

پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی با مدل توسعه یافته شبکه عصبی

حمید مهدیزاده^۲

عبدالرضا کرباسی^۱

روح‌اله نوری^۱

(دریافت ۸۸/۳/۳۰ پذیرش ۸۸/۱۱/۱۴)

چکیده

هدف اصلی این مقاله پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی با استفاده از مدل توسعه داده شده شبکه عصبی مصنوعی بر مبنای توابع آموزش شبه-نیوتنی بود. به این منظور از اطلاعات هیدرولیکی و هندسه جریان استفاده گردید. مجموع کل اطلاعات مورد استفاده در این تحقیق، ۱۰۰ سری داده بود که به سه دسته آموزش، دسته نظارت بر آموزش و دسته آزمایش تقسیم شد. در این تحقیق، ابتدا با دیدی انتقادی به مرور برخی از مهم‌ترین تحقیقات انجام گرفته در این زمینه پرداخته شد که نتیجه آن نمایان ساختن اشکالات موجود در برخی از این مطالعات بود. در گام بعدی به منظور ارائه مدلی که قادر به مدل‌سازی ضریب انتشار طولی در رودخانه‌های طبیعی باشد، رویکردی جدید از شبکه عصبی بر مبنای توابع آموزش شبه-نیوتنی که کمتر مورد توجه محققان بوده، معرفی شد. در نهایت نیز با بررسی نقش این دسته از توابع آموزش بر عملکرد شبکه، بهترین ساختار شبکه برای این منظور پیشنهاد گردید. نتایج به‌دست آمده از این تحقیق بیانگر دقت قابل قبول مدل پیشنهادی بود به طوری که مقادیر ضریب تعیین و میانگین قدرمطلق خطا برای مرحله آزمایش به ترتیب معادل ۰/۸۵ و ۵۳ بود.

واژه‌های کلیدی: ضریب انتشار طولی، شبکه عصبی مصنوعی، توابع آموزش شبه-نیوتنی، پیش‌بینی

Predicting the Longitudinal Dispersion Coefficient in Natural Streams Using Developed Artificial Neural Network Model

Roohollah Noori¹

Abdulreza Karbassi²

Hamid Mehdizadeh³

(Received July 8, 2008 Accepted Dec. 15, 2009)

Abstract

The main objective of the present work is to predict the longitudinal dispersion coefficient in natural streams using a neural network (NN) model which was developed based on Quasi-Newton training functions. For this reason, we used the hydraulic and geometric data easily obtained in natural streams. A total number of 100 data sets was used which were split into three subsets: training, validation, and testing sets. The most cited literature in the field was first reviewed in an attempt to identify possible deficiencies and inadequacies in previous studies. In a second stage, a new approach less commonly used by researchers, i.e. the NN model based on Quasi-Newton training functions, was employed for predicting the longitudinal dispersion coefficient in natural streams. Finally, the effect of Quasi-Newton training function on the performance of the NN model was investigated and the best architecture was selected for the model developed. The results obtained in this study showed that the proposed model enjoys a satisfactory level of accuracy. The two statistics of the model, i.e. determination coefficient and mean absolute error in testing step, were found to be equal to 0.85 and 53, respectively.

Keywords: Longitudinal Dispersion Coefficient, Artificial Neural Network, Quasi-Newton Training Functions, Prediction.

1. Ph.D. Student of Environmental Eng., Dept. of Environmental Eng., University of Tehran (Corresponding Author) 09374320526 roohollahnoori@gmail.com

2. Assist. Prof., Dept. of Environmental Eng. University of Tehran

3. M.Sc. of Chemistry Eng., Research Institute of Petroleum Industry, Tehran

۱- دانشجوی دکترای مهندسی محیط زیست، دانشکده محیط‌زیست، دانشگاه تهران (نویسنده مسئول) ۰۹۳۷۴۳۲۰۵۲۶ roohollahnoori@gmail.com

۲- استادیار، دانشکده محیط زیست، دانشگاه تهران

۳- کارشناس ارشد مهندسی شیمی، پژوهشگاه صنعت نفت، تهران

قادر به تخمین دقیق این پارامتر نیستند. از طرفی نیز استفاده از مدل‌های پیشرفته‌تر نظیر شبکه عصبی مصنوعی (ANNs)^{۱۱} ظرافت‌های خاص خود را داشته که بی‌توجهی نسبت به آنها باعث نامعتبر شدن نتایج می‌شود [۳]. به‌طور مثال در این راستا می‌توان به مطالعه تیفور و سینگ اشاره نمود [۵]. در تحقیق مذکور ضریب انتشار طولی رودخانه‌ها با استفاده از شبکه عصبی پس‌خور چندلایه مدل‌سازی شده است و در نهایت نیز با مقایسه نتایج با تحقیقات مشابه انجام گرفته توسط کاشفی‌پور و فالکنر، فیشر، سئو و چونگ و دنگ و همکاران، برتری مدل مذکور نتیجه گرفته شده است. مشکلی که در مطالعه تیفور و سینگ می‌توان مشاهده نمود تفاوت معنادار نتایج به‌دست آمده از مرحله آموزش و آزمایش شبکه است [۳، ۴، ۹ و ۱۰]. این مسئله باعث می‌شود تا مدل پیشنهادی مذکور از جامعیت کافی برخوردار نباشد.

با توجه به موارد ذکر شده، هدف این تحقیق یافتن مدلی مناسب برای پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی با استفاده از توسعه مدل شبکه عصبی مصنوعی بر مبنای توابع آموزش شبه-نیوتنی^{۱۲} بود.

۲- مواد و روشها

۲-۱- اطلاعات مسئله

در این تحقیق به منظور دستیابی به مدل مناسبی برای پیش‌بینی ضریب انتشار طولی رودخانه‌ها، با جمع‌آوری مجموعه‌ای وسیع از داده‌های محققان مختلف، اقدام به آموزش و آزمایش ANN شد [۳، ۴، ۵، ۷]. ورودی‌ها به ANN ترکیبی از مشخصات هندسی و جریان در رودخانه‌ها شامل عرض و عمق رودخانه بر حسب متر و سرعت و سرعت برشی جریان بر حسب متر بر ثانیه و خروجی مدل نیز ضریب انتشار طولی بر حسب متر مربع بر ثانیه است.

۲-۲- شبکه عصبی مصنوعی

با توجه به مراجع کافی برای ANN، در این تحقیق با توجه به حجم مطالب مورد بررسی، تنها به موارد ضروری و مرتبط با کار انجام شده متناسب با موضوع مقاله پرداخته شد [۱۱-۱۵]. در استفاده از ANN مشکلی که همواره وجود دارد مشکل فوق‌برازشی شبکه است که در این تحقیق با توجه به مطالعات نوری و همکاران، برای رفع این مشکل از روش الگوریتم توقف آموزش (STA)^{۱۳} استفاده شد [۱۶]. شبکه مورد استفاده در این تحقیق، شبکه پس‌خور چند لایه با الگوریتم پس انتشار خطا بود. توابع انتقال نیز در لایه پنهان و خروجی شبکه به ترتیب تابع سیگموئیدی و خطی انتخاب شدند.

تعیین ضریب انتشار طولی در رودخانه‌ها، کمک شایانی به مدل‌سازی رفتار آلاینده‌ها به منظور اتخاذ تدابیر لازم برای مقابله با آنها می‌نماید. روشهای متعددی به منظور دستیابی در حل این مسئله ارائه شده است. در این راستا می‌توان به مطالعات فیشر و همکاران^۱، ایواسا^۲ و آیا^۳، سئو^۴ و چونگ^۵، کاشفی‌پور و فالکنر^۶، تیفور^۷ و سینگ^۸ و نوری و همکاران اشاره نمود [۱-۷].

دامنه تغییرات ضریب انتشار طولی در رودخانه‌های طبیعی بسته به خصوصیات جریان و هندسه مقطع بسیار متغیر است. این عامل و عوامل دیگر نظیر برخی از اشتباهات موجود که در مدل‌های به‌کار گرفته شده توسط برخی از محققان وجود داشته، باعث شده تا نتایج این مطالعات در برگزیده تخمین دقیقی از این پارامتر پیچیده نباشند [۶-۷]. سئو و چونگ با استفاده از روش رگرسیونی یک مرحله‌ای هابر^۹ مدلی برای تعیین ضریب انتشار طولی در رودخانه‌های طبیعی ارائه دادند [۳ و ۸]. به این منظور از اطلاعات میدانی به‌دست آمده از ۲۶ رودخانه در آمریکا استفاده شد. در پایان نیز ضریب تعیین (R) ۰/۷۵ برای مدل ارائه گردید. در مطالعات نوری و همکاران در شرایط یکسان با مطالعه بالا، ضریب همبستگی برای معادله مذکور برابر ۰/۶۳ به‌دست آمد. دنگ و همکاران^{۱۰} نیز در تحقیقی به توسعه مدلی مناسب برای تعیین ضریب انتشار طولی در رودخانه‌ها پرداختند و در انتها نیز با مقایسه نتایج به‌دست آمده از مدل خود با نتایج تحقیقات سئو و چونگ به این نتیجه رسیدند که مدل به‌دست آمده از دقت بیشتری برخوردار است [۳ و ۹]. طبق مطالعات نوری و همکاران بر روی معادله ارائه شده توسط دنگ و همکاران مشخص گردید که ادعای برتری این مدل بر مدل ارائه شده توسط سئو و چونگ اشتباه بوده و ضریب همبستگی برای معادله ارائه شده توسط این محققان در مرحله آموزش و آزمایش مدل به ترتیب برابر با ۰/۱۹ و ۰/۳۴ است [۳ و ۹]. این مقادیر برای معادله ارائه شده توسط سئو و چونگ برابر با ۰/۴۰ و ۰/۲۷ می‌باشد [۳].

به هر حال با مرور مطالعات قبلی و نتایج آنها مشخص می‌شود که به دلیل پیچیدگی رفتار ضریب انتشار طولی در شرایط مختلف، مدل‌های کلاسیک رگرسیونی مورد استفاده توسط برخی محققان

¹ Fischer et al.

² Iwasa

³ Aya

⁴ Seo

⁵ Cheong

⁶ Falconer

⁷ Tayfur

⁸ Singh

⁹ Huber

¹⁰ Deng et al.

¹¹ Artificial Neural Networks (ANNs)

¹² Quasi-Newton

¹³ Stop Training Algorithm (STA)

محدوده اختیارات محققان در استفاده از توابع آموزش به منظور بهینه کردن وزن‌ها و بایاس شبکه با توجه به توابع آموزش فراوانی که معرفی شده‌اند متنوع و زیاد است. در این تحقیق برای بهینه کردن پارامترها شبکه دسته‌ای از این توابع به نام الگوریتم‌های شبه-نیوتنی مورد بررسی قرار گرفتند. روش مذکور یک روش بهینه‌سازی سریع جایگزین برای روشهای گرایان مزدوج^۱ است. مرحله پایه‌ای برای انواع روشهای بر پایه نیوتن به صورت زیر است

$$x_{k+1} = x_k - A_k^{-1}g_k \quad (1)$$

که در این رابطه

x_k و x_{k+1} بردارهای وزن و بایاس به ترتیب در تکرار k و $k+1$ شیب در تکرار k و A_k^{-1} ماتریس هسین^۲ (مشتقات دوم) تابع بازده با مقادیر فعلی وزن و بایاس است. معمولاً روش نیوتن سریع‌تر از روشهای گرایان مزدوج، همگرا می‌شود. متأسفانه این روش پیچیده بوده و بار محاسباتی ماتریس هسین برای شبکه‌های عصبی پس‌خور زیاد است. دسته‌ای از الگوریتم‌ها وجود دارند که بر مبنای روش نیوتن بنا شده‌اند اما به محاسبه مشتق دوم نیاز ندارند. این دسته، روشهای شبه-نیوتنی نامیده می‌شوند. این دسته از الگوریتم‌ها در هر تکرار خود یک تخمین به روز شده از ماتریس هسین ارائه می‌دهند. این مقدار به روز شده بر اساس تابعی از گرایان، محاسبه می‌شوند.

۲-۲-۱- تابع آموزش برویدن^۳ - فلچر^۴ - گلدفارب^۵ - شانو^۶ (TRAINBFGS)

موفق‌ترین روش شبه-نیوتنی که در مطالعات، بیشتر مد نظر محققان بوده است، روش برویدن-فلچر-گلدفارب-شانو است [۱۷]. این الگوریتم در هر گردش به مقدار محاسبات و فضای ذخیره‌سازی بیشتری نسبت به روشهای گرایان مزدوج نیاز دارد و ماتریس هسین تخمین زده شده با ابعاد $n \times n$ (برابر تعداد وزن‌ها و بایاس در شبکه) باید در جایی ذخیره شود. این الگوریتم عموماً در تعداد گردش کمتری نسبت به گرایان مزدوج همگرا می‌شود.

۲-۲-۲- تابع آموزش شیب تک مرحله‌ای^۷ (TRAINOSS)

از آنجا که الگوریتم TRAINBFGS نسبت به گرایان‌های مزدوج مقدار ذخیره‌سازی و محاسبه بیشتری در هر مرحله نیاز دارد،

احتمال می‌رود روشی برای محاسبه شیب با تعداد مراحل و فضای ذخیره‌سازی کمتر وجود داشته باشد. روش محاسبه شیب تک مرحله‌ای (OSS) تلاشی برای ایجاد یک روش واسطه و پرکردن خلاء بین الگوریتم‌های شبه-نیوتنی (بر اساس شیب) و گرایان‌های مزدوج است.

این الگوریتم، ماتریس کامل هسین را ذخیره نمی‌کند، بلکه فرض می‌کند در گردش قبلی، ماتریس هسین یک ماتریس واحد بوده است. فرض مذکور این مزیت را نیز دارد که جهت جستجو بدون محاسبه ماتریس معکوس قابل محاسبه است [۱۸]. این الگوریتم به فضای ذخیره‌سازی و همچنین محاسبه کمتری در دوره نسبت به الگوریتم TRAINBFGS نیاز دارد. اما نسبت فضای مورد نیاز برای ذخیره‌سازی و محاسبات آن در هر دوره از روش گرایان مزدوج کمتر است. این روش یک روش میانه بین شبه-نیوتنی کامل و الگوریتم گرایان مزدوج است. در بیشتر الگوریتم‌های آموزش مورد استفاده به منظور بهینه کردن وزن‌ها و بایاس شبکه، پارامتر نرخ آموزش برای تعیین کردن طول گام مورد استفاده قرار می‌گیرد. اما در الگوریتم‌های شبه-نیوتنی، مقدار طول گام در هر تکرار به صورت خودکار تنظیم می‌شود که به این منظور لازم است تابع جستجوی مناسبی وجود داشته باشد. پنج تابع جستجوی متفاوت در جعبه ابزار شبکه عصبی (نرم‌افزار مطلب) وجود دارند که در میان آنها تابع جستجوی پیمایش معکوس^۸ (SEARCHBAC) بهترین همخوانی را با الگوریتم‌های بهینه‌سازی شبه-نیوتنی دارد [۱۷].

۲-۲-۳- تابع جستجوی پیمایش معکوس

این الگوریتم کار خود را با ضریب گام واحد آغاز کرده و سپس حرکت به عقب خود را آغاز می‌کند تا هنگامی که یک کاهش قابل قبول در بازده رخ دهد. در اولین گام از مقدار بازده در نقطه فعلی و ضریب گام واحد استفاده می‌شود. همچنین این روش از مشتق بازده در نقطه فعلی برای به دست آوردن یک تخمین درجه ۲ از تابع بازده در راستای جستجو استفاده می‌کند. کمینه تابع درجه ۲ یک نقطه بهینه موقت تحت شرایط خاص است و مقدار بازده در این نقطه آزموده می‌شود. اگر مقدار بازده به اندازه کافی کاهش داده نشود، از یک درون‌یابی درجه ۳ استفاده می‌شود و نقطه کمینه درون‌یابی درجه ۳، نقطه بهینه موقت جدید می‌شود. این روند ادامه می‌یابد تا کاهش مورد نظر در تابع بازده اتفاق بیفتد. برای اطلاعات بیشتر در مورد این روش می‌توان به مطالعات دنیس و همکاران^۹ مراجعه نمود [۱۷].

¹ Conjugate Gradient

² Hessian

³ Broyden

⁴ Fletcher

⁵ Goldfarb

⁶ Shanno

⁷ One Step Secant Algorithm

⁸ Backtracking

⁹ Dennis et al.

۳- بحث و نتایج

۳-۱- توسعه مدل شبکه عصبی

در این تحقیق به منظور پیش‌بینی ضریب انتشار طولی، بعد از استاندارد کردن متغیرها با تغییر تعداد نرون‌ها در لایه پنهان شبکه، با استفاده از هر کدام از توابع آموزشی مورد استفاده، مدل‌های متفاوتی ایجاد شد. تعداد بهینه نرون‌ها در لایه پنهان شبکه با استفاده از روش سعی و خطا تعیین گردید. در این مقاله برای تعیین تعداد نرون‌ها در لایه پنهان شبکه از توصیه فلچر و گاس^۱ استفاده شد [۱۹]. فلچر و گاس دامنه تغییرات تعداد نرون‌های لایه پنهان شبکه را از $(2n^{0.5}+m)$ تا $(2n+1)$ پیشنهاد نمودند که در این رابطه n برابر با تعداد متغیرهای ورودی و m نیز تعداد متغیرهای خروجی شبکه است [۱۹]. در تحقیق حاضر با توجه به تعداد ۴ متغیر ورودی و یک متغیر خروجی و همچنین توصیه مذکور، دامنه تغییر نرون‌ها در لایه پنهان شبکه بین ۵ تا ۹ نرون به دست آمد. به همین دلیل در این مقاله، مدل‌های با ۴ تا ۱۰ نرون در لایه پنهان شبکه مورد بررسی قرار گرفتند. همچنین به منظور تعیین کردن طول گامی که مقدار تابع هدف را کمینه نماید، از تابع جستجوی پیمایش معکوس برای هر دو تابع مورد استفاده در این مقاله استفاده گردید. قابل ذکر است که به منظور ارزیابی عملکرد مدل‌ها در این تحقیق از ۳ مشخصه آماری ضریب تعیین (R^2)، مجذور مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) استفاده گردید.

۳-۲- آموزش شبکه با تابع آموزش BFGS

در این مرحله از تحقیق به منظور دستیابی به مدل بهینه برای پیش‌بینی ضریب انتشار طولی، مدل‌های متفاوتی با تغییر در تعداد نرون‌های لایه پنهان ANN با تابع آموزش BFGS آموزش داده و آزمایش شدند که نتایج این بررسی‌ها در جدول ۱ آمده است. با توجه به نتایج به دست آمده از این تابع آموزش، مشخص است که مدل‌های با تعداد ۴ و ۸ نرون نتایج بهتری را نسبت به دو مدل دیگر داشتند. مقدار ضریب تعیین برای هر دو مدل در مرحله آزمایش برابر و معادل ۰/۸۵ بود. مقدار میانگین مجذور مربعات خطا نیز در هر دو مدل تقریباً یکسان بود. اما قدر مطلق میانگین خطا برای مدل با ۸ نرون در لایه پنهان از مقدار مطلوب‌تری برخوردار بود و مقدار آن تقریباً یک سوم مدل با ۴ نرون در لایه پنهان بود. با توجه به مطالب ذکر شده مدل با ۸ نرون در لایه پنهان (ANN-BFGS-8) به عنوان مدل بهینه در این مرحله از تحقیق انتخاب شد.

۳-۳- آموزش شبکه با تابع شیب تک مرحله‌ای

مشابه مرحله قبل مدل‌های متفاوتی برای این تابع آموزش با تغییر در تعداد نرون‌ها در لایه پنهان شبکه ایجاد گردید که نتایج مراحل آموزش و آزمایش هر مدل در جدول ۲ آمده است.

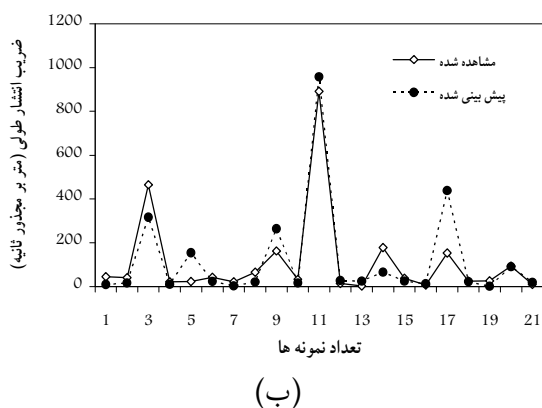

¹ Goss

جدول ۱- نتایج حاصل از مرحله آموزش و آزمایش شبکه عصبی برای تابع آموزش BFGS

آزمایش			آموزش			نرون	تابع جستجو	تابع آموزش
MAE	RMSE	R ²	MAE	RMSE	R ²			
۱۴۵/۷۳	۸۷/۴۶	۰/۸۵	۴۷/۹۶	۹۱/۰۳	۰/۸۷	۴	SEARCHBAC	TRAINBFGS
۲۳۱/۱۹	۱۳۱/۴۹	۰/۷۷	۶۷/۶۱	۱۰۷/۷۶	۰/۸۰	۶		
۵۲/۹۲	۸۵/۸۵	۰/۸۵	۵۰/۴۹	۱۱۱/۱۶	۰/۸۴	۸		
۱۰۱/۰۷	۱۵۲/۷۱	۰/۷۲	۹۷/۴۶	۱۲۸/۲۲	۰/۷۸	۱۰		

جدول ۲- نتایج حاصل از مرحله آموزش و آزمایش شبکه عصبی برای تابع آموزش شیب تک مرحله‌ای

آزمایش			آموزش			نرون	تابع جستجو	تابع آموزش
MAE	RMSE	R ²	MAE	RMSE	R ²			
۶۴۰/۴۱	۱۲۶/۴۷	۰/۶۳	۷۰/۴۸	۱۵۱/۵۴	۰/۶۲	۴	SEARCHBAC	TRAINOSS
۸۲/۳۲	۱۳۴/۲۶	۰/۷۴	۹۱/۴۲	۱۳۰/۰۶	۰/۷۶	۶		
۸۴/۰۵	۱۴۰/۴۱	۰/۶۳	۷۸/۳۲	۱۴۲/۸۰	۰/۶۷	۸		
۹۱/۸۸	۱۷۷/۶۳	۰/۵۹	۷۶/۱۳	۱۳۶/۴۰	۰/۷۰	۱۰		



شکل ۱- مقادیر مشاهده و پیش‌بینی شده توسط مدل ANN-BFGS-8 در مرحله (الف) آموزش و (ب) آزمایش

مدل‌های متفاوتی از شبکه عصبی مصنوعی برای پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی آموزش داده و آزمایش شوند. نتایج به‌دست آمده از این مدل‌ها نشان‌دهنده عملکرد مناسب این نوع توابع آموزش در تخمین ضریب انتشار طولی بود به‌طوری‌که نتایج مطلوبی از به‌کارگیری این توابع در ساختار شبکه عصبی حاصل شد.

متدولوژی ارائه شده در این تحقیق می‌تواند رهیافت جدیدی در تخمین ضریب انتشار طولی آلودگی در رودخانه‌ها محسوب شود. این متدولوژی به خوبی قابلیت اتصال و ترکیب با مدل‌های ریاضی انتقال آلودگی و نیز بهنگام‌سازی با توجه به شرایط واقعی را دارد.

در این مرحله نیز با توجه به نتایج به‌دست آمده، مدل با ۶ نرون در لایه پنهان شبکه (ANN-OSS-6) نسبت به بقیه مدل‌ها از عملکرد مطلوب‌تری برخوردار بود. به همین دلیل، این ساختار به‌عنوان ساختار بهینه در این مرحله از تحقیق انتخاب گردید.

۴-۳- انتخاب بهترین مدل

در مراحل قبل، مدل‌های مناسبی با استفاده از دو نوع تابع شبه-نیوتنی، آموزش داده و آزمایش شدند. در هر مرحله نیز بهترین مدل انتخاب شد که نتایج مدل‌های بهینه در جدول‌های ۱ و ۲ آمده است. در این مرحله با مقایسه نتایج به‌دست آمده از این دو مدل، بهترین مدل به‌منظور پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی انتخاب گردید. با توجه به جدول‌های ۱ و ۲ مشخص است که در بین این دو مدل در مراحل آزمایش، مدل ANN-BFGS-8 نسبت به مدل ANN-OSS-6 از نتایج مطلوب‌تری برخوردار و مقدار هر سه پارامتر آماری مورد استفاده در این تحقیق برای مدل مذکور بهتر بود. مقدار ضریب تعیین، میانگین مجذور مربعات و قدرمطلق میانگین خطا در مرحله آزمایش برای این مدل در مقایسه با مدل ANN-OSS-6 به میزان ۱۵، ۴۸ و ۵۵ درصد بهبود داشت. با توجه به مطالب ذکر شده، این مدل به‌عنوان بهترین مدل در این تحقیق برای پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی انتخاب شد. نمودار مربوط به مقادیر مشاهده و پیش‌بینی شده توسط این مدل برای مراحل آموزش و آزمایش مدل در شکل ۱ آمده است.

۴- نتیجه‌گیری

این مطالعه تلاشی در جهت دستیابی به مدل بهینه پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی بود. به این منظور در ابتدا با مرور برخی از مطالعات انجام گرفته در این زمینه، این نکته محرز شد که به‌دلیل پیچیدگی رفتار این پارامتر، مدل‌های کلاسیک ارائه شده قادر به پیش‌بینی دقیق آن نیستند و از طرفی نیز استفاده از مدل‌های مناسب‌تر مثل شبکه عصبی مصنوعی در برخی مطالعات با نواقصی همراه بوده است. سپس در این مقاله با توجه به ناتوانی مدل‌های رگرسیونی و همچنین استفاده صحیح از شبکه عصبی مصنوعی، سعی شد تا با استفاده از توابع آموزشی شبه-نیوتنی،

۵- مراجع

- 1- Fischer, H. B., List, E. J., Koh, R. C. Y., Imberger, J., and Brooks, N. H. (1979). *Mixing in inland and coastal waters*, 1st Ed., Academic, New York.
- 2- Iwasa, Y., and Aya, S. (1991). "Predicting longitudinal dispersion coefficient in open-channel flows." *Proc. Int. Symp. on Environmental Hydrology*, Hong Kong, 505-510.

- 3- Seo, I. W., and Cheong, T. S. (1998). "Predicting longitudinal dispersion coefficient in natural Streams." *J. of Hydraulics Eng.*, 124 (1), 25-32.
- 4- Kashefipour, M. S., and Falconer, R. A. (2002). "Longitudinal dispersion coefficients in natural channels." *Water Res.*, 36(6), 1596-1608.
- 5- Tayfur, G., and Singh, V.P. (2005). "Predicting longitudinal dispersion coefficient in natural streams by artificial neural network." *J. of Hydraulic Engineering*, 131 (11), 991-1000.
- 6- Noori, R., Karbassi, A.R., Farokhnia, A., and Dehghani, M. (2009). "Predicting the longitudinal dispersion coefficient using support vector machine and adaptive neuro-fuzzy inference system techniques." *Environmental Engineering Science*, 26 (10), 1503-1510.
- 7- Noori, R., Karbassi, A., Mehdizadeh, H., Vesali-Naseh, M. and Sabahi, M. S. (2010). "Development of a framework for predicting the longitudinal dispersion coefficient in natural streams using artificial neural network." *Environmental Progress and Sustainable Energy*, DOI: 10.1002/ep.10478.
- 8- Huber, P.J. (1981). *Robust statistics*, 1st Ed., John Wiley and Sons Inc., New York.
- 9- Deng, Z. Q., Singh, V. P., and Bengtsson, L. (2001). "Longitudinal dispersion coefficient in straight rivers." *J. Hydraul. Eng.*, 127(11), 919-927.
- 10- Fischer, H. B. (1975). "Discussion of simple method for predicting dispersion in streams." *J. of Environ Eng Div ASCE*, 101, 453-455.
- 11- Haykin, S. (1999). *Neural networks: A comprehensive foundation*, 2nd Ed., Prentice Hall, New Jersey.
- 12- Maier, H.R., and Dandy, G.C. (2000). "Neural networks for the prediction and forecasting water resources variables: A review of modeling issues and applications." *J. Env. Model. Soft.*, 15 (23), 101-124.
- 13- Noori, R., Farokhnia, A., Morid, S., and Riahi Madvar, H. (2008). "Effect of input variables preprocessing in artificial neural network on monthly flow prediction by PCA and wavelet transformation." *J. of Water and Wastewater*, 69, 13-22. (In persian)
- 14- Noori, R., Hoshiyaripour, G.A., Ashrafi, K., and Araabi, B.N. (2009). "Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration." *Atmospheric Environment*, 44 (4), 476-482.
- 15- Noori, R., Khakpour, A., Omidvar, B., and Farokhnia, A. (2010). "Comparison of ANN and principal component analysis-multivariate linear regression models for predicting the river flow based on developed discrepancy ratio statistic." *Expert Systems with Applications*, 37 (8), 5856-5862.
- 16- Noori, R., Karbassi, A.R., and Sabahi, M.S. (2009). "Evaluation of PCA and gamma test techniques on ANN operation for weekly solid waste prediction." *J. of Environmental Management*, 91 (3), 767-771.
- 17- Dennis, J.E., and Schnabel, R.B. (1983). *Numerical methods for unconstrained optimization and nonlinear equations*, 1st Ed., Prentice-Hall, New York.
- 18- Battiti, R., (1992), "First and second order methods for learning: Between steepest descent and Newton's method." *Neural Computation*, 4(2), 141-166.
- 19- Fletcher, D, and Goss, E. (1993). "Forecasting with neural networks: An application using bankruptcy data." *Inf. Management*, 24 (32), 159-167.