

پیش‌بینی توزیع غلظت رسوبات معلق با استفاده از مدل شبکه‌عصبی مصنوعی

حسین بهرامی^{*۱}، صمد امامقلی زاده^۲

۱. گروه سازه های دریایی، دانشکده مهندسی دریا، دانشگاه علوم و فنون دریایی خرمشهر
۲. گروه مهندسی آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

تاریخ پذیرش: ۱۳۹۴/۸/۹

تاریخ دریافت: ۱۳۹۳/۲/۳۰

شناسه دیجیتال (DOI): [10.22113/jmst.2016.41032](https://doi.org/10.22113/jmst.2016.41032)

چکیده

در هیدرولیک رسوب، برآورد صحیح غلظت رسوب معلق از جهات مختلف مانند تخمین دبی رسوب عبوری، جانمایی سازه های هیدرولیکی و غیره مهم می باشد. با توجه به اهمیت موضوع، در این مطالعه برای مدل سازی و پیش‌بینی غلظت رسوب رودخانه کارون از شبکه عصبی مصنوعی پرسپترون چند لایه (ANN/MLP) استفاده شد. بدین منظور از ۱۲۵ سری داده صحرائی اندازه گیری شده شامل غلظت نزدیک کف، سرعت نقطه ای، نزدیکترین فاصله از ساحل، عمق کل جریان و عمق نقطه ای جریان استفاده شد. کارایی مدل مورد استفاده با استفاده از پارامترهای آماری مانند ضریب تبیین (R^2) و ریشه میانگین مجذور خطا، میانگین خطای مطلق (RMSE) مورد ارزیابی قرار گرفت. نتایج این پژوهش نشان داد، مدل MLP با یک لایه میانی، تابع سیگموئید و ۵ نرون، بهترین ساختار را در مدل سازی غلظت رسوب رودخانه کارون داشته‌اند. مقدار ضریب تبیین (R^2) و خطای ریشه میانگین مربعات خطا (RMSE) برابر ۰/۹۵۳ و ۶۳/۳۷ میلی گرم بر لیتر به ترتیب در مرحله آموزش و ۰/۷۵۲ و ۲۰۳/۰۲ میلی گرم بر لیتر در مرحله صحت‌سنجی بوده است. همچنین آنالیز حساسیت انجام شده بر روی پارامترهای ورودی مدل نشان می‌دهد کمترین و بیشترین تاثیر را دو پارامتر فاصله از ساحل و عمق جریان در یادگیری شبکه عصبی مصنوعی داشتند.

واژگان کلیدی: مدل سازی، غلظت رسوب، رودخانه کارون، شبکه عصبی مصنوعی

* نویسنده مسئول، پست الکترونیک: hossein_bahrami1979@yahoo.com

۱. مقدمه

در راستای عمق جریان می باشد. با فرض ثابت بودن w و ε_y و انتگرال گیری معادله فوق در راستای y و حذف مشتق مرتبه دوم غلظت خواهیم داشت:

$$\varepsilon_y \frac{dc}{dy} + wc = 0 \quad (2)$$

با در نظر گرفتن معادله تنش برشی در جریان آشفته، پذیرش معادله توزیع لگاریتمی سرعت عمقی و فرض اینکه ضریب پخشیدگی رسوب، مضربی از ضریب انتقال اندازه حرکت باشد، پس از انتگرال گیری میتوان معادله توزیع عمقی غلظت رسوب را بصورت زیر بیان کرد:

$$\frac{c}{c_a} = \left[\frac{d-y}{y} \cdot \frac{a}{d-a} \right]^{z_0} \& Z_0 = \frac{w_0}{k \cdot \beta \cdot u_*} \quad (3)$$

z_0 ، نمای معادله توزیع رسوب و c_a غلظت در عمق a از کف است که بعنوان غلظت مبنا در نظر گرفته می شود. معادله فوق اولین بار توسط Rouse منتشر گردید (Galappatti, 1983). بعدها دیگر محققین بر اساس تئوری پخشیدگی و با در نظر گرفتن توزیعهای سرعت و نیز فرضیات متفاوت، معادلات دیگری بدست آوردند که از جمله آنها میتوان به روابط تاناکا و ساجیموتو و نیز رابطه مک تیگو اشاره کرد. Tanaka و Sujimoto با استفاده از تغییرات واقعی تنش برشی در برابر عمق جریان و در نظر گرفتن یک رابطه جدید برای تغییرات سرعت $\left(\frac{du}{dy}\right)$ ، رابطه خود را بصورت زیر بیان نمودند:

$$\frac{c}{c_a} = \left\{ \left(\frac{\sqrt{d} + \sqrt{d-y}}{\sqrt{d} - \sqrt{d-y}} \right) \left(\frac{\sqrt{d} - \sqrt{d-a}}{\sqrt{d} + \sqrt{d-a}} \right) \right\}^{w_0/k u_*} \quad (4)$$

ماکتیگو نیز، عمق جریان را به دو ناحیه درونی و بیرونی تقسیم کرد. از نظر وی لایه درونی شامل ناحیه‌ای از کف تا $0.2d$ و لایه بیرونی در بالای لایه درونی قرار داشته و تا سطح آب ادامه دارد. بنابراین

به کلیه مواد جامدی که توسط آب حمل می‌شوند، رسوب اطلاق می‌گردد. مواد رسوبی را می‌توان به دو گروه بار معلق و بار بستر تقسیم‌بندی نمود. مواد معلق بخش عمده‌ای از کل رسوبات را در بسیاری از رودخانه های آبرفتی تشکیل می‌دهند. غلظت این نوع رسوبات در نزدیکی بستر آبراهه زیاد بوده و به طرف سطح آب از غلظت آن کاسته می‌گردد. در جریان آشفته، حرکت المانهای آب هنگامیکه موقعیتشان را بین لایه‌های جریان تغییر می‌دهند، باعث بروز تغییرات غلظت و دانه بندی رسوب در جریان می‌گردند. در همان زمان، ذرات رسوب، بخاطر وزن مخصوص بیشتر تمایل به ته‌نشینی داشته و به سمت بستر حرکت می‌کنند. نتیجه اینکه، غلظت رسوبات در نزدیکی بستر نسبت به نقاط دورتر، بیشتر است. بدلیل گرادیان غلظت ایجاد شده، المانهایی از جریان که حرکت رو به بالا دارند، مقدار بیشتری از رسوبات را نسبت به جریان رو به پایین حمل می‌کنند. بنابراین مبادله بین جریانهای رو به بالا و پایین المانهای آب در حجم ثابت، برآیندی بصورت جریان خالص رسوب رو به بالا دارد. این مقدار شار رسوب رو به بالا، متناسب با گرادیان غلظت موجود است (Gard R.J. & K.G. RangaRaju (2000)).

شکل (۱) پروفیل عمقی غلظت را نشان می‌دهد. از جمله تئوریهای موجود برای تفسیر توزیع قائم غلظت بار معلق رسوبات، تئوری پخشیدگی است که بر اساس آن روابط متعددی توسط دانشمندان مختلف ارائه شده است. اگر پروفیل قائم غلظت بار معلق در حالت تعادل باشد، فرآیند پخشیدگی رسوب ماندگار و یکنواخت است. در چنین حالتی معادله پخشیدگی را میتوان بصورت رابطه زیر نوشت:


$$\varepsilon_y \frac{d^2c}{dy^2} + \frac{d\varepsilon_y}{dy} \frac{dc}{dy} + w \frac{dc}{dy} = 0 \quad (1)$$

که در آن c غلظت رسوب معلق، y عمق جریان، w سرعت سقوط رسوبات و ε_y ضریب پخشیدگی رسوب

چند لایه بین آنها که مستقیماً به داده های ورودی و نتایج خروجی متصل نیستند، تشکیل یافته اند. واحدهای لایه ورودی وظیفه توزیع مقادیر ورودی ها به لایه بعد و لایه خروجی نیز پاسخ سیگنالهای خروجی را ارائه می دهد. در این دو لایه، تعداد نرونها برابر با تعداد ورودی ها و خروجی ها می باشد و لایه یا لایه های پنهان وظیفه ارتباط لایه های ورودی به لایه های خروجی و به دست آوردن روابط خطی و غیرخطی را بر عهده دارند (Minasny, B., and A. B. 2002, McBratney). ساختار پرسپترون چند لایه به توابع غیرخطی نیاز دارد که به طور پیوسته مشتق پذیر باشد و به عبارت دیگر هموار باشد. اغلب اوقات این تابع به شکل تابع باینری، سیگموئید، تانژانت هیپربولیک خطی یا گوسی و سکانت هیپربولیک در نظر می گیرند (شکل ۲). ساده ترین و معمول ترین نوع شبکه عصبی مصنوعی که در بسیاری از علوم مهندسی و از جمله پژوهش حاضر استفاده می گردد شبکه های عصبی چند لایه پیشخور همراه با ناظر است که از روش پس انتشار خطا برای آموزش کمک می گیرد. این روش توسط Rumelhart et al, ۱۹۸۶ پیشنهاد شده است. ساختار ریاضی مدل MLP بصورت زیر می باشد:

$$y_i = f\left(\sum_{j=1}^N w_{ji} x_j + b_j\right) \quad (6)$$

که در آن x_i برابر با i th مقدار نود لایه قبلی، که در آن y_j برابر با j th مقدار نود لایه فعلی، b_j بایاس نود j th در لایه فعلی، w_{ji} وزن اتصال x_i و y_j ، و N تعداد نودها در لایه های قبلی و f تابع فعال در لایه فعلی می باشد (Mohanty et al. 2010).



شکل ۲. ساختار شبکه عصبی چند لایه

معادله توزیع غلظت را برای نواحی ذکر شده بصورت زیر بیان کرد:

$$\begin{cases} \frac{c}{c_a} = \exp\left(-\frac{w_0}{k_1 u_* d}(y-d)\right) & \text{for } y \geq 0.2d \\ \frac{c}{c_a} = \left(\frac{y}{a}\right)^{-w_0/(k_2 u_*)} & \text{for } y < 0.2d \end{cases} \quad (5)$$

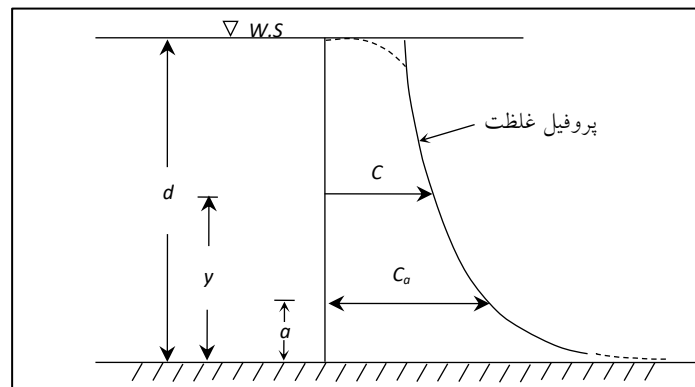
مقادیر k_2, k_1 ضرایبی هستند که وی با استفاده از نتایج آزمایشات به ترتیب مقادیر 0.11 و 0.35 را برای آنها ارائه کرد (Gard R.J. & K.G. RangaRaju) (2000). روابط متعددی دیگری نیز برای تخمین مقدار رسوبات توسط محققین ارائه شده است که کاربرد آنها در رودخانه ها نمی تواند با اطمینان کامل صورت گیرد و هنوز امکان پیش بینی مقدار رسوب یک رودخانه با درجه اطمینانی که برای اکثر اهداف مهندسی رضایت بخش باشد وجود ندارد. این امر به دلیل پیچیدگی مسائل رسوب و عدم تطابق کامل فرضهای تئوری و مسایل عملی در انتقال رسوب است. شناخت فرآیند معلق شدن ذرات و بررسی توزیع رسوبات معلق، نقش بسیار مهمی در مطالعات رسوب و تعیین ضوابط مربوط به انتقال رسوبات ایفا می کند. در این تحقیق سعی بر آن است تا با استفاده از مقادیر غلظت نقطه ای اندازه گیری شده در مقاطع عرضی متفاوت از رودخانه کارون، به بررسی توانایی مدلسازی و پیش بینی غلظت عمقی رسوبات معلق در رودخانه کارون با استفاده از شبکه های هوشمند مصنوعی مانند شبکه عصبی مصنوعی پرداخته شود.

۲- مواد و روش ها

شبکه عصبی مصنوعی یک روش شبیه سازی می باشد که از مطالعه سیستم شبکه عصبی موجودات زنده الهام گرفته است (Nayak et al. 2006). یکی از متداولترین شبکه های عصبی مورد استفاده، شبکه عصبی پرسپترون چند لایه می باشد (Haykin, 1994). این شبکه از یک لایه ورودی، یک لایه خروجی و یک یا

از جمله وجود دو ایستگاه هیدرومتری، تعدد طرح‌های کشاورزی و به تبع آن؛ کانالها، ایستگاههای پمپاژ آب و نیز سهولت دسترسی بیشتر به آن انتخاب گردیده است.

محدوده مورد مطالعه شامل مسیر رودخانه کارون از ایستگاه اهواز واقع در محدوده محله عامری تا ایستگاه فارسیات واقع در ۲۰ کیلومتری جاده اهواز-آبادان می‌باشد. لازم به ذکر است این محدوده بدلائل مختلف



شکل ۱. شماتیک پروفیل غلظت و سرعت قائم

شاخص‌های آماری ریشه میانگین مجذور خطا^۱، میانگین خطای مطلق^۲ و ضریب همبستگی^۳ استفاده شد.

۳- نتایج

ساختار بهینه شبکه‌های عصبی مصنوعی تحت تاثیر پارامترهایی مانند تعداد نرون‌ها در لایه پنهان، توابع محرک بین گره‌ها و تعداد لایه‌های پنهان می‌باشد. یافتن ساختار بهینه نیازمند انجام کار سعی و خطا می‌باشد. لذا برای دستیابی به ساختار بهینه شبکه عصبی مصنوعی، تعداد نرون‌های مختلف (از ۴ تا ۹ نرون) در لایه پنهان، توابع محرک (سیگموئید، تانژانت هیپربولیک، گوسی و سکانت هیپربولیک) و تعداد لایه‌های پنهان (از ۱ تا ۸) مورد استفاده قرار گرفت. در مجموع برای بدست آوردن ساختار بهینه ۱۹۲ مدل اجرا و بهترین مدل بر اساس حداقل میزان مربعات خطا، برای هر ساختار تعیین گردید. اجرای مدل با استفاده از توابع محرک ذکر شده نشان می‌دهد زمانی

برای انجام مدلسازی، ابتدا ۱۲۵ سری داده صحرائی شامل غلظت نزدیک کف (میلیگرم بر لیتر)، سرعت نقطه‌ای (متر بر ثانیه)، نزدیکترین فاصله از ساحل (متر)، عمق کل جریان (متر) و عمق نقطه‌ای جریان (متر)، در رودخانه کارون اندازه گیری شد. در جدول خلاصه آماری پارامترهای مورد استفاده آمده است.

برای انجام مدل سازی در ابتدا به منظور یکسان سازی مجموعه داده‌های ورودی و خروجی، داده‌ها بر اساس فرمول زیر بین صفر و یک نرمال گردیدند:

$$x_N = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

سپس داده‌ها به دو دسته آموزش و صحت‌سنجی تقسیم شدند. در مرحله آموزش ۸۰٪ داده‌ها و در مرحله صحت‌سنجی ۲۰٪ داده‌ها به شبکه معرفی شد. پس از یادگیری در هر دو مرحله آموزش و صحت‌سنجی، داده‌های محاسبه شده توسط نرم‌افزار QNET2000 با داده‌های اندازه‌گیری شده مقایسه شد. برای تعیین بازده ساختارها برای گزینش بهترین و صحیح‌ترین خروجی برای پیش‌بینی غلظت بار معلق از

^۱ Root Mean Square Error (RMSE)

^۲ Mean Absolute Error, MAE

^۳ Regression Coefficient, R²

بالاترین ضریب تبیین) حالتی است که مدل با استفاده از یک لایه میانی، تابع محرک سیگموئید و ۵ نرون باشد. در مجموع مدل بهینه شبکه عصبی دارای ضریب تبیین ۰/۹۵ و ۰/۷۵ و همچنین ریشه میانگین مربعات خطا (RMSE) برابر با ۶۳/۳۷ و ۲۰۳/۰۲۵ به ترتیب در مرحله آموزش و صحت‌سنجی بوده و بهترین عملکرد در میان سایر ساختارهای مورد بررسی را داشته است. همچنین شکل‌های ۴ و ۵، نمودار پراکندگی داده‌ها را در مرحله آموزش و صحت‌سنجی بر اساس بهترین ساختار بدست آمده نشان می‌دهد.

جدول ۱. پارامترهای آماری داده‌های مورد استفاده

پارامتر	حداقل	متوسط	حداکثر
غلظت	۶۰	۱۱/۳۹۷	۱۷۸۰
سرعت	۳۴/۰	۸۹/۰	۸/۱
غلظت	۱۸۰	۷۰۰	۱۷۸۰
نزدیکترین	۶	۱۶/۱۶۵	۲۱۸
عمق نقطه	۰۶/۰	۱۴/۲	۸/۶
عمق کل	۸/۱	۲۵/۴	۷

برای تعیین همبستگی هر یک از پارامترهای ورودی بر یادگیری شبکه و ارتباط آن با غلظت رسوب تخمین زده شده، از آنالیز حساسیت استفاده شد. بدین منظور مدل MLP شبکه عصبی که بالاترین دقت را در تخمین غلظت رسوب داشته است استفاده شده است. با انجام این روش می‌توان نقش هر یک از پارامترها را مشخص کرده و قدرت آنها را در یادگیری مدل محاسبه کرد و در صورت ناچیز بودن تاثیر پارامتر ورودی در یادگیری مدل می‌توان آن را حذف کرد.

که تابع محرک سیگموئید باشد، خطای ریشه میانگین مربعات خطا (RMSE) برابر با ۶۳/۳۷ و ۲۰۳/۰۲ میلی گرم بر لیتر به ترتیب در مرحله آموزش و صحت‌سنجی بوده است. به عبارت دیگر تغییر تابع محرک موجب کاهش خطا RMSE در مرحله صحت‌سنجی به مقدار ۷۲، ۷/۶ و ۶/۴ درصد نسبت به حالتی که از توابع گوسی، تانژانت هیپربولیک، و سکانت هیپربولیک استفاده شده است گردید. جدول ۲ نتایج حاصل از اجرای مدل با توابع فوق‌الذکر را نشان می‌دهد. همانطوریکه گفته شد، علاوه بر تاثیر تابع محرک در یادگیری شبکه عصبی مصنوعی، تعداد لایه میانی نیز می‌تواند بر فرآیند یادگیری شبکه MLP تاثیر معنی‌داری داشته باشد. بدین منظور شبکه MLP با لایه‌های میانی مختلفی از ۱ تا ۸ اجرا گردید که جدول ۳، اجرای مدل با تابع محرک سیگموئید و تغییرات لایه پنهان از ۱ تا ۸ را نشان می‌دهد نتیجه بدست آمده بیانگر آن است در حالتی که تعداد لایه میانی ۱ باشد، مقدار RMSE به ترتیب ۶۳/۳۷ و ۲۰۳/۰۲ میلی گرم بر لیتر در مرحله آموزش و صحت‌سنجی بدست آمده است. همچنین برای حالتی که تعداد لایه‌های میانی برابر با ۸ باشد، مقدار RMSE به ترتیب ۸۱/۳۷ و ۲۵۹/۸۵ میلی گرم بر لیتر در مرحله آموزش و صحت‌سنجی می‌باشد. به عبارتی افزایش تعداد لایه‌ها موجب پیچیده‌تر شدن شبکه گردید و قدرت یادگیری آن در مرحله آموزش کاهش و متعاقباً دقت مدل در مرحله صحت‌سنجی برای برآورد غلظت رسوب را کاهش داده است. همچنین اجرای مدل با تعداد نرون‌های مختلف (از ۴ تا ۹ نرون) در لایه پنهان نشان داد که بهترین ساختار مدل (حداقل خطا و

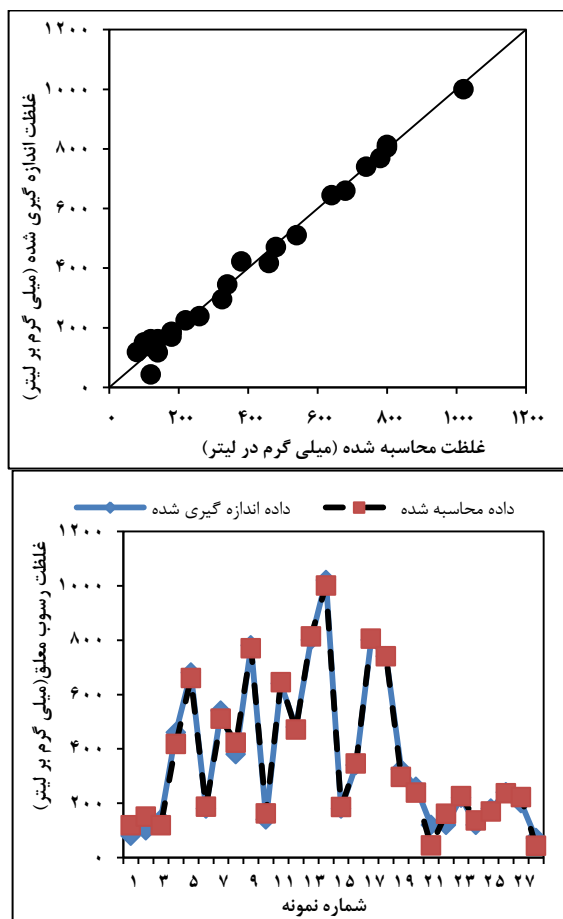
جدول ۲. بررسی تاثیر توابع انتقال در یادگیری شبکه عصبی مصنوعی

شماره	تابع انتقال	آموزش	تست
		R ² RMSE(mg/l) MAE(mg/l)	R ² RMSE(mg/l) MAE(mg/l)
۱	Sig.	۰/۹۵۳ ۶۳/۳۷ ۴۶/۴۳	۰/۷۵ ۲۰۳/۰۲۵ ۱۲۴/۲۳
۲	Gauss.	۰/۱ ۷۵۶/۲۸ ۷۰/۶۷	۰/۰۸ ۷۲۶/۶۵ ۶۷۷/۷۱
۳	Tan. H.	۰/۹۵۲ ۶۴/۳۶ ۴۸/۳۴	۰/۷۱ ۲۱۹/۶۶ ۱۲۷/۷۱
۴	Sec. H.	۰/۹۳۹ ۷۲/۷۵ ۵۵/۴۸	۰/۶۴ ۲۱۶/۹۹ ۱۳۰/۲۷

