

تخمین ضریب پخش طولی آلاینده‌ها در مجاری روباز با استفاده از شبکه عصبی مصنوعی

الهام ایزدی‌نیا^{1*}، عالیه سعادت‌پور²، منوچهر حیدرپور³

تاریخ دریافت: 93/10/12 تاریخ پذیرش: 94/10/21

¹ استادیار گروه مهندسی عمران، دانشگاه شهید اشرفی اصفهانی (ره)

² دانشجوی دکتری گروه علوم و مهندسی آب، دانشگاه فردوسی مشهد

³ استاد گروه مهندسی آب، دانشگاه صنعتی اصفهان

* مسئول مکاتبات، پست الکترونیکی: Izadinia@ashrafi.ac.ir

چکیده

انتقال طولی آلاینده‌ها یکی از مراحل مهم در فرآیند رقیق‌سازی آلاینده‌ها می‌باشد که شناخت آن از اهمیت ویژه‌ای برخوردار است. دشواری اندازه‌گیری ضریب انتشار طولی در رودخانه‌ها نیاز به استفاده از روش‌های مناسب مدل‌سازی در پیش‌بینی این ضریب را بیشتر می‌کند. یکی از روش‌های کارآمد مدل‌سازی شبکه عصبی مصنوعی است که یکی از تکنیک‌های هوش مصنوعی محسوب می‌شود. در این مدل بدون استفاده از معادلات پیچیده غیرخطی، می‌توان دینامیک حاکم بر سیستم را استخراج نموده و از این طریق، خروجی مدل را پیش‌بینی نمود. در این مطالعه ضریب انتشار طولی با توجه به مقادیر پارامترهای هیدرولیکی و هندسی رودخانه‌ها به‌عنوان پارامترهای ورودی و با استفاده از شبکه عصبی مصنوعی پیش‌بینی گردید. نتایج نشان داد شبکه پرسپترون پیش‌خور، پس‌انتشار خطا از دقت مناسبی برای تخمین ضریب پخش طولی آلودگی برخوردار است. نتایج تحلیل ترکیب پارامترهای ورودی نشان داد که با لحاظ نسبت سرعت به سرعت برشی به‌عنوان پارامتر ورودی مدل، میزان ضریب تعیین همبستگی 0/84 و تابع خطا برابر 0/87 % و در صورت لحاظ نسبت عرض جریان به عمق جریان به‌عنوان پارامتر ورودی، میزان ضریب تعیین همبستگی 0/7 و تابع خطا برابر 1/01 % حاصل شد. بنابراین نسبت سرعت به سرعت برشی یا ضریب زبری دارای تأثیر بیشتری بر ضریب انتشار طولی است. روش ارائه‌شده در این تحقیق رهیافتی کارآمد در تخمین ضریب پخش طولی آلودگی در رودخانه‌ها محسوب شده و قابلیت ترکیب با سایر مدل‌های پخش آلودگی را دارا می‌باشد.

واژه‌های کلیدی: آلاینده، انتقال آلودگی، شبکه عصبی مصنوعی، ضریب پخش طولی، کانال باز

Estimating Longitudinal Dispersion Coefficient of Pollutants in Open Channel Flows Using Artificial Neural Networks

E Izadinia*¹, A Saadatpour², M Heidarpour³

Received: 2 January 2015 Accepted: 11 January 2016

¹- Assist. Prof., Civil Eng. Dept., Shahid Ashrafi Esfahani Univ., Iran

²- Ph.D Student, Water Sci. and Eng. Dept., Ferdowsi Univ. of Mashhad, Iran

³- Prof., Dept. of Water Eng., Isfahan Univ. of Tech., Iran

* Corresponding Author, Email: Izadinia@ashrafi.ac.ir

Abstract

The longitudinal dispersion of pollutants is one of the most effective phases of the pollutants dilution process, which having insight about it is of importance. The complexity of measuring longitudinal dispersion coefficient in rivers increases the necessity of using appropriate methods of modeling to predict it. One of the most efficient methods for modeling is the artificial neural network which is one of the artificial intelligence techniques. In this model, without applying the complex nonlinear equations, the dynamics of the system can be extracted and, by this way the output of the model can be predicted. In this study, the longitudinal dispersion coefficient was predicted by artificial neural network (ANN), using hydraulic and geometric parameters of the streams as input parameters. Results indicated that the feed forward perceptron network had a suitable precision in estimating the longitudinal dispersion coefficient. Sensitivity analysis indicated that in the model, for which the ratio of velocity to the shear velocity was considered as an input variable, the determination coefficient and error function were equal to 0.84 and 0.87%, respectively. However, in the model with an input variable of width to flow depth ratio, the determination coefficient and error function were obtained 0.7 and 1.01%, respectively. Therefore, the ratio of the velocity to the shear velocity or roughness coefficient had a greater impact on longitudinal dispersion coefficient, as compared with the last one. The proposed methodology is an efficient approach to estimate dispersion coefficient in streams and can be implemented into mathematical models of pollutant transfer.

Keywords: Artificial Neural Network, Longitudinal Dispersion Coefficient, Open Channel, Pollutant, Pollution Transmission

مقدمه

شبیه‌سازی جریان، انتقال آلودگی و رسوب در سیستم‌های رودخانه‌ای برای منابع آب اهمیت زیادی دارد. استفاده از فرآیند پخش و تقویت خودپالایی رودخانه یکی از مهم‌ترین روش‌های مدیریت زیست‌محیطی رودخانه محسوب می‌شود. این قابلیت موجب کاهش خطر خسارت به محیط‌زیست در آینده و افزایش تأثیر مهندسی محیط‌زیست بر مدیریت منابع آب می‌شود. برای کنترل

حفاظت از رودخانه‌ها و پاک‌سازی آن‌ها به منظور کنترل کیفیت و حفاظت از منابع آب امری ضروری و غیرقابل اجتناب می‌باشد. این در حالی است که پساب‌های کشاورزی و فاضلاب صنعتی کارخانه‌های بزرگ به صورت بی‌رویه و بدون توجه به توانایی خودپالایی رودخانه‌ها به آن‌ها ریخته می‌شود. توانایی تخمین و

شکل جدی و تأثیرگذار توسط مک‌کلند و رومل هارت (1986) با ابداع و ارائه مدل پرسپترون بهبودیافته به جهان معرفی شد. این شیوه از ساختاری نرونی و هوشمند با الگوبرداری مناسب از نرون‌های موجود در مغز انسان سعی می‌کند تا از طریق توابع تعریف‌شده ریاضی رفتار درون‌سلولی نرون‌های مغز را شبیه‌سازی کند و از طریق وزن‌های محاسباتی موجود در خطوط ارتباطی نرون‌های مصنوعی، عملکرد سیناپسی را در نرون‌های طبیعی به مدل درآورد. ماهیت و ذات تجربی و منعطف این روش باعث می‌شود تا در مسائلی مانند پیش‌بینی پدیده‌هایی که دارای رفتار غیرخطی و پیچیده هستند به خوبی قابل‌استفاده باشد (روزن بلات 1962).

ضریب پخش طولی به‌عنوان اندازه‌ای از فرآیند پخش طولی یک بعدی توسط معادله انتقال پخش برای اولین بار توسط تیلور (1954) ارائه گردید. فیشر و همکاران (1979) برای نخستین بار بحث تأثیر پدیده انتشار بر پخش و کاهش غلظت پساب‌ها در رودخانه را مطرح نمودند. آن‌ها پدیده انتشار را مطابق شکل 1 سه مرحله در نظر گرفتند: در مرحله اول (حد فاصل نقاط A و B) مواد آلاینده از منبع آلاینده خارج شده و وارد جریان رودخانه می‌شود. در این مرحله اندازه حرکت اولیه و شناوری جریان دو عاملی هستند که باعث رقیق‌سازی پساب می‌گردند. مرحله دوم (حد فاصل نقاط B و C) درحالی‌که پساب‌ها در حال گسترش در عرض و رقیق شدن هستند اندازه حرکت اولیه و شناوری جریان به تدریج محو شده و در این مرحله آشفتگی و جریان‌های ثانویه ناشی از آن عامل فرآیند پخش و انتشار می‌گردند. مرحله سوم (نقطه C به بعد) هنگامی است که پساب‌های ورودی در عرض کانال به‌طور کامل انتشار پیدا کرده، برش‌های طولی جریان شروع به فعالیت می‌نماید. در پایان این مرحله غلظت در تمام سطح مقطع به یک مقدار ثابت رسیده و انتشار به‌طور کامل انجام می‌گیرد.

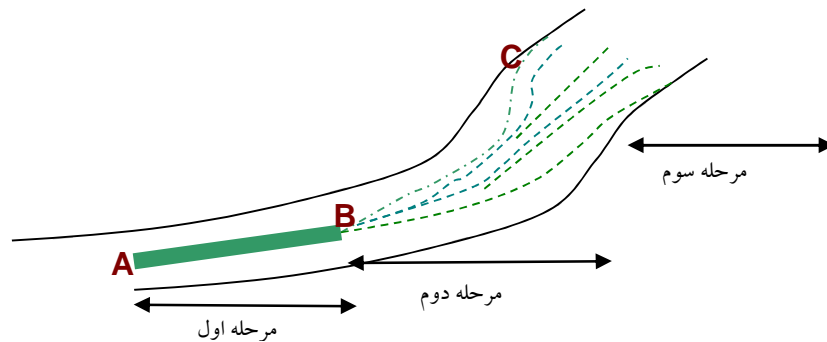
آلودگی در جریان‌های روباز، رهاسازی آلاینده‌ها باید به‌صورت منطقی و تنظیم‌شده انجام شود. این موضوع نیازمند اطلاع دقیق از توانایی حمل، پخش و پاک‌سازی آلودگی توسط جریان آب در طول مشخصی از مسیر خود است که آن را طول انتشار کامل¹ می‌نامند. در حقیقت طول انتشار کامل، مسافتی است که جریان در طول آن توانایی رقیق‌سازی و پخش کامل آلاینده را به‌صورت یکنواخت در سطح مقطع دارا است (پورآبادی و همکاران 1386).

انتقال آلاینده‌ها در جهت پایین‌دست توسط فرآیندهای پراکنش طولی، عرضی و عمقی انجام می‌گیرد. به‌طورکلی انتقال آلاینده‌ها در جهات طولی، عرضی و عمقی تحت تأثیر فرآیندهای انتقال و انتشار صورت گرفته و توسط ضرایب طولی، عرضی و قائم پخش K_x ، K_y ، K_z بیان می‌شود. پس از آن‌که انتشار در کل مقطع عرضی کامل شد، تنها انتشار طولی قابل‌توجه بوده و در نهایت سرنوشت انتقال آلاینده تابع انتشار طولی خواهد بود (ریاحی مدوار و ایوب‌زاده 1387).

اطلاع از مقادیر دقیق ضریب پخش طولی برای مسائل محیط زیستی رودخانه‌ها اهمیت ویژه‌ای دارد. اندازه‌گیری مستقیم این ضریب که در حقیقت با برداشت غلظت نمونه‌ها در بالادست و پایین‌دست مقاطع عرضی رودخانه به‌دست می‌آید به‌علت سختی کار به‌ندرت صورت گرفته و معمولاً با استفاده از روابط تجربی و نظری محاسبه می‌شود. یکی از روش‌های پیش‌بینی ضریب پخش طولی استفاده از روش‌های مدل‌سازی است. از جمله این روش‌ها، مدل‌سازی شبکه عصبی مصنوعی² است که از مؤلفه‌های هوش مصنوعی محسوب می‌شود. در این‌گونه مدل‌ها بدون در نظر گرفتن معادلات پیچیده غیرخطی، می‌توان رفتار حاکم بر سیستم را استخراج نموده و از این طریق، خروجی مدل را پیش‌بینی نمود. شبکه عصبی مصنوعی در علوم مهندسی برای اولین بار در سال 1962 توسط روزن بلات و در

2 - Artificial neural network (ANN)

1- Complete mixing length (CML)



شکل 1- نمای پخش آلودگی در رودخانه تحت سه مرحله متوالی.

یکی از روش‌های مدل‌سازی پیشرفته استفاده از شبکه عصبی مصنوعی است که امکان شبیه‌سازی سیستم‌های غیرخطی را دارا است.

مطالعات متنوعی در زمینه پیش‌بینی ضریب پخش طولی توسط شبکه عصبی مصنوعی صورت گرفته است. اکبرزاده و همکاران (1389) با انجام تحلیل عدم قطعیت مونت-کارلو در روش شبکه عصبی و نروفازی انطباقی اذعان داشتند میزان عدم قطعیت در روش شبکه عصبی بیش از نروفازی انطباقی است. تیفور و سینگ (2005)، توپراک و سیگزوگلو (2008) و ساهایی (2011) مقادیر K_x را با استفاده از شبکه عصبی مصنوعی پیش‌بینی کردند. تیفور و سینگ (2005) پنج مدل شبکه عصبی مصنوعی را توسعه دادند. آن‌ها اذعان داشتند متغیرهای ورودی در بهترین مدل شامل عمق میانگین جریان، عرض جریان، و سرعت متوسط جریان طولی است. آن‌ها در مطالعه خود سرعت برشی متوسط بستر و انحنای کانال را در نظر نگرفتند. توپراک و سیگزوگلو (2008) سه ساختار متفاوت شبکه عصبی مصنوعی را با در نظر گرفتن عرض جریان، سرعت متوسط جریان طولی، عمق میانگین جریان و سرعت برشی متوسط بستر به‌عنوان پارامترهای ورودی و با صرف‌نظر از انحنای کانال برای پیش‌بینی ضریب پخش طولی ارائه دادند. نتایج آن‌ها نشان داد روش پرسپترون پیش‌خور نتایج بهتری را در پیش‌بینی ضریب پخش طولی دارا است. ساهایی (2011)

طبق تحقیقات تیلور سرنوشت تزریق آلاینده، تابعی از K_x است که فیشر و همکاران (1979) عبارت انتگرال سه‌گانه زیر را برای تخمین آن ارائه نمودند:

$$K_x = - \frac{1}{A_0} \int_0^B \int_0^y \int_0^y \frac{1}{e_i h} \frac{\partial u}{\partial y} dy dy dy \quad [1]$$

که در آن K_x ضریب پراکندگی طولی، A سطح مقطع جریان، B عرض بالای سطح آب، h عمق موضعی جریان در هر نقطه عرضی، u میزان انحراف سرعت متوسط عمقی از سرعت متوسط مقطع، y مختصه عرضی که از ساحل سمت چپ اندازه‌گیری می‌شود و e_i ضریب پخش عرضی است. مقایسه اندازه‌گیری‌های واقعی با نتایج نظری نشان می‌دهد که در جریان یکنواخت متوسط خطای آن 30% و در جریان غیریکنواخت تا 4 برابر مقادیر واقعی نیز می‌رسد (تیلور 1954). ایزدی‌نیا و عابدی (1390) با استفاده از تحلیل ابعادی و روش رگرسیون‌گیری نشان دادند تأثیر ضریب زبری بر ضریب پخش طولی بیشتر از سایر پارامترها می‌باشد. بیشتر مطالعات صورت گرفته و معادلات تجربی ارائه‌شده تاکنون بر اساس فرضیات ساده‌کننده و برای شرایط خاص آزمایشگاهی یا اندازه‌گیری می‌باشد. بنابراین ارائه یک مدل جامع دربرگیرنده پارامترهای تأثیرگذار بر ضریب پخش طولی امری ضروری است.

تحلیل ابعادی، پارامترها بدون بعد گردید، سپس با استفاده از روش شبکه عصبی و با متغیر در نظر گرفتن تعداد نرون‌های لایه میانی و تابع انتقال، مدل مناسب تعیین شد. علاوه بر آن در این مطالعه با استفاده از تحلیل حساسیت صورت گرفته میزان تأثیرپذیری مدل از پارامترهای ورودی مورد ارزیابی قرار گرفت.

مواد و روش‌ها

با توجه به این‌که دقت شبکه عصبی مصنوعی به ورودی‌های مدل وابسته است. برای انتخاب ورودی‌های مدل باید دقت لازم صورت گیرد. بهره‌گیری از روش تحلیل ابعادی و ارائه متغیرهای بدون بعد این امکان را فراهم می‌سازد که با دقت بیشتری عوامل مؤثر بر رفتار و روابط حاکم بر ضریب پخش طولی بررسی گردد. در مطالعه حاضر، تحلیل ابعادی با استفاده از قضیه باکینگهام صورت گرفت. پارامترهای مؤثر بر ضریب پخش طولی (K_x) شامل سرعت متوسط جریان (u)، عمق جریان (h)، عرض آبراهه (w)، تنش برشی کف یا سرعت برش (u_*)، چگالی سیال (ρ) و لزجت دینامیکی جریان (μ) است. از آنجاکه جریان در رودخانه‌ها آشفته است ($Re \geq 70$) می‌توان از تأثیر گرانروی سیال صرف‌نظر نمود. رابطه حاصل از تحلیل ابعادی را می‌توان به صورت زیر خلاصه کرد:

$$K_x = f\left(\frac{u}{u_*}, \frac{W}{h}\right) \quad [2]$$

با توجه به این‌که فاکتور اصطکاک داریسی-ویسباخ (f) برابر با $8(u_*^2/u)$ است، بنابراین ضریب بدون بعد انتشار طولی تابعی از فاکتور اصطکاک و نسبت عرض به عمق هست (ایزدی‌نیا و عابدی 1390). در رابطه 2، فاکتور اصطکاک بیان‌گر برش‌های کف بوده که آن‌ها نیز تولیدکننده اغتشاش و آشفتگی در جریان هستند. همچنین نسبت عرض به عمق (نسبت ظرافت¹) می‌تواند

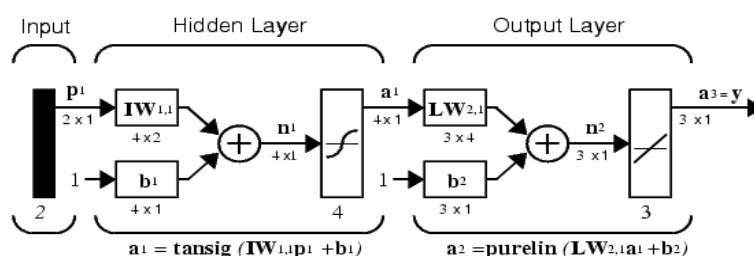
نشان داد که با در نظر گرفتن پارامترهای انحنای کانال و سرعت برشی متوسط بستر کارآیی مدل شبکه عصبی مصنوعی به‌طور قابل‌توجهی بهبود می‌یابد. نوری و همکاران (2011) با استفاده از معروف‌ترین توابع آموزشی روش شبکه عصبی مصنوعی، مقدار ضریب پخش طولی را در جریان‌های طبیعی پیش‌بینی کردند. نتایج نشان داد تابع آموزشی Levenberg-Marquardt به‌عنوان بهترین انتخاب برای آموزش پارامترهای شبکه هست. احسان (2013) با در نظر گرفتن یک پارامتر ورودی بدون بعد نشان‌دهنده مشخصات هیدرولیکی جریان، یک مدل سه لایه‌ای شبکه عصبی شامل 4، 6 و 1 نرون به‌ترتیب در لایه‌های اول، دوم و سوم ارائه نمود. توپراک و همکاران (2014) سه مدل را بر اساس روش‌های مختلف شبکه عصبی مصنوعی و فازی توسعه دادند تا ضریب بدون بعد پخش طولی در کانال‌ها را پیش‌بینی کنند. هدف دیگر مطالعه آن‌ها، ارزیابی مطالعات موجود بر پخش طولی بدون بعد و بعد دار بود. داده‌های آن‌ها از مطالعات گذشته برداشت شده از 30 رودخانه در زمان‌های مختلف در ایالات متحد تهیه شده است. نتایج آن‌ها با روابط ارائه شده در پیشینه پژوهش مقایسه گردید و نشان دادند که روش شبکه عصبی مصنوعی پیش‌رونده به جلو بهترین نتایج قابل‌اعتماد را ارائه می‌دهد.

از مرور تحقیقات صورت گرفته بر پیش‌بینی ضریب پخش طولی با استفاده از روش شبکه عصبی مشخص است این مدل‌ها به پارامترهای ورودی حساس بوده و نتایج خروجی مدل را نیز تحت تأثیر قرار می‌دهد. تاکنون مطالعه‌ای در برگیرنده میزان تأثیرگذاری پارامترهای ورودی بر ضریب پخش طولی صورت نگرفته است. همچنین در بیشتر مطالعات پارامترهای ورودی دارای بعد هست، این در حالی است که برای ارائه یک مدل جامع و قابل‌مقایسه با سایر مدل‌ها پارامترها باید بدون بعد باشند. در این تحقیق ابتدا با استفاده از

¹ - Aspect ratio

ورودی جهت اعمال ورودی‌های مسئله یک لایه پنهان و یک لایه خروجی که نهایتاً پاسخ‌های مسئله را ارائه می‌نمایند، استفاده می‌شود.

گره‌هایی که در لایه ورودی هستند، نرون‌های حسی² و گره‌های لایه خروجی، نرون‌های پاسخ‌دهنده³ هستند. در لایه پنهان نیز، نرون‌های پنهان⁴ وجود دارند. آموزش این‌گونه شبکه‌ها معمولاً با روش پس انتشار خطا⁵ انجام می‌شود. نمونه‌ای از یک شبکه پرسپترون چند لایه در زیر نمایش داده شده است (شکل 2).



شکل 2- ساختار پرسپترون چندلایه با نرون‌های پنهان tansig (شریفی و صالحی 1384).

در طول آموزش، یک نرون، داده‌ها را از لایه‌های قبل می‌گیرد، هر داده را با مقدار از پیش مرتب‌شده وزن می‌دهد و وزن داده‌های ورودی را با هم ترکیب می‌کند. اگر فعالیت یک نرون به اندازه کافی قدرتمند باشد، باعث تولید یک خروجی می‌شود که به عنوان ورودی به سایر نرون‌ها در لایه موفق فرستاده می‌شود. معمولاً تابع سیگموئید یا لجستیک (استدلالی) به عنوان تابع فعال در مرحله آموزش شبکه استفاده می‌شود. تابع استدلالی، در یک شبکه، نقشه‌ای برای هر رفتار غیرخطی فراهم می‌کند و پاسخ غیرخطی تهیه می‌کند.

در مطالعه حاضر با استفاده از اطلاعات جمع‌آوری‌شده در 29 رودخانه طبیعی ایالات متحده توسط فیشر (1968)، مک‌کیوی و کیفر (1974) و سیو و چنگ (1998) که در جدول 1 آورده شده و نرم‌افزار MATLAB، ضریب پخش طولی با استفاده از شبکه

معرف جریان‌های ثانویه در کانال روباز باشد (افضلی-مهر و حیدرپور 1380). در تحقیق حاضر از دو پارامتر بدون بعد فاکتور اصطکاک و نسبت عرض به عمق به عنوان ورودی‌های شبکه عصبی استفاده گردید.

در بسیاری از مسائل پیچیده ریاضی که به حل معادلات پیچیده غیرخطی منجر می‌شود، یک شبکه پرسپترون چندلایه می‌تواند به سادگی با تعریف اوزان و توابع مناسب مورد استفاده قرار گیرد. توابع فعالیت مختلفی به فراخور اسلوب مسئله در نرون‌ها مورد استفاده قرار می‌گیرد. در این نوع شبکه‌ها از یک لایه

شبکه‌های پرسپترون چند لایه می‌توانند با هر تعداد لایه ساخته و به کار گرفته شوند، ولی به طور معمول یک شبکه پرسپترون سه لایه قادر است هر نوع فضای را تفکیک کند، بنابراین در این تحقیق از یک شبکه سه لایه استفاده گردید. قبل از کاربرد شبکه عصبی مصنوعی برای هرگونه مسئله‌ای، شبکه ابتدا آموزش داده می‌شود. بدین صورت با تنظیم وزن از طریق آموزش الگوریتم، اختلاف بین خروجی و مدل محاسبه شده و به کمترین مقدار می‌رسد. آموزش شبکه عصبی مصنوعی شامل سه عنصر است: 1) وزن بین نرون‌ها که معرف اهمیت نسبی داده‌های ورودی است، 2) تابع انتقال که نسل خروجی از هر نرون را کنترل می‌کند و 3) قوانین یادگیری که توصیف‌کننده چگونگی تنظیمات وزن در طول آموزش است.

⁴ -Hidden

⁵ -Back propagation

² -Sensory

³ -Responding

75 درصد داده‌ها به‌عنوان مجموعه آموزشی و 25 درصد داده‌ها به‌عنوان مجموعه صحت‌سنجی مورد استفاده قرار گرفت. برای ارزیابی بهترین شبکه از پارامترهای آماری ضریب تعیین همبستگی R^2 ⁸ و ریشه نرمال میانگین مربع خطا NRMSE⁹ استفاده شد. دامنه تغییرات ضریب تعیین همبستگی بین صفر تا یک است که هرچه این ضریب به یک نزدیک‌تر باشد همبستگی دو پارامتر بیشتر است، این در حالی است که ریشه نرمال میانگین مربع خطا نیز بین صفر تا یک تغییر کرده و معمولاً به‌صورت درصد بیان می‌گردد و هر چه به صفر نزدیک‌تر باشد میزان خطا کمتر و دقت رابطه بیشتر است. در این تحقیق برای تعیین میزان تأثیر پارامترهای ورودی تحلیل حساسیت صورت گرفت. سپس با استفاده از تابع خطای NRMSE مقدار خطای نتایج محاسباتی و اندازه‌گیری تعیین گردید.

$$R^2 = \frac{[\sum_1^N (K_{meas} - \bar{K}_{meas})(K_{pred} - \bar{K}_{pred})]^2}{\sum_1^N (K_{meas} - \bar{K}_{meas})^2 (\sum_1^N (K_{pred} - \bar{K}_{pred})^2)} \quad [3]$$

$$NRMSE = \sqrt{\frac{\sum_1^N (K_{meas} - K_{pred})^2}{\sum_1^N (K_{meas} - \bar{K}_{meas})^2}} \quad [4]$$

که در آن K_{pred} و K_{meas} به ترتیب مقادیر اندازه‌گیری شده و محاسبه شده، \bar{K}_{pred} و \bar{K}_{meas} به ترتیب مربوط به متوسط مقادیر اندازه‌گیری شده و محاسبه شده ضریب پخش طولی آلودگی و N تعداد مقادیر اندازه‌گیری است.

نتایج و بحث

برآورد ضریب پراکنندگی طولی نیازمند داده‌های هیدرولیکی و هندسی است. در این تحقیق با جمع‌آوری مجموعه‌ای وسیع از داده‌های محققان پیشین که در آن‌ها مقادیر تمام پارامترهای مورد نیاز ارائه شده بود مورد استفاده قرار گرفت. لازم به ذکر است که برای مدل‌سازی ضریب پخش طولی، بازه یا سال

عصبی مصنوعی شبیه‌سازی گردید. فیشر (1968) در طی سال‌های 1961-1959 داده‌های خود را توسط ردیاب رادیواکتیو برداشت نمود. او یک روش جدید (روش مسیریابی)⁶ را پیشنهاد کرد. در این روش مقدار ضریب پخش در پایین‌دست رودخانه مورد مطالعه در مسیر ردیابی و با استفاده از داده بالادست تعیین می‌شود در صورتی که پیش‌بینی مناسب نباشد ضریب پخش تعدیل شده تا دقت آن افزایش یابد. سیو و چنگ (1998) نیز مقدار ضریب پخش را از داده‌های میدانی برداشت و با استفاده از روش مسیریابی محاسبه و ارائه کردند.

شبکه به‌کار گرفته شده یک شبکه پرسپترون چندلایه است که به‌صورت پیش‌خور⁷ عمل می‌کند و در سه لایه (یک لایه ورودی، یک لایه میانی و یک لایه خروجی) طراحی شده است. تعداد نرون‌های لایه ورودی با توجه به تعداد پارامترهای ورودی دو نرون هست و خروجی شامل یک نرون است که همان ضریب پخش طولی است. تعداد نرون‌های لایه میانی با سعی و خطا تعیین گردید و تعداد 10، 20، و 30 نرون مورد ارزیابی قرار گرفت. علاوه بر آن در این تحقیق از دو تابع تبدیل تانژانت سیگموئید و لگاریتم سیگموئید استفاده گردید. روش شبکه آموزش از نوع پس انتشار خطا هست.

در یک تحقیق شبکه عصبی مصنوعی داده‌ها معمولاً به دو قسمت تقسیم می‌شود. یک قسمت برای آموزش یا واسنجی کردن شبکه و قسمت دیگر برای صحت‌سنجی مورد استفاده قرار می‌گیرد. با توجه به اینکه شبکه‌های عصبی مصنوعی قادر به برون‌یابی در خارج از محدوده تعریف شده داده‌ها نیستند، زمانی که محدوده داده‌های صحت‌سنجی خارج از محدوده داده‌های آموزشی باشد شبکه نتایج خوبی نخواهد داشت. بنابراین بایستی مقادیر بیشینه و کمینه داده‌ها در مجموعه آموزشی قرار بگیرد. جدول 2 محدوده تغییرات پارامترها را نشان می‌دهد. در این تحقیق حدود

³- Correlation of determination

⁴-Normal root mean square error (NRMSE)

⁶ - Routing method

⁷ -Feed forward

آموزش قرار گرفت. با توجه به غیرخطی بودن تغییرات ضریب پخش نسبت به پارامترهای ورودی، در این تحقیق از دو تابع انتقال غیرخطی متداول تانژانت سیگموئید و لگاریتم سیگموئید استفاده گردید. از آنجاکه تعداد نرون‌های لایه پنهان به‌طور تجربی و با سعی و خطا به‌دست می‌آید سه مقدار متفاوت 10، 20، و 30 نرون مورد ارزیابی قرار گرفت. خلاصه نتایج در جدول 3 آورده شده است.

نمونه‌برداری جزء پارامترهای موردنیاز نبوده و تمام اطلاعات ثبت‌شده از رودخانه‌ها طی سالیان گذشته در مقالات مختلف فاقد این اطلاعات بوده‌اند و تنها به ارائه اطلاعات ورودی ذکر شده و خروجی (ضریب پخش طولی) در کنار نام رودخانه بسنده کرده‌اند. در این تحقیق نیز از اطلاعات موجود عرض، عمق، سرعت و سرعت برشی جریان استفاده شد (اکبرزاده و همکاران 1389).

داده‌های به‌دست‌آمده با استفاده از شبکه عصبی مصنوعی پیش‌خور پس‌انتشار خطا با سه لایه مورد

جدول 1- داده‌های استفاده‌شده در تحقیق.

| منبع | رودخانه | h (m) | w (m) | u (m s ⁻¹) | u* (m s ⁻¹) | K _x (m ² s ⁻¹) |
|------------------------|------------------|--------|-------|------------------------|-------------------------|--|
| فیشر (1968) | Copper creek, VA | ۰/۴۹ | ۱۵/۹۰ | ۰/۲۱ | ۰/۰۷ | ۱۹/۵۲ |
| | | ۰/۸۴ | ۱۸/۳۰ | ۰/۵۲ | ۰/۱۰ | ۱۲/۴۰ |
| | | ۰/۴۹ | ۱۶/۲۰ | ۰/۲۵ | ۰/۰۷ | ۹/۵۰ |
| | Clinch river, TN | ۰/۸۶ | ۴۶/۹۰ | ۰/۲۸ | ۰/۰۶ | ۱۳/۹۳ |
| | | ۲/۱۳ | ۵۹/۴۰ | ۰/۸۶ | ۰/۱۰ | ۵۳/۸۸ |
| | | ۲/۰۹ | ۵۳/۳۰ | ۰/۷۹ | ۰/۱۰ | ۴۶/۴۵ |
| | | ۰/۳۹ | ۱۸/۶۰ | ۰/۱۴ | ۰/۱۱ | ۹/۸۵ |
| | Copper creek, VA | ۰/۸۵ | ۳۳/۸۰ | ۰/۱۶ | ۰/۰۵ | ۹/۵۰ |
| | | ۰/۵۸ | ۳۶/۰۰ | ۰/۳۰ | ۰/۰۴ | ۸/۰۸ |
| | | ۱/۵۶ | ۲۴/۴۰ | ۰/۶۷ | ۰/۰۴ | ۹/۵۷ |
| مک‌کیوی و کیفیر (1974) | Bayou Anacoco | ۰/۹۴ | ۲۵/۹۰ | ۰/۳۴ | ۰/۰۶ | ۳۲/۵۲ |
| | | ۰/۹۱ | ۳۶/۶۰ | ۰/۴۰ | ۰/۰۶ | ۳۹/۴۸ |
| | Nooksack river | ۰/۴۱ | ۱۹/۸۰ | ۰/۲۹ | ۰/۰۴ | ۱۳/۹۴ |
| | | ۰/۷۶ | ۶۴/۰۰ | ۰/۶۷ | ۰/۰۲ | ۳۴/۸۴ |
| | | ۲/۹۴ | ۸۶/۰۰ | ۱/۲۰ | ۰/۵۱ | ۱۵۳/۲۹ |
| | Antietam creek | ۰/۳۹ | ۱۵/۸۰ | ۰/۳۲ | ۰/۰۶ | ۹/۲۹ |
| | | ۰/۵۲ | ۹۰/۸۰ | ۰/۴۳ | ۰/۰۶ | ۱۶/۲۶ |
| | Monocacyriver | ۰/۷۱ | ۲۴/۴۰ | ۰/۵۲ | ۰/۰۸ | ۲۵/۵۵ |
| | | ۰/۳۲ | ۳۵/۱۰ | ۰/۲۱ | ۰/۰۴ | ۴/۶۵ |
| | | ۰/۴۵ | ۳۶/۶۰ | ۰/۳۲ | ۰/۰۵ | ۱۳/۹۴ |
| Missouri river | ۰/۸۷ | ۴۷/۵۰ | ۰/۴۴ | ۰/۰۷ | ۳۷/۱۶ | |
| | ۲/۲۳ | ۱۸۲/۹۰ | ۰/۹۳ | ۰/۰۶ | ۴۶۴/۵۲ | |
| | ۳/۵۶ | ۲۰۱/۲۰ | ۱/۲۷ | ۰/۰۸ | ۸۳۶/۱۳ | |
| Wind/Bighorn rivers | ۳/۱۱ | ۱۹۶/۶۰ | ۱/۵۳ | ۰/۰۷ | ۸۹۱/۸۷ | |
| | ۰/۹۸ | ۶۷/۱۰ | ۰/۸۸ | ۰/۱۱ | ۴۱/۸۱ | |
| | ۲/۱۶ | ۶۸/۶۰ | ۱/۵۵ | ۰/۱۶ | ۱۶۲/۵۸ | |
| Elkhorn river | ۰/۳۰ | ۳۲/۶۰ | ۰/۴۳ | ۰/۰۴ | ۹/۲۹ | |
| | ۰/۴۲ | ۵۰/۹۰ | ۰/۴۶ | ۰/۰۴ | ۲۰/۹۰ | |
| John Dayriver | ۰/۵۶ | ۲۵/۰۰ | ۱/۰۱ | ۰/۱۳ | ۱۳/۹۴ | |
| | ۲/۴۶ | ۳۴/۱۰ | ۰/۸۲ | ۰/۱۶ | ۶۵/۰۳ | |
| Comite river | ۰/۲۶ | ۱۲/۵۰ | ۰/۳۱ | ۰/۰۴ | ۶/۹۷ | |
| | ۰/۴۱ | ۵۰/۸۰ | ۰/۳۷ | ۰/۰۵ | ۱۳/۹۴ | |
| Amite river | ۰/۸۱ | ۳۶/۶۰ | ۰/۲۹ | ۰/۰۶ | ۲۳/۲۳ | |

| | | | | | |
|-------------------------|-------|--------|------|------|----------|
| | ۰/۸۰ | ۴۲/۴۰ | ۰/۴۲ | ۰/۰۶ | ۳۰/۱۹ |
| Sabine river | ۲/۰۴ | ۱۰۳/۶۰ | ۰/۵۶ | ۰/۰۵ | ۳۱۵/۸۷ |
| | ۴/۷۵ | ۱۲۷/۴۰ | ۰/۶۴ | ۰/۰۸ | ۶۶۸/۹۰ |
| Yadkin river | ۲/۳۵ | ۷۰/۱۰ | ۰/۴۳ | ۰/۱۰ | ۱۱۱/۴۸ |
| | ۳/۸۴ | ۷۱/۶۰ | ۰/۷۶ | ۰/۱۲ | ۲۶۰/۱۳ |
| Muddycreek | ۰/۸۱ | ۱۳/۴۰ | ۰/۳۷ | ۰/۰۷ | ۱۳/۹۴ |
| | ۱/۲۰ | ۱۹/۵۰ | ۰/۴۵ | ۰/۰۹ | ۳۲/۵۲ |
| Sabine river, Texas | ۰/۹۸ | ۳۵/۱۰ | ۰/۲۱ | ۰/۰۴ | ۳۹/۴۸ |
| White river | ۰/۵۵ | ۶۷/۱۰ | ۰/۳۵ | ۰/۰۴ | ۳۰/۱۹ |
| Chattahoochee river | ۱/۱۳ | ۶۵/۵۰ | ۰/۳۹ | ۰/۰۷ | ۳۲/۵۲ |
| Susquehanna river | ۱/۳۵ | ۲۰۲/۷۰ | ۰/۳۹ | ۰/۰۶ | ۹۲/۹۰ |
| سیو و چنگ (1998) | ۰/۹۸ | ۲۴/۱۰ | ۰/۵۹ | ۰/۰۹ | ۱۰۱/۵۰ |
| | ۰/۶۶ | ۱۱/۹۰ | ۰/۴۳ | ۰/۰۸ | ۲۰/۹۰ |
| Monocacyriver, MD | ۰/۷۱ | ۹۳/۰۰ | ۰/۱۶ | ۰/۰۴ | ۴۱/۴۰ |
| | ۰/۶۵ | ۵۱/۲۰ | ۰/۶۲ | ۰/۰۴ | ۲۹/۶۰ |
| | ۱/۱۵ | ۹۷/۵۰ | ۰/۳۲ | ۰/۰۵ | ۱۱۹/۸۰ |
| | ۰/۴۱ | ۴۰/۵۰ | ۰/۲۳ | ۰/۰۴ | ۶۶/۵۰ |
| Conococheague creek, MD | ۰/۶۹ | ۴۲/۲۰ | ۰/۲۳ | ۰/۰۶ | ۴۰/۸۰ |
| | ۰/۴۱ | ۴۹/۷۰ | ۰/۱۵ | ۰/۰۸ | ۲۹/۳۰ |
| | ۱/۱۳ | ۴۳/۰۰ | ۰/۶۳ | ۰/۰۸ | ۵۳/۳۰ |
| Chattahoochee river, GA | ۱/۹۵ | ۷۵/۶۰ | ۰/۷۴ | ۰/۱۳ | ۸۸/۹۰ |
| | ۲/۴۴ | ۹۱/۹۰ | ۰/۵۲ | ۰/۰۹ | ۱۶۶/۹۰ |
| Salt creek, NE | ۰/۵۰ | ۳۲/۰۰ | ۰/۲۴ | ۰/۰۳ | ۵۲/۲۰ |
| Difficult run, VA | ۰/۳۱ | ۱۴/۵۰ | ۰/۲۵ | ۰/۰۶ | ۱/۹۰ |
| Bear creek, CO | ۰/۸۵ | ۱۳/۷۰ | ۱/۲۹ | ۰/۵۵ | ۲/۹۰ |
| Little Pincycreek, MD | ۰/۲۲ | ۱۵/۹۰ | ۰/۳۹ | ۰/۰۵ | ۷/۱۰ |
| Bayou Anacoco, LA | ۰/۴۵ | ۱۷/۵۰ | ۰/۳۲ | ۰/۰۲ | ۵/۸۰ |
| Bayou Bartholomew, LA | ۱/۴۰ | ۳۳/۴۰ | ۰/۲۰ | ۰/۰۳ | ۵۴/۷۰ |
| Amite river, LA | ۰/۵۲ | ۲۱/۳۰ | ۰/۵۴ | ۰/۰۲ | ۵۰۱/۴۰ a |
| Tickfau river, LA | ۰/۵۹ | ۱۴/۹۰ | ۰/۲۷ | ۰/۰۸ | ۱۰/۳۰ |
| Tangipahoa river, LA | ۰/۸۱ | ۳۱/۴۰ | ۰/۴۸ | ۰/۰۷ | ۴۵/۱۰ |
| | ۰/۴۰ | ۲۹/۹۰ | ۰/۳۴ | ۰/۰۲ | ۴۴/۰۰ |
| Red river, LA | ۱/۶۲ | ۲۵۳/۶۰ | ۰/۶۱ | ۰/۰۳ | ۱۴۳/۸۰ |
| | ۳/۹۶ | ۱۶۱/۵۰ | ۰/۲۹ | ۰/۰۶ | ۱۳۰/۵۰ |
| | ۳/۶۶ | ۱۵۲/۴۰ | ۰/۴۵ | ۰/۰۵ | ۲۲۷/۶۰ |
| | ۱/۷۴ | ۱۵۵/۱۰ | ۰/۴۷ | ۰/۰۳ | ۱۷۷/۷۰ |
| Sabine river, LA | ۱/۶۵ | ۱۱۶/۴۰ | ۰/۵۸ | ۰/۰۵ | ۱۳۱/۳۰ |
| | ۲/۳۲ | ۱۶۰/۳۰ | ۱/۰۶ | ۰/۰۵ | ۳۰۸/۹۰ |
| Sabine river, TX | ۰/۵۰ | ۱۴/۲۰ | ۰/۱۳ | ۰/۰۳ | ۱۲/۸۰ |
| | ۰/۵۱ | ۱۲/۲۰ | ۰/۲۳ | ۰/۰۳ | ۱۴/۷۰ |
| | ۰/۹۳ | ۲۱/۳۰ | ۰/۳۶ | ۰/۰۳ | ۲۴/۲۰ |
| Mississippi river, LA | ۱۹/۹۴ | ۷۱۱/۲۰ | ۰/۵۶ | ۰/۰۴ | ۲۳۷/۲۰ a |
| Mississippi river, MO | ۴/۹۴ | ۵۳۳/۴۰ | ۱/۰۵ | ۰/۰۶ | ۴۵۷/۷۰ |
| | ۸/۹۰ | ۵۳۷/۴۰ | ۱/۵۱ | ۰/۰۹ | ۳۴۱/۱۰ a |
| Wind/Bighorn river, WY | ۱/۳۷ | ۴۴/۲۰ | ۰/۹۹ | ۰/۱۴ | ۱۸۴/۶۰ |
| | ۲/۳۸ | ۸۵/۳۰ | ۱/۷۴ | ۰/۱۵ | ۴۶۴/۶۰ |
| Clinch river, VA | ۱/۱۶ | ۴۸/۵۰ | ۰/۲۱ | ۰/۰۶ | ۱۴/۷۶ |
| Missouri river | ۳/۲۸ | ۱۸۰/۶۰ | ۱/۶۲ | ۰/۰۷ | ۱۴۸۶/۴۵ |

جدول 2- محدوده تغییرات داده‌های استفاده‌شده در تحقیق.

| پارامتر | کمینه | بیشینه |
|--------------------------------|-------|---------|
| سرعت جریان ($m s^{-1}$) | 0/13 | 1/74 |
| عمق جریان (m) | 0/22 | 19/94 |
| عرض جریان (m) | 11/9 | 711/2 |
| سرعت برشی ($m s^{-1}$) | 0/02 | 0/553 |
| ضریب پخش طولی ($m^2 s^{-1}$) | 1/9 | 1486/45 |

مشخص می‌گردد $(\frac{u}{u_*})$ نسبت به $(\frac{w}{h})$ دارای تأثیر بیشتری هست. همان‌گونه که بیان شد نسبت $(\frac{u}{u_*})$ نشان‌دهنده فاکتور اصطکاک یا برش‌های کف بوده که تولیدکننده اغتشاش و آشفتگی در جریان هستند. بنابراین می‌توان اذعان داشت آنچه در یک فرآیند انتشار آلودگی اهمیت بیشتری دارد وجود زبری‌ها در بستر است. به عبارت دیگر با افزایش زبری‌های بستر می‌توان اغتشاشات و جریان‌های ثانویه را افزایش داد و باعث کاهش طول انتشار آلاینده‌ها در طول رودخانه‌ها گردید. با توجه به جدول 3، ANN₅ با پارامتر ورودی $(\frac{u}{u_*})$ نسبت به سایر شبکه‌ها، دارای ضریب تعیین همبستگی بالاتر و تابع خطای کمتری است. با این وجود در شبکه ANN₆ با پارامتر ورودی $(\frac{w}{h})$ مقدار ضریب تعیین همبستگی بالا است و نمی‌توان از تأثیر $(\frac{w}{h})$ صرف‌نظر نمود. بنابراین شبکه ANN₂ با دو پارامتر ورودی که دارای ضریب تعیین همبستگی قابل قبول 0/78 و مقدار تابع خطای 0/94 درصد هست به‌عنوان بهترین شبکه پیشنهاد می‌گردد. لازم به ذکر است با توجه به دقت بالای شبکه ANN₅، در صورتی که تنها پارامتر ورودی $(\frac{u}{u_*})$ موجود باشد می‌توان جهت تخمین ضریب پخش طولی از این مدل استفاده نمود.

جهت بررسی و آزمون اعتبار شبکه‌ها، از ضریب تعیین همبستگی (R^2) و تابع خطا NRMSE استفاده گردید. هرچه ضریب تعیین همبستگی بزرگ‌تر و تابع خطا دارای مقدار کمتری باشد دقت مدل در پیش‌بینی بیشتر است. از مقایسه تعداد نرون‌های لایه مخفی، با توجه به جدول 3 مشخص است که شبکه عصبی با 20 نرون در لایه میانی (ANN₂) نتایج بهتری را نشان می‌دهد به طوری که دارای ضریب تعیین همبستگی 0/78 و مقدار تابع خطای 0/94 درصد است. با کاربرد دو تابع انتقال تانژانت سیگموئید و لگاریتم سیگموئید به ترتیب در دو شبکه ANN₂ و ANN₄ مشخص گردید رفتار ضریب پخش طولی بر اساس تابع انتقال تانژانت سیگموئید بهتر پیش‌بینی می‌گردد.


به منظور بررسی تأثیر هر یک از پارامترهای ورودی بر ضریب پخش طولی، هر یک از پارامترهای ورودی به صورت مجزا در شبکه‌های ANN₅ و ANN₆ هر یک با تعداد 20 نرون در لایه پنهان و تابع انتقال تانژانت سیگموئید مورد ارزیابی قرار گرفت. با توجه به آن که در شبکه ANN₅ با پارامتر ورودی $(\frac{u}{u_*})$ مقدار ضریب تعیین همبستگی و مقدار تابع خطا به ترتیب برابر با 0/84 و 0/87 درصد و در شبکه ANN₆ با پارامتر ورودی $(\frac{w}{h})$ ، مقدار ضریب تعیین همبستگی و مقدار تابع خطا برابر با 0/7 و 1/01 درصد است


جدول 3- خلاصه نتایج با استفاده از تحلیل شبکه عصبی.

| نام شبکه | تعداد نرون لایه میانی | تابع انتقال | پارامترهای ورودی | ضریب تعیین همبستگی | (%) NRMSE |
|------------------|-----------------------|-------------|--------------------------------|--------------------|-----------|
| ANN ₁ | ۱۰ | TANSIG | $(\frac{u}{u_s}, \frac{W}{h})$ | ۰/۲۷ | ۱/۰۷ |
| ANN ₂ | ۲۰ | TANSIG | $(\frac{u}{u_s}, \frac{W}{h})$ | ۰/۷۸ | ۰/۹۴ |
| ANN ₃ | ۳۰ | TANSIG | $(\frac{u}{u_s}, \frac{W}{h})$ | ۰/۳۰ | ۱/۱۰ |
| ANN ₄ | ۲۰ | LOGSIG | $(\frac{u}{u_s}, \frac{W}{h})$ | ۰/۵۳ | ۲/۰۳ |
| ANN ₅ | ۲۰ | TANSIG | $(\frac{u}{u_s})$ | ۰/۸۴ | ۰/۸۷ |
| ANN ₆ | ۲۰ | TANSIG | $(\frac{W}{h})$ | ۰/۷۰ | ۱/۰۱ |

طولی نرمال شده در مرحله صحت‌سنجی با استفاده از شبکه عصبی مصنوعی ANN₂ را نشان می‌دهد. خط 45 درجه جهت نشان دادن تخمین کمتر یا بیشتر از مقدار واقعی کشیده شده است. با توجه به شکل مشخص است روش شبکه عصبی اندکی ضریب پخش طولی را بیشتر تخمین می‌زند.

شکل 3 نشان‌دهنده عملکرد شبکه عصبی ANN₂ در مرحله صحت‌سنجی هست. همان‌گونه که مشخص است مدل به خوبی و با دقت مطلوب توانسته است الگوی حاکم بر انتقال آلودگی و ضریب پراکندگی طولی را درک نموده و آن را برآورد نماید. شکل 4 مقادیر اندازه‌گیری شده و تخمین زده‌شده ضریب پراکندگی

شکل 3- عملکرد شبکه عصبی ANN₂ در مرحله صحت‌سنجی مدل.



شکل 4- مقایسه مقادیر اندازه‌گیری شده و تخمین زده‌شده ضریب پخش طولی با استفاده از مدل ANN₂.

از اندازه‌گیری است و مقادیر بیشتر تخمین زده شده‌اند. در صورتی که DR منفی باشد نشان‌دهنده کمتر تخمین زدن مقادیر هست. با توجه به جدول 4 مدل سیو و چیونگ (1998)، کاشفی‌پور و فالكونر (2002)، ساهایی و دتا (2009) و شبکه عصبی از دقت مناسبی برخوردار هستند. در مدل کاشفی‌پور و فالكونر (2002) نسبت سرعت به سرعت برشی به‌عنوان پارامتر ورودی در نظر گرفته شده و در مدل‌های سیو و چیونگ (1998) و ساهایی و دتا (2009) هر دو پارامتر مؤثر نسبت سرعت به سرعت برشی و نسبت عرض به عمق در نظر گرفته شده است. دقت بالای مدل کاشفی‌پور و فالكونر (2002) به‌علت صرف‌نظر کردن از نسبت عرض به عمق است. در حقیقت این دقت بالا مشابه نتایج تحقیق حاضر با در نظر گرفتن نسبت سرعت به سرعت برشی به‌عنوان تنها پارامتر ورودی در شبکه عصبی ANN₅ (جدول 3) هست. این در حالی است که با توجه به ضریب بالای تعیین همبستگی بین ضریب پخش طولی و نسبت عرض به عمق نمی‌توان از این پارامتر صرف‌نظر نمود. دقت کم رابطه آوسا و ایا

به‌منظور بررسی میزان دقت و اعتبار شبکه عصبی نتایج حاصل از مدل ANN₂ با دو پارامتر ورودی نسبت سرعت به سرعت برشی و نسبت عرض به عمق با استفاده از داده‌های مرحله صحت‌سنجی با مدل‌های ارائه شده توسط ليو (1977)، فیشر و همکاران (1979)، آوسا و ایا (1991)، سیو و چیونگ (1998)، کاشفی‌پور و فالكونر (2002) و ساهایی و دتا (2009) مورد ارزیابی قرار گرفت. پارامترهای آماری که برای مقایسه نتایج مورد استفاده قرار گرفت عبارت‌اند از ریشه میانگین مربع خطا RMSE¹²، نسبت توافق DR¹³ و ضریب همبستگی R¹⁴ که جذر ضریب تعیین همبستگی هست و در محدوده -1 تا 1 تغییر می‌کند.

$$RMSE = \sqrt{\frac{\sum (K_{pred} - K_{meas})^2}{N}} \quad [5]$$

$$DR = \log \frac{K_{pred}}{K_{meas}} \quad [6]$$

نسبت توافق نشان‌دهنده تطابق بین مقادیر اندازه‌گیری شده و تخمین زده‌شده را نشان می‌دهد. در صورتی که DR مثبت باشد مقادیر پیش‌بینی شده بیش

14- Correlation coefficient (R)

12- Root mean square error (RMSE)

13- Discrepancy ratio (DR)

نشان می‌دهد تأثیرگذاری این پارامتر کمتر از نسبت سرعت به سرعت برشی یا ضریب زبری است.

(1991) نشان می‌دهد که در نظر گرفتن نسبت عرض به عمق به‌عنوان تنها پارامتر ورودی مناسب نبوده و

جدول 4- مقایسه نتایج شبکه عصبی با مدل‌های سایر محققان.

| منبع | رابطه | RMSE (m ² s ⁻¹) | R | R ² | DR |
|----------------------------|---|---|------|----------------|------------|
| لیو (1977) | $K_x = \alpha \frac{u^2 W^2}{hu_*}$ $\alpha = 0.18 \left(\frac{u_*}{u}\right)^{1.5}$ | 207/93 | 0/71 | 0/51 | -0/76.1/07 |
| فیشر و همکاران (1979) | $K_x = 0.011 \frac{u^2 W^2}{hu_*}$ | 844/07 | 0/94 | 0/89 | -0/63.0/92 |
| آوسا وایا (1991) | $K_x = 2hu_* \left(\frac{W}{h}\right)^{1.5}$ | 224/82 | 0/46 | 0/21 | -1/03.0/95 |
| سیو و چیونگ (1998) | $K_x = 5.915hu_* \left(\frac{W}{h}\right)^{0.62} \left(\frac{u}{u_*}\right)^{1.428}$ | 125/42 | 0/98 | 0/96 | -0/20.0/77 |
| کاشفی‌پور و فالکونر (2002) | $K_x = 10.612hu \left(\frac{u}{u_*}\right)$ | 65/22 | 0/96 | 0/93 | -0/44.0/50 |
| سাহایی و دتا (2009) | $K_x = 2hu_* \left(\frac{W}{h}\right)^{0.96} \left(\frac{u}{u_*}\right)^{1.25}$ | 71/09 | 0/97 | 0/95 | -0/38.0/70 |
| شبکه عصبی ANN ₂ | - | 107/77 | 0/91 | 0/83 | -0/28.0/75 |

از روش شبکه عصبی مصنوعی پرسپترون پیش‌خور پس‌انتشار خطا استفاده گردید. با توجه به آنکه شبکه عصبی به پارامترهای ورودی حساس هست با استفاده از تحلیل ابعادی پارامترهای مؤثر بر ضریب انتشار تعیین گردید و به‌عنوان پارامتر ورودی به مدل داده شد. سپس با استفاده از فرآیند سعی و خطا تعداد نرون‌های لایه میانی و تابع انتقال تعیین گردید. نتایج نشان داد شبکه عصبی با 20 نرون در لایه میانی و تابع انتقال غیرخطی تانژانت سیگموئید از دقت مناسبی برای تخمین ضریب پخش طولی آلودگی برخوردار است. از تحلیل حساسیت صورت گرفته مشخص شد تأثیر زبری‌های موجود در بستر رودخانه بیشتر از نسبت عرض به عمق هست. بنابراین می‌توان اذعان نمود با ایجاد زبری‌های مصنوعی در بستر رودخانه‌ها می‌توان قدرت خودپالایی رودخانه‌ها را افزایش داد.

در جدول 4 بازه تغییرات نسبت توافق آورده شده است، توزیع تغییرات DR نشان داد مدل کاشفی‌پور و فالکونر (2002) در بسیاری از موارد ضریب پخش طولی را کمتر از مقدار واقعی تخمین می‌زند این در حالی است که مدل سیو و چیونگ (1998)، ساهایی و دتا (2009) و شبکه عصبی در بیشتر موارد مقادیر را بیش از مقدار اندازه‌گیری تخمین زده که در جهت اطمینان در مرحله طراحی است. بنابراین مدل شبکه عصبی با دو پارامتر ورودی از دقت مناسبی مانند روابط سیو و چیونگ (1998) و ساهایی و دتا (2009) برخوردار است.

نتیجه‌گیری کلی

تکنیک شبکه‌های عصبی مصنوعی در مسائل پیچیده غیرخطی کاربرد موفقیت‌آمیزی دارند. در این تحقیق برای تخمین ضریب پخش طولی در رودخانه‌ها

منابع مورد استفاده

- افضلی‌مهرح و حیدرپور م، 1380. مبانی هیدرودینامیک کانال‌های باز. انتشارات ارکان.
- اکبرزاده ع، نوری ر، فرخ‌نیا ا، خاکپور ا و صباحی م، 1389. تحلیل دقت و عدم قطعیت مدل‌های هوشمند در پیش‌بینی ضریب انتشار طولی رودخانه‌ها. مجله آب و فاضلاب، شماره 3، صفحه‌های 99 تا 107.
- ایزدی‌نیا ا و عابدی ج، 1390. تعیین ضریب پراکندگی طولی آلودگی در رودخانه‌ها. مجله تحقیقات منابع آب ایران، سال 7، شماره 1، صفحه‌های 59 تا 66.
- پورآبادی‌ای م، تکلدانی م، و لیاقت ع، 1386. بررسی تأثیر پارامترهای جریان بر ضریب پخش آلودگی در کانال مستطیلی. صفحه‌های 29 تا 38 مجموعه مقالات ششمین کنفرانس هیدرولیک ایران، شهریورماه، شهرکرد.
- ریاحی مدوار ح، و ایوب‌زاده ع، 1387. تخمین ضریب پراکندگی طولی آلودگی با استفاده از سیستم استنتاج فازی-عصبی انطباقی. مجله آب و فاضلاب، شماره 67، صفحه‌های 34 تا 46.
- شریفی م و صالحی م، 1384. کاربرد شبکه‌های عصبی در پیش‌بینی جریان رودخانه در حوزه معرف کارده. پروژه تحقیقاتی شرکت سهامی مدیریت منابع آب ایران.
- Ahsan N, 2013. An ANN based approach to estimate longitudinal dispersion coefficient using dimensionally consistent input parameters. *Res and Dev (IJCSEIERD)* 3(2): 205-212.
- Fischer HB, 1968. Dispersion predictions in natural streams. *J Sanit Eng ASCE* 94: 927-43.
- Fischer HB, List EJ, Koh RY, Imberger J, and Brooks NH, 1979. *Mixing in Inland and Coastal Waters*. Academic Press, New York: 104-138.
- Iwasa Y and Aya S, 1991. Predicting longitudinal dispersion coefficient in open channel flows. Pp. 505-510. In: *Proceedings of the international symposium on environmental hydraulics, Hong Kong*.
- Kashefipour MS and Falconer RA, 2002. Longitudinal dispersion coefficients in natural channels. *Water Resour Res* 36(6):1596-1608.
- Liu H, 1977. Predicting dispersion coefficient of streams. *J Environ Eng Div* 103(1): 59-69.
- McClelland J, and Rumelhart D, 1986. *Biol Mech* 327-331.
- McQuivey RS and Keefer TN, 1974. Simple method for predicting dispersion in streams. *J Environ Eng ASCE* 100: 997-1011.
- Noori R, Karbassi AR, Mehdizadeh H, Vesali-Naseh M and Sabahi MS, 2011. A framework development for predicting the longitudinal dispersion coefficient in natural streams using an artificial neural network. *Environ Prog and Sus Ener* 30(3): 439-449.
- Rosenblatt F, 1962. *Principles of Neurodynamics*. Spartan Books, New York.
- Sahay RR and Dutta S, 2009. Prediction of longitudinal dispersion coefficients in natural rivers using genetic algorithm. *Hydraul Res* 40(6): 544-552.
- Sahay RR, 2011. Prediction of longitudinal dispersion coefficients in natural rivers using artificial neural network. *Environ Fluid Mech* 11: 247-261
- Seo IW and Cheong TS, 1998. Predicting longitudinal dispersion coefficient in natural streams. *J Hydraul Eng. ASCE* 124(1): 25-32.
- Tayfur G and Singh VP, 2005. Predicting longitudinal dispersion coefficient in natural streams by artificial neural network. *J Hydraul Eng ASCE*, 131(11): 991-1000.
- Taylor G, 1954. The dispersion of matter in turbulent flow through a pipe. *Proc R Soc London A223*: 446-68.
- Toprak ZF and Cigizoglu HK, 2008. Predicting longitudinal dispersion coefficient in natural streams by artificial intelligence methods. *Hydrol Process* 22(20): 4106-4129.
- Toprak ZF, Hamidi N, Kisi O and Gerger R, 2014. Modeling dimensionless longitudinal dispersion coefficient in natural streams using artificial intelligence methods. *KSCE J Civil Eng*. 18(2): 718-730.