

را قرن‌ها مطالعه کرده‌اند. مطالعه بار بستر انتقال‌یافته برای بررسی ارتباط بین عوامل هیدرولیکی و شکل بستر کانال‌های آبی نیز اهمیت بسزایی دارد [۱۲]. علم بررسی انتقال رسوب به روشن شدن علل و پیامدهای تغییرات در رودخانه کمک می‌کند و تابع تصمیم‌گیری آگاهانه و مدیریتی که رودخانه را تحت تاثیر قرار می‌دهد، می‌باشد. برای توسعه توابع انتقال رسوب روش‌های مختلفی ارائه گردیده که برای حل مشکلات مهندسی و محیطی استفاده شده‌اند، نتایج بدست آمده از روش‌های مختلف متفاوت از دیگری است. برخی از مفاهیم اساسی توابع انتقال رسوب، محدودیت‌های کاربرد آن‌ها و روابط درونی میان پارامترهای موثر بر آن‌ها، در سال‌های اخیر برای ما روشن شده است. بسیاری از جنبه‌های پیچیده انتقال رسوب هنوز درک نشده و به عنوان بحث‌هایی چالشی برای مطالعات آینده باقی مانده است. یکی از این جنبه‌های مهم و فاکتورهای موثر روی نرخ انتقال رسوب حضور و عدم حضور مصالح چسبنده در رودخانه می‌باشد. مکانیزم انتقال رسوب برای مصالح چسبنده و غیرچسبنده متفاوت است. تاکنون تحقیقات بسیار کمی در مورد نرخ حمل و نقل رسوبات با چسبندگی‌های مختلف در بستر رودخانه‌ها و مدل‌های آزمایشگاهی مختلف انجام شده است.

تعدادی از مدل‌های انتقال رسوب برای رسوبات فاقد مصالح چسبنده ارائه شده‌اند که در این میان می‌توان به کارهای مایر- پیترو و مولر، اینشتین، بگنولد، یالین و چانگ و همکاران و نیز گراف، کریم و کندی، یانگ، یانگ و لیم و یانگ اشاره کرد [۲۶، ۲، ۳۶، ۴، ۱۳، ۲۱، ۳۸، ۳۹، ۴۰].

محققان معدودی با استفاده از کارهای آزمایشگاهی مبتنی بر فرسایش رسوبات چسبنده که عمدتاً شامل خاک رس خالص و یا مخلوط شن، سیلت و رس بطور عمده مطالعاتی انجام داده‌اند. اگر چه در بیشتر این مطالعات نیز نحوه انتقال (فرم بستر یا مواد معلق) مدنظر بوده و رابطه تحلیلی‌ای ذکر نشده است، که از این میان می‌توان به مطالعات هانسون، آموس و همکاران و وان و فل اشاره کرد [۱۶، ۱، ۳۴].

دقت فرمول‌های محاسبه شده و تطابق بین داده‌های مشاهداتی و محاسباتی بسته به شرایط جمع‌آوری داده‌ها، متفاوت می‌باشد، که این موضوع، انتخاب فرمول مناسب را برای رودخانه (کانال آبی) مورد مطالعه مشکل می‌کند [۳۳، ۳۶].

انتقال بار بستر یک فرآیند بسیار پیچیده است، از این‌رو ارائه رابطه‌ای کامل و قطعی در قالبی ریاضی برای برآورد این فرآیند بسیار

پیش‌بینی انتقال بار بستر در رسوبات چسبنده با استفاده از شبکه عصبی

مریم رستمی^۱، علی سلاجقه^۲، مجتبی صانعی^۳، سعید رستمی^۴
و محمد مهدوی^۵

تاریخ دریافت: ۱۳۹۳/۱/۲۲ تاریخ پذیرش: ۱۳۹۳/۱۱/۱۵

چکیده:

انتقال بار بستر به‌طور گسترده در دهه‌های اخیر مورد توجه و مطالعه قرار گرفته است و معادلات زیادی از آن‌ها نتیجه شده که اجزای تشکیل‌دهنده و شکل ارائه هر یک از این فرمول‌ها متفاوت از بقیه می‌باشد. به‌دلیل پیچیدگی و تنوع عوامل موثر بر فرآیند انتقال بار بستر، دستیابی به روابط قطعی یا تحلیلی، بسیار مشکل می‌باشد. مدل‌سازی شبکه عصبی که تاکنون بیشتر برای فرآیندهایی که به علم فیزیک محدود می‌شوند استفاده شده و نتایج مطلوبی را در برداشته، در مطالعه آزمایشگاهی پیش رو به‌عنوان یک ابزار مناسب برای مدل‌سازی انتقال بار بستر استفاده گردیده است. بر اساس معیارهای آماری مختلف، مدل توسعه‌یافته کارایی بالایی را نشان داد. معنی‌داری پارامترهای ورودی و تاثیر و اهمیت هر یک از پارامترهای مورد مطالعه بر فرآیند انتقال نیز در این پژوهش مورد بررسی قرار گرفته‌اند.

