333	17340	1.09	0.337838	4.31
70	187.5	19500	1.38	0.326797	6.01
71	190	18240	1.21	0.33557	4.13
72	188	20880	1.58	0.326264	5.65
73	191.6667	20820	1.58	0.322061	5.05
74	198	22260	1.8	0.29985	7.59
75	180.8333	24240	2.13	0.330033	5.88
76	189.1667	23220	1.95	0.323625	5.37
77	191.6667	23340	1.97	0.31746	5.29
78	193.3333	25440	2.35	0.312012	5.87
79	192.5	24900	2.25	0.319489	4.56
80	198.1667	24960	2.26	0.31746	4.3
81	195.1667	27300	2.71	0.304414	6.52
82	196.6667	27420	2.73	0.304414	5.68
83	204.6667	28680	2.98	0.28169	8.65
84	201.6667	29640	3.19	0.288184	7.9
85	201	30780	3.44	0.282885	9.38
86	200	29520	3.16	0.294551	6.41
87	201.8333	30900	3.46	0.286944	7.84
88	205	31680	3.64	0.284495	7.18
89	207.1667	32940	3.94	0.277008	8.57

no	h/d_{50}	R_*	θ	w/U_f	k_s/d_{50}
1	28.36667	366900	1.88	0.973017	7.47
2	28.83333	375000	1.97	0.952	8.65
3	28.07692	187200	1.43	1.013889	1.43
4	188.3333	10260	0.38	1.169591	1.72
5	33.83333	436200	2.66	0.818432	14.29
6	30	327900	1.5	1.088747	3.72
7	188.3333	11160	0.45	1.075269	3.35
8	808.4615	8918	2.24	0.174927	4.27
9	25	144300	0.86	1.315315	2.48
10	224.5	39540	5.67	0.237812	17.42
11	33.33333	210000	0.67	1.7	2.46
12	797.6923	5434	0.83	0.287081	3.42
13	31.7	386100	2.08	0.924631	10.59
14	29.83333	298800	1.25	1.194779	3.09
15	30.16667	393600	2.16	0.907012	8.84
16	30.56667	385500	2.08	0.92607	8.5
17	30.83333	401700	2.26	0.888723	10.11
18	31.33333	400200	2.24	0.892054	10.42
19	32.06667	411300	2.36	0.86798	12.15
20	32.13333	419100	2.46	0.851825	12.63
21	32.63333	404100	2.28	0.883445	11.31
22	32.53333	404400	2.29	0.882789	10.22
23	33.6	424200	2.52	0.841584	13.17
24	26.53846	195780	1.59	0.969456	5.07
25	26.26923	196300	1.6	0.966887	4.17
26	26.46154	202540	1.7	0.937099	4.27
27	26.92308	208780	1.81	0.909091	4.67
28	28.84615	197600	1.62	0.960526	3.25
29	28.26923	226200	2.12	0.83908	6.81
30	27.69231	221520	2.03	0.856808	5.32
31	28.69231	233220	2.25	0.813824	7.29
32	28.46154	236860	2.32	0.801317	7.06
33	29	237380	2.34	0.799562	7.86
34	29.61538	244920	2.49	0.774947	9.29
35	29.80769	250120	2.59	0.758836	10.1
36	29.46154	249080	2.57	0.762004	9.13
37	29.23077	218400	1.98	0.869048	4.97
38	30.38462	255320	2.7	0.743381	10.87
39	30.15385	249340	2.58	0.76121	9.46
40	30.30769	258960	2.78	0.732932	10.62
41	30.19231	258440	2.77	0.734406	10.04
42	31.15385	264940	2.91	0.716389	11.84
43	31.53846	263900	2.88	0.719212	11.18
44	32.30769	269360	3	0.704633	11.79
45	32.5	276640	3.17	0.68609	12.17

no	h/d_{50}	R_*	θ	w/U_f	k_s/d_{50}
134	33.33333	264000	1.06	1.352273	2.3
135	32.56667	418200	2.45	0.853659	12.79
136	25	169780	1.19	1.117917	3.96
137	25	174200	1.26	1.089552	3.69
138	25.23077	179920	1.34	1.054913	3.76
139	27.69231	182000	1.38	1.042857	4.21
140	25.57692	185640	1.43	1.022409	3.96
141	26.92308	161200	1.07	1.177419	2.81
142	27.03846	213980	1.9	0.886999	4.64
143	28.23077	228280	2.16	0.831435	6.47
144	28.69231	233220	2.25	0.813824	7.29
145	28.84615	218400	1.96	0.869048	5.44
146	38.46154	166400	1.14	1.140625	2.36
147	38.84615	176800	1.3	1.073529	2.35
148	38.84615	182000	1.38	1.042857	2.3
149	39.23077	182000	1.38	1.042857	2.38
150	40.38462	197600	1.63	0.960526	3.23
151	40.38462	223600	2.06	0.848837	4.51
152	41.92308	226200	2.12	0.83908	4.71
153	40.76923	235300	2.29	0.80663	5.4
154	186.6667	10680	0.41	1.123596	1.54
155	190	12840	0.6	0.934579	4.73
156	188.3333	11460	0.48	1.04712	1.98
157	184.3333	14640	0.78	0.819672	5.84
158	188.3333	13200	0.63	0.909091	3.08

no	h/d_{50}	R_*	θ	w/U_f	k_s/d_{50}
90	214.5	34440	4.31	0.266312	9.24
91	213.5	35880	4.68	0.261438	10.92
92	218.5	36840	4.92	0.252207	12.49
93	220.3333	37680	5.16	0.248447	13.38
94	231.5	35100	4.48	0.249688	9.54
95	803.8462	5590	0.88	0.27907	3.6
96	793.8462	6253	1.1	0.24948	4.88
97	795.3846	6175	1.07	0.252632	4.39
98	790.7692	6682	1.26	0.233463	5.68
99	781.5385	6916	1.35	0.225564	5.78
100	784.6154	7046	1.4	0.221402	4.77
101	778.4615	7072	1.41	0.220588	4.39
102	779.2308	7514	1.59	0.207612	5.9
103	775.3846	7605	1.62	0.205128	4.58
104	776.1538	7735	1.69	0.201681	5.22
105	775.3846	7969	1.78	0.195759	4.82
106	776.9231	8034	1.81	0.194175	4.33
107	793.0769	8177	1.88	0.190779	5.56
108	792.3077	8463	2.02	0.184332	5.61
109	804.6154	8801	2.18	0.177253	6.51
110	798.4615	8515	2.04	0.183206	3.69
111	800	8749	2.15	0.178306	4.04
112	26.66667	270000	1.02	1.322222	2.39
113	27.3	282000	1.11	1.265957	2.83
114	28.33333	270900	1.03	1.317829	2.88
115	33.33333	240000	0.87	1.4875	1.94
116	28.5	270900	1.03	1.317829	2.72
117	28.66667	274800	1.06	1.299127	2.78
118	27.06667	291600	1.19	1.22428	2.59
119	28.66667	282300	1.12	1.264612	2.88
120	27.76667	315000	1.39	1.133333	3.96
121	28.93333	287700	1.16	1.240876	3.06
122	33.33333	225000	0.76	1.586667	1.77
123	27.7	334800	1.57	1.066308	4.75
124	29.13333	290400	1.18	1.229339	3.04
125	28.5	376500	1.98	0.948207	8.05
126	28.66667	375000	1.97	0.952	7.82
127	29.63333	290400	1.18	1.229339	2.87
128	33.33333	243000	0.89	1.469136	2.31
129	29.46667	304800	1.3	1.17126	2.92
130	29.53333	297600	1.24	1.199597	2.66
131	30.16667	321000	1.44	1.11215	4.03
132	33.33333	267000	1.08	1.337079	3.09
133	30.8	348900	1.7	1.023216	5.11

چگونه به این مقاله ارجاع دهیم

M. Zanganeh, A. Rastegar, Estimation of Roughness Coefficient in Erodible Channels by ANNs and the ANFIS Methods, Amirkabir J. Civil Eng., 52(2) (2020) 495-512.

DOI: 10.22060/ceej.2018.14532.5678