واژه‌های کلیدی: انتقال بار بستر، مطالعه آزمایشگاهی، فرآیند مدل‌سازی، معنی‌داری ورودی‌ها، شبکه عصبی

مقدمه

بررسی انتقال رسوب کانال‌های آبی در مطالعات مهندسی و رسوب‌شناسی اهمیت ویژه‌ای دارد، به‌طوری‌که مهندسین زمین‌شناسان و مورفولوژیست‌های رودخانه موضوع انتقال رسوب

۱- دانش‌آموخته کارشناسی ارشد آبخیزداری دانشکده منابع طبیعی دانشگاه تهران،
ma_rostami@alumni.ut.ac.ir

۲- استاد دانشکده منابع طبیعی دانشگاه تهران و نویسنده مسئول، salajegh@ut.ac.ir

۳- دانشیار پژوهشکده حفاظت خاک و آبخیزداری

۴- دانش‌آموخته کارشناسی ارشد مکانیک دانشکده فنی دانشگاه خواجه‌نصیرالدین طوسی

۵- استاد دانشکده منابع طبیعی دانشگاه تهران

جدول ۱- مشخصات مصالح مورد استفاده

Table 1. Characteristics of materials used

نفوذپذیری (سانتی متر بر ثانیه)	چگالی نسبی (گرم بر سانتی متر مکعب)	قطر متوسط ذرات (میلی متر)	شن (درصد)	مصالح چسبنده (درصد)
Permeability (cm/sec)	Density (gr/cm ³)	D ₅₀ (mm)	Sand (%)	Cohesive materials (%)
0.05063	2.62	0.258	100	0
0.02532	2.60	0.247	95	5
0.02298	2.60	0.232	90	10
0.01277	2.60	0.225	85	15
0.00718	2.60	0.220	75	25
0.00025	2.59	0.120	60	40

متر طول و ۰/۲۵ متر عرض و ۰/۱۵ متر عمق در یک فاصله ۳ متری از ورودی کانال می باشد. اندازه گیری ها علاوه بر شیب های متفاوت در دبی های مختلف انجام گردید. جزئیات روند انجام آزمایش ها در زیر آورده شده است.

به طور کلی، پژوهشگران معتقدند که مهم ترین فاکتورهای موثر در فرسایش بستر رودخانه، شیب، عمق جریان، رسوبات معلق و مصالح بستر می باشند. رسوبات غیر چسبنده شامل شن به عنوان رسوبات پایه استفاده شدند. برای ایجاد رسوبات چسبنده، رس، لای و سیلت خیلی ریز در درصد های گوناگون به رسوبات پایه اضافه گردید. در مطالعات مهندسی وقتی میزان مصالح چسبنده در مخلوط رسوبات بیشتر از ۵ تا ۱۰ درصد شود خصوصیات چسبندگی اهمیت ویژه ای می یابد. بنابراین رسوبات چسبنده با مخلوط کردن درصد های متفاوت مصالح چسبنده با شن آماده گردید. آزمایش ها روی شش نوع از مصالح بستر انجام شدند؛ که اطلاعات مربوط به رسوبات مورد استفاده در بستر مورد آزمایش در جدول ۱ آورده شده است. آزمایش ها در شرایط یکسان از لحاظ تمام پارامترهای موثر روی انتقال بار از قبیل محتوای رطوبت پیشین، فشردگی بستر رسوبی و... و شرایط متفاوت جریان ترتیب داده شدند.

بعد از اشباع شدن بستر رسوبی، به دبی مورد نظر اجازه ورود به فلوم و جریان یافتن روی بستر داده شد. رسوباتی که به دو متر انتهایی فلوم و همچنین به تله تعبیه شده در انتهای فلوم انتقال پیدا کرده بودند جمع آوری شدند.

اندازه گیری بار بستر پس از ۳۰ دقیقه صورت گرفت. وزن بار بستر به صورت وزن خشک رسوبات اندازه گیری شده اند (خشک کردن رسوبات با استفاده از دستگاه آون به طور یکنواخت و در شرایط یکسان انجام شد). در مجموع ۷۲ آزمایش با تفاوت در مصالح بستر (با درصد های متفاوت مصالح چسبنده به شرح جدول ۱)، دبی (۲ و ۳ و ۴ و ۵ لیتر بر ثانیه) و شیب فلوم (۰/۰۷۵، ۰/۰۱ و ۰/۱۲۵) مورد بررسی واقع شد به عنوان شاهد نیز آزمایش هایی بدون حضور رس در مصالح بستر انجام شد. تغییرات عمق جریان ناشی از تغییر دبی، نیز در طی انجام آزمایش ها با کمک دستگاه پروفایلر بررسی شد.

فرایند فرسایش رسوبات چسبنده به وسیله خصوصیات مکانیکی مثل

مشکل می باشد. به موازات تحقیقات صورت گرفته در انتقال رسوب یک روش مدل سازی جدید به عنوان داده کاوی^۱ وجود دارد. این روش با استفاده از علوم دردسترس و با توجه به محدودیت ها و اطلاعات نسبی موجود برای مدل سازی در یک چهارچوب ریاضی راه گشا می باشد. داده کاوی امروزه تقریباً در تمامی شاخه های علوم و به عنوان یک راه حل تکمیلی برای مدل سازی بیشتر سیستم های فیزیکی سنتی استفاده می شود. در مدل سازی تکمیلی، استفاده از شبکه های عصبی مصنوعی^۲ پیشگام می باشد. مدل سازی شبکه عصبی در علوم مختلف کاربردهای بسیاری دارد. تکنیک های شبکه عصبی برای مطالعه چندین پدیده هیدرولوژیکی و هیدرولیکی شامل کیفیت آب، جریان های آبراهه، ریزش باران، رواناب، انتقال رسوب و یافتن داده های گمشده استفاده شده است [۹، ۳۰، ۶، ۱۸، ۱۱]. شبکه عصبی همچنین به طور موفقیت آمیزی برای پیش بینی دبی رسوب به کار گرفته شده است [۵، ۲۸]. کیسی با استفاده از شبکه های عصبی تمرکز رسوبات معلق را پیش بینی کرد [۲۲]. کامانو و همکاران از تکنیک شبکه عصبی برای بدست آوردن فرمول انتقال رسوبات بار بستر استفاده کردند [۳].

دوگان و همکاران مدل سازی شبکه عصبی را برای پیش بینی بار کل و ساسال و همکاران از آن برای پیش بینی بار بستر استفاده کردند [۸، ۳۱]. کاربردهای اولیه شبکه های عصبی شامل توسعه مدل هایی برای پیش بینی مقدار نهایی یک متغیر پاسخ بخصوص، از بین یک سری متغیر مستقل موجود می باشد. مطالعات اخیر روش های مختلفی برای کمی کردن و تفسیر سهم هر یک از متغیرها در شبکه های عصبی فراهم کرده است [۲۹، ۱۰].

همان طور که اشاره شد، درک مناسب پارامترهای موثر بر فرآیند انتقال اهمیت زیادی در برنامه ریزی و طراحی سازه های هیدرولیکی در محیط های آبرفتی دارند.

مواد و روش ها

آزمایش ها در یک فلوم با ۸ متر طول و ۰/۲۵ متر عرض و ۰/۵ متر عمق مورد بررسی قرار گرفته اند. فلوم دارای یک مقطع آزمایشی با ۲

1- Data Mining (DM)

2- Artificial Neural Networks (ANN)



شیب = 0.01 دبی = 3 lit/s شن = 90% میزان مصالح چسبنده = 10%

Slope= 0.01 discharge= 3 lit/s sand= 90% Amount of the Cohesive Materials=10%



شیب = 0.01 دبی = 3lit/s شن = 75% میزان مصالح چسبنده = 25%

Slope= 0.01 discharge= 3 lit/s sand= 75%



شیب = 0.01 دبی = 3lit/s شن = 60% میزان مصالح چسبنده = 40%

Slope= 0.01 discharge= 3 lit/s sand= 60%



شکل ۱- وضعیت بستر در محدوده دو متر پوشیده شده از مواد مورد مطالعه، پس از انجام آزمایش (سمت راست) و وضعیت مواد انتقال یافته به سه متر انتهایی فلوم آزمایشگاهی، پس از انجام آزمایش (سمت چپ)

Figure 1. The bed in the range of study that covered by target materials, after testing (right) and the materials of transfer to a three-meter of the flume end, after testing (left)

می شود. در صورتی که درصدهای مصالح چسبنده بیشتر باشد (بیشتر از ۱۵ درصد) فرسایش به صورت یک گودال بزرگ در طول بستر کانال توسعه پیدا کرده که به شکل فرسایش خندقی می باشد و انتقال رسوب نیز در این مواقع بسیار کاهش می یابد. با افزایش مقدار مصالح چسبنده انتقال بار بستر کاهش پیدا کرد. این روند کاهشی تا زمانیکه نرخ انتقال بار بستر صفر شد، موقعی که درصد مصالح چسبنده (رس + لای + سیلت خیلی ریز) در مخلوط مصالح بستر به ۴۰ رسید، ادامه پیدا کرد (شکل ۱). مقایسه بین نرخ انتقال بار بستر رسوبات چسبنده و غیرچسبنده تحت تاثیر تغییر پارامترهای هیدرولیکی نیز (عمق متغیر جریان در نتیجه تغییر دبی و شیب فلوم) در این مطالعه بررسی شده است.

تنش برشی و خصوصیات فیزیکوشیمیایی آن ها کنترل می شود. مقدار و نوع رس، محتوای رطوبت پیشین و... فاکتورهای کنترل کننده فرسایش رسوبات چسبنده ای هستند که به راحتی قابل اندازه گیری اند [۲۲]. از میان تمام این متغیرها و فرایندهای فرسایش بستر کانال، اثر تنش برشی و مقدار رس روی انتقال رسوبات چسبنده در اینجا مورد مطالعه قرار گرفته و بقیه عوامل کنترل کننده موثر ثابت در نظر گرفته شده اند.

مشاهدات نشان داد که در شرایط یکسان از لحاظ تنش برشی اعمال شده توسط جریان بر بستر و...، وقتی درصدهای کمتر مصالح چسبنده حداکثر ۱۵ درصد) در مصالح بستر وجود داشته باشد مقدار بار بستر انتقال یافته خیلی زیاد می باشد. علاوه بر این اشکال ثانویه ای چون دیون و ریپل در نتیجه انتقال بار بستر تشکیل

بررسی‌ها نشان می‌دهند که مقدار انتقال بار بستر چندین برابر کاهش می‌یابد هنگامی که مصالح چسبنده در درصد‌های مختلف در مصالح بستر موجود باشد بنابراین سطوح متفاوت چسبندگی تفاوت معنی‌داری در انتقال بار بستر و تحت شرایط مشابه جریان ایجاد می‌کند و مقدار انتقال بار بستر در این حالات به‌طور معنی‌داری کمتر از انتقال بار بستر رسوبات فاقد چسبندگی می‌باشد.

رسوبات چسبنده تمایل به اتصال به هم به شکل واحدهای بزرگ با چگالی کم دارند. این موضوع خود دلیلی بر کاهش نرخ انتقال بار بستر با افزایش مصالح چسبنده می‌باشد این فرایند به شدت وابسته به نوع رسوب، مقدار رس، نوع و غلظت یون‌ها در آب و شرایط جریان می‌باشد [۲۷]. فرسایش رسوبات چسبنده نه تنها بوسیله خصوصیات فیزیکی ماکروسکوپی بلکه بوسیله خصوصیات فابریک و نیروهای بین ذره‌ای کنترل می‌شود [۲۵]. از طرفی مکانیزم اصلی که باعث انتقال رسوب در جریان آب می‌شود سرعت جریان و تنش برشی ناشی از جریان می‌باشد [۱۴]. هنگامیکه نیروی هیدروپنمیک در جریان آشفته از نیروی چسبندگی بستر رسوبی بیشتر شود رسوبات شروع به جدا شدن از بستر می‌کنند و جریان آب کدر می‌شود. با افزایش بیشتر در تنش برشی جریان، رسوب از بستر جدا شده و توسط جریان منتقل می‌شود [۲۳]. نرخ انتقال رسوبات در مطالعه حاضر مربوط به تغییر در میزان چسبندگی، اندازه ذرات بسترهای رسوبی و پارامترهای هیدرولیکی و دینامیکی (عمق جریان، شیب و تنش برشی) می‌باشد [۲۵] که با استفاده از شبکه عصبی مدل استخراج و تاثیر پارامتر چسبندگی در کنار پارامترهای دیگر بررسی گردیده است.

– مدل‌سازی شبکه عصبی

برای تخمین بار بستر چندین معادله تجربی توسط محققان، با استفاده از داده‌های آزمایشگاهی و با فرض هموزن و غیرچسبنده بودن رسوبات انجام شده است. این گونه معادلات برای رسوبات چسبنده خیلی کم ارائه شده است علاوه بر آن مدل‌سازی میزان بار بستر انتقال‌یافته با استفاده از شبکه عصبی نیز برای این نوع رسوبات در دسترس نمی‌باشد. در مطالعات مهندسی رودخانه همه پارامترها را نمی‌توان در یک مطالعه بررسی کرد لذا هر یک از این مدل‌ها در شرایط مختلف قابل استناد نیستند. بنابراین ما می‌توانیم روند کلی نرخ انتقال رسوب را با استفاده از چندین فرمول، مدل و با داشتن پیش زمینه تئوری تشخیص دهیم.

پارامترهای ورودی و خروجی مدل شبکه عصبی در مطالعه حاضر و چگونگی دستیابی به آن‌ها در زیر ارائه شده است:

$$q_s = f(\tau_b, S, \gamma_s', d_m, \rho_o) \quad (1)$$

q_s : میزان بار بستر انتقال‌یافته در واحد عرض، τ_b : تنش برشی بستر، d_m : قطر متوسط ذرات تشکیل‌دهنده بستر، S : شیب بستر، γ_s' : وزن مخصوص مواد جامد، ρ_o : درصد مصالح چسبنده در مواد بستر. که در آن:

$$\gamma_s = \gamma_s - \gamma = (\rho_s - \rho)g \quad (2)$$

ρ_s : چگالی مواد بستر، ρ : چگالی سیال، γ : وزن مخصوص سیال فریدوس در سال ۱۹۸۱، فرمولی برای محاسبه تنش برشی ارائه داده است که در پژوهش پیش رو برای دستیابی به مقادیر تنش برشی بستر از آن بهره گرفته شده است:

$$\tau_b = \frac{1}{2} \rho_w f_c \bar{v}^2 \quad (3)$$

f_c : فاکتور مربوط به اصطکاک که از رابطه ۴ به دست می‌آید [۷]،

$\bar{v}$: سرعت متوسط (m/s)

$$f_c = 2 \frac{k^2}{(\ln(\frac{30H}{K_N} - 1))^2} \quad (4)$$

k : ثابت وان کارمن که تقریباً برابر ۰/۴ می‌باشد؛ H : عمق آب (m)؛ k_N : زبری بستر (m).

فاکتور اصطکاکی علاوه بر فرمول بالا، می‌تواند با استفاده از ضریب شزی و در قالب فرمول زیر محاسبه شود:


$$f_c = \frac{g}{C^2} \quad (5)$$

g : شتاب گرانشی ($m.s^{-2}$) و C : ضریب شزی ($m^{1/2}.s^{-1}$) می‌باشد. شبکه‌های عصبی، همراه با یک الگوریتم یادگیری مناسب می‌توانند برای شناسایی روابط پیچیده موجود بین مجموعه‌ای از داده‌های ورودی و خروجی استفاده شوند. پرکاربردترین الگوریتم یادگیری برای شبکه‌های feed-forward layered روش پس‌انتشار خطا می‌باشد [۱۹]. هورنیک و همکاران، بیان کردند شبکه‌های عصبی با تعداد کافی گره در لایه پنهان، بدون نیاز به اطلاعات قبلی درباره سیستم، توانایی پیدا کردن هرگونه رابطه غیرخطی بین ورودی‌ها و خروجی‌ها را دارند. در یک شبکه عصبی اطلاعات، در وزن‌های بین نوروها و توپولوژی شبکه نهفته است [۱۷، ۱۸].

فرآیند آموزش عبارت است از تخمین ماتریس‌های وزنی که بهترین برازش را برای پیش‌بینی خروجی‌ها بر اساس مجموعه داده‌های آموزشی تولید می‌کند. روش مینا بدین طریق است که، ابتدا وزن‌های بین لایه‌ها به صورت تصادفی مقداردهی می‌شوند، سپس لایه‌ی ورودی تحت تاثیر بردار ورودی قرار گرفته و از طریق شبکه به لایه‌ی خروجی انتشار می‌یابد. ماتریس وزن‌ها توسط یک روش بهینه‌سازی تکراری بروزرسانی می‌شود تا مجموع مربعات خطا (اختلاف بین خروجی شبکه و خروجی هدف) کمینه گردد.

مشکل اصلی الگوریتم پس‌انتشار خطا همگرایی به مقادیر کمینه محلی می‌باشد. روش‌های مختلفی برای اصلاح الگوریتم پس‌انتشار خطا پیشنهاد شده است که از بین آن‌ها روش لونیگ-مارکوت در مقایسه با روش‌هایی چون Conjugate gradient یا Quasi-Newton بسیار موثرتر می‌باشد [۱۵].

کارهای لونیگ-مارکوت بر این فرض استوار است که تابع اصلی بصورت خطی می‌باشد. بر اساس این فرض مقدار کمینه می‌تواند در یک مرحله بطور دقیق تعیین شود. کمینه محاسبه شده آزموده می‌شود، اگر خطا کمتر شود الگوریتم وزن‌ها را به نقطه‌ای جدید منتقل می‌کند. این فرآیند در هر مرحله تکرار می‌شود. از



شکل ۲- ساختار شبکه عصبی

Figure 2. The structure of the neural network

شکل به وضوح نشان می‌دهد که ضریب همبستگی خطی بین داده‌های مشاهداتی و مقادیر پیش‌بینی شده شبکه‌های عصبی زیاد است؛ به طوری که مقادیر در آموزش و آزمایش به ترتیب ۰/۹۸ و ۰/۹۹ می‌باشد. در مجموع برای تمامی داده‌ها ضریب همبستگی خطی ۰/۹۸ است.

ارزیابی مدل به دست آمده بر مبنای R^2 ، ضریب عملکرد مدل Nash-Sutcliffe و نسبت اختلافی انجام شده است. ضریب کارایی Nash-Sutcliffe برای ارزیابی قدرت پیش‌بینی مدل استفاده می‌شود و به صورت زیر تعریف می‌گردد [۲۹]:

$$E = 1 - \frac{\sum (Observed - Simulated)^2}{\sum (Observed - ObservedMean)^2} \quad (V)$$

مقدار E می‌تواند در محدوده بین $-\infty$ تا ۱/۰ تغییر کند، به طوری که هرچه مقادیر بالاتر، برازش کلی بهتر و مقدار ۱/۰ نشان‌دهنده برازش کامل می‌باشد. ضریب کارایی صفر نشان‌دهنده این است که پیش‌بینی‌های مدل به درستی میانگین داده‌های مشاهداتی است، در حالی که ضریب کارایی کمتر از صفر نمایانگر حالتی است که میانگین مشاهده شده پیش‌بینی بهتری را نسبت به مدل ارائه می‌دهد.

نسبت اختلافی و انحراف معیار نیز برای نمایش برازش مناسب مدل استفاده شده است. یک راه اندازه‌گیری برازش مناسب مدل، استفاده از نسبت اختلافی متوسط و انحراف معیار [۴۰] بر اساس متوسط نسبت لگاریتمی بین مقدار محاسبه شده و اندازه‌گیری شده می‌باشد:

$$\bar{D}_a = \frac{\sum \log(Simulated / Observed)}{n} \quad (8)$$

$$\sigma_a = \frac{\sqrt{\sum (\log(Simulated / Observed) - \bar{D}_a)^2}}{n-1} \quad (9)$$

که در آن n تعداد مشاهدات است. برای یک برازش کامل مقادیر σ_a و $\bar{D}_a$ برابر صفر می‌باشند. نتایج این محاسبات برای مدل حاصل در این پژوهش به شرح زیر می‌باشد:

$\bar{D}_a$ و σ_a به ترتیب برابر با ۰/۹۱۷، ۰/۱۱۵ و ۰/۲۳۵ می‌باشند، این مقادیر بیانگر عملکرد مناسب مدل و در نتیجه تعمیم مطلوب

آنجا که فرض خطی بودن نادرست می‌باشد، ممکن است الگوریتم لونبرگ-مارکوت یک نقطه نامناسب را نسبت به نقطه قبلی نتیجه دهد. برای اجتناب از این مسئله، الگوریتم لونبرگ-مارکوت نقطه جدید را از طریق مصالحه بین حرکت در راستای بیشترین شیب و انتقال فوق‌الذکر انجام می‌دهد:

معادله بروزرسانی وزن‌ها در روش لونبرگ-مارکوت در طول آموزش به شرح زیر می‌باشد:

$$\Delta w = (J^T J + \mu I)^{-1} J^T E \quad (6)$$

که در آن J ماتریس ژاکوبین مشتق خطا به وزن، μ یک مقدار اسکالر و E بردار خطا می‌باشد. الگوریتم لونبرگ-مارکوت عملکرد بسیار خوبی دارد و نسبت به روش مرسوم پس انتشار خطای دارای نرخ یادگیری و فاکتور مومنتم^۱ بسیار کاراتر است.

تمامی مراحل مدل‌سازی و آنالیز با استفاده از جعبه ابزار شبکه عصبی نرم‌افزار MATLAB انجام شده است. تعیین تعداد نورون‌های عصبی در لایه پنهان نیز یک مسئله مهم است. استراتژی رایج، شروع با یک شبکه کوچک، آموزش شبکه، اضافه کردن نورون‌های جدید و ادامه دادن تا زمانی که عملکرد شبکه به حد قابل قبولی برسد، می‌باشد.

مسترز پیشنهاد کرده است مشاهدات به صورت تصادفی به دو قسمت آماری، بخش آموزش برای کالیبراسیون مدل و بخش اعتبارسنجی برای آزمون مدل تقسیم شود [۳۹].

برای ایجاد مدل ANN در این پژوهش، ۷۰٪ کل داده‌ها برای آموزش، ۱۵٪ برای آزمون و ۱۵٪ برای اعتبارسنجی مورد استفاده قرار گرفته است. لازم به ذکر است که ANN‌ها مشابه تمامی مدل‌های تجربی، نشان‌دهنده بهترین حالت درونیابی به جای برون‌یابی می‌باشد [۲۴]؛ در نتیجه، بیشتر داده‌های موجود در بخش آموزش استفاده شده است. هنگامی که داده‌ها برای مجموعه آموزش و آزمون تقسیم شدند، متغیرهای ورودی و خروجی برای از بین بردن بعدهایشان و اطمینان از این که تمامی متغیرها در آموزش و آزمون اهمیت یکسانی دارند، در مقیاسی بین ۰/۰۰ و ۱/۰۰ پیش‌پردازش شدند.

به عنوان بخشی از این روش، برای هر متغیر X با مقادیر حداقل و حداکثر که به ترتیب با X_{Min} و X_{Max} نشان داده می‌شوند، مقدار پیش‌پردازش شده (X_n) به شرح زیر محاسبه می‌شود:

$$X_n = (X - X_{min}) / (X_{max} - X_{min})$$


ساختار نهایی شبکه عصبی استفاده شده در مطالعه پیش‌رو برای آنالیز ۱-۲-۵ می‌باشد که در شکل ۲ نمایش داده شده است.

تابع انتقال مورد استفاده در لایه پنهان و لایه خروجی به ترتیب sigmoid tan و خطی می‌باشد. حداکثر تعداد دور تا ۱۰۰۰ در نظر گرفته شد. هدف موجود در انتخاب توابع سیگموئید به عنوان توابع انتقال شباهت زیاد آن‌ها به نورون‌های عصبی بیولوژیکی می‌باشد.

نتایج

نتایج مدل‌سازی عصبی در شکل ۳ نشان داده شده است، این

1- momentum



شکل ۳- نتایج مدل سازی شبکه عصبی برای مقادیر آموزش، آزمایش، اعتبارسنجی و کل داده ها
Figure 3. Simulation results of neural network for the training, testing values and validation

سازه های هیدرولیکی، مدیریت مشکلات مربوط به آبستکی و... مورد نیاز است. مدل های انتقال بار مواد بستر اغلب بسیار پیچیده اند و معادلات انتقال تجربی یا نیمه تجربی به خصوصیات مانند دبی، سرعت، عمق جریان و مشخصات و اندازه ذرات رسوبی بستگی دارد. در این کار، یک مدل شبکه عصبی برای پیش بینی انتقال بار مواد بستر با استفاده از داده های آزمایشگاهی توسعه یافته است. عملکرد مدل ANN توسعه یافته با توجه به تنوع و تفاوت داده های آزمایشگاهی استفاده شده رضایت بخش است. ماتریس وزنی مدل استخراج شده، بیانگر حساسیت بالای میزان بار بستر انتقال یافته به تغییر مقادیر پارامترهای شیب بستر، تنش برشی و چسبندگی می باشد. بنابراین در نظر گرفتن پارامتر چسبندگی به عنوان پارامتری حائز اهمیت در مطالعات انتقال بار باید مورد توجه قرار گیرد.

ماهیت غیر خطی و غیر پارامتریک مدل شبکه عصبی استفاده از آن را برای کاربردهای صحرایی امکان پذیر می سازد؛ همچنین فرصت های بیشتری برای یافتن اشتباهات موجود در مدل سازی و اشکالات نرم افزاری به ارمغان می آورد. بنابراین، توجه به این نکته که پیش بینی های مدل های ANN هنگامی که برای محدوده ای از

آن می باشند.

ماتریس وزنی مدل استخراج شده و راهنمای آن نیز در جدول ۲ آورده شده است.

همان طور که انتظار می رفت و از جدول ۲ قابل برداشت است، متغیرهای مربوط به شیب، تنش برشی و چسبندگی نسبت به دیگر پارامترها دارای تاثیر بیشتری بر انتقال بار مواد بستر می باشند. در میان متغیرهای مورد بررسی قطر متوسط ذرات تشکیل دهنده از اهمیت و تاثیر کمتری بر فرآیند انتقال برخوردار است. هر معادله انتقال بار مواد بستری ارائه شده در مقالات و پژوهش های مختلف با توجه به مجموعه داده های استفاده شده در آن ها، ارزش و اعتبار کاربردی مختص به خود را دارا می باشند [۳۲]. وزن های ارائه شده در جدول ۲ نشان می دهد هرگونه تغییر در شیب، تنش برشی و چسبندگی می تواند به کمتر یا بیش از حد برآورد شدن مقدار مواد بستری انتقال یافته منجر گردد.

بحث و نتیجه گیری

پیش بینی نرخ انتقال رسوبات به عنوان مبنایی برای طراحی

جدول ۲: ماتریس وزنی مدل

Table 2: The weight matrix of the model

W_1					W_2	B_1
S	D_o	P_{co}	γ_s'	τ_b		
-0.4261	-1.0787	0.5646	-0.1856	-1.1207	-1.0079	2.4186
13.5903	-0.7725	-8.7910	4.0829	9.4118	-0.0243	-3.5582

مقادیر وزنی لایه ورودی پنهان
hidden input-layer weight values: w_1
پارامترهای ورودی
represents the input patterns: x
بایس
bias: b_1
نمایان گر بعد ماتریکس
matrix the of dimension the represent: ()

$$Y = f_2(w_2 f_1(w_1 x + b_1))$$

مقدار خروجی مدل
Y: output value of the model
توابع خطی
functions linear: f_2
مقادیر وزنی لایه خروجی پنهان
the hidden output-layer weight values: w_2
توابع انتقالی تانژانتی هایپربولیک
hyperbolic tangent transfer functions.: f

7- Dyer K. R. (1986) Coastal and Estuarine Sediment dynamics. John Wiley & Sons. Chichester. 342 p.

8- Doğan, E., Yüksel, I., and Kişioğlu, O., 2007. Estimation of total sediment load concentration obtained by experimental study using artificial neural networks. Environmental Fluid Mechanics, 7, 271–288.

9- Dolling, O.R. and Varas, E.A., 2002. Artificial neural networks for streamflow prediction. Journal of Hydraulic Research, 40 (5), 547–554.

10- Gevrey, M., Dimopoulos, I., and Lek, S., 2003. Review and comparison of methods to study the contribution of variables in artificial neural network models. Ecological Modelling, 160, 249–264.

11- Giustolisi, O. and Simeone, V., 2006. Optimal design of artificial neural networks by a multi-objective strategy: groundwater level predictions. Hydrological Sciences Journal, 51, 502–523.

12- Gomez, B., 2006. The potential rate of bed-load transport. Proceedings of the National Academy of Sciences, 73 (103), 17170–17173.

13- Graf, W.H., 1971. Hydraulics of sediment transport. New York: McGraw-Hill.

14- Garde, R. J., and K. G. Ranga Raju (2006), Mechanics of Sediment Transport and Alluvial Stream Problems, 3rd ed., New Age Int. Publ., New Delhi.

15- Hagan, M.T. and Menhaj, M.B., 1994. Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, 6, 989–993.

متغیرهای ورودی مشابه آنچه که در آموزش مدل استفاده شده، به کار رود نتیجه بهتری خواهد داد، بسیار ارزشمند است. عملکرد مدل در هر سه مورد آموزش، آزمون و کل بطور تقریبی یکسان است که نمایانگر تعمیم مطلوب مدل می باشد.

منابع

1- Amos, C. L., T. Feeney, T. F. Sutherland, and J. L. Luternauer (1997), The stability of fine grained sediments from the Fraser River delta, Estuarine Coastal Shelf Sci., 45, 507– 524, doi:10.1006/ecss.1996.0193.

2- Bagnold, R.A., 1966. An approach to the sediment transport problem from general physics. US Geological Survey Professional Paper 422-I.

3- Caamaño, D., Goodwin, P., and Manic, M., 2006. Derivation of a bed-load sediment transport formula using artificial neural networks. In: Seventh International Conference on Hydroinformatics, Nice, France.

4- Chang, F.M., Simons, D.B., and Richardson, E.V., 1967. Total bed material discharge in alluvial channels. In: Proceedings of 12th Congress IAHR., vol. I, Fort Collins, Colorado.

5- Cigizoglu, H.K., 2002. Suspended sediment estimation and forecasting using artificial neural networks. Turkish Journal of Engineering and Environmental Science, 26, 15–25.

6- Cigizoglu, H.K., 2003. Estimation, forecasting and extrapolation of river flows by artificial neural networks. Hydrological Sciences Journal, 48, 349–361.

Engineering, American Society of Civil Engineers, 128, 588–595.

30- Nash, J. E. and Sutcliffe, J.V., 1970. River flow forecasting through conceptual models. 1: Discussion of principles. *Journal of Hydrology*, 10, 282–290.

31- Olden, J.D. and Jackson D.A., 2002. Illuminating the “blackbox”: understanding variable contributions in artificial neural networks. *Ecological Modelling*, 154, 135–150.

32- Rajurkar, M.P., Kothiyari, U.C., and Chaube, U.C., 2002. Artificial neural networks for daily rainfall–runoff modelling. *Hydrological Sciences Journal*, 47, 865–877.

33- Sasal, M. et al., 2009. Artificial neural network for bedload estimation in alluvial rivers. *Journal of Hydraulic Research*, 47 (2), 223–232.

34- Sinnakaudan, S. et al., 2006. Multiple linear regression model for total bed material load prediction. *Journal of Hydraulic Engineering, American Society of Civil Engineers*, 132 (5), 521–528.

35- Vanoni, V.A., 1975. *Sedimentation engineering*. New York: American Society of Civil Engineers, ASCE Manuals and Reports on Engineering Practice no. 54.

36- Wan, C. F., and R. Fell (2004), Investigation of rate of erosion of soils in embankment dams, *J. Geotech. Geoenviron. Eng.*, 130(4), 373 – 380, doi:10.1061/(ASCE)1090-0241(2004)130:4(373).

37- Yalin, M.S., 1963. An expression for bed-load transportation. *Proceedings of the American Society of Civil Engineers*, 89 (HY3), 221–250.

38- Yang, C.T., 1996. *Sediment transport: theory and practice*. New York: McGraw-Hill.

39- Yang, C.T. and Simões, F.J.M., 2005. Wash load and bed-material load transport in the Yellow River. *Journal of Hydraulic Engineering, American Society of Civil Engineers*, 131, 413–418.

40- Yang, S. and Lim S.Y., 2003. Total load transport formula for flow in alluvial channels. *Journal of Hydraulic Engineering, American Society of Civil Engineers*, 129 (1), 68–72.

41- Yang, S-Q., 2005. Prediction of total bed material discharge. *Journal of Hydraulic Research*, 43 (1), 12–22.

16- Hanson, G. J. (1990), Surface erodibility of earthen channels at high stress: Part I. Open channel testing, *Trans. ASAE*, 33(1), 127–131.

17- Hornik, K., Stinchcombe, M., and White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2, 359–366.

18- Hu, T.S., Lam, K.C., and Ng, S.T., 2005. A modified neural network for improving river flow prediction. *Hydrological Sciences Journal*, 50, 299–318.

19- Irie, B. and Miyanki, S., 1988. Capabilities of three layer perceptrons. In: *IEEE Second International Conference on Neural Networks*, San Diego, vol. 1, 641–648.

20- Jones, W.P. and Hoskins J., 1987. Back–propagation a generalized delta learning rule. *Byte*, 155–162.

21- Karim, M.F. and Kennedy, J.F., 1981. Computer based predictions for sediment discharge and friction factors of alluvial streams. In: *Proceedings of the second international symposium on river sedimentation*, Nanjing, China.

22- Kisi, O., 2004. Multi-layer perceptrons with Levenberg-Marquardt optimization algorithm for suspended sediment concentration prediction and estimation. *Hydrological Sciences Journal*, 49, 1025–1040.

23- Jain, R. K., and U. C. Kothiyari (2008), Cohesion influences on erosion and bed load transport, *Water Resour. Res.*, 45, W06410, doi:10.1029/2008WR007044.

24- Masters, T., 1993. *Practical neural network recipes in C++*. San Diego, CA: Academic Press.

25- Mazurek, K. A., N. Rajaratnam, and D. C. Sego (2001), Scour of cohesive soil by submerged circular turbulent impinging jets, *J. Hydraul. Eng.*, 127(7), 598–606, doi:10.1061/(ASCE)0733 9429(2001) 127:7(598).

26- Meyer-Peter, E. and Müller, R., 1948. Formulas for bedload transport. In: *Proceedings of the 2nd Meeting of the International*

27- Association for Hydraulic Structures Research, 39–64. Delft: International Association of Hydraulic Research.

28- Mehta, A.J., E.J. Hayter, W.R. Parker, R.B. Krone, and A.M. Teeter (1989). “Cohesive Sediment Transport. I: Process Description,” *Journal of Hydraulic Engineering*, vol. 115, no. 8, pp. 1076–1 093.

29- Nagy, H.M., Watanabe, K., and Hirano, M., 2002. Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydraulic*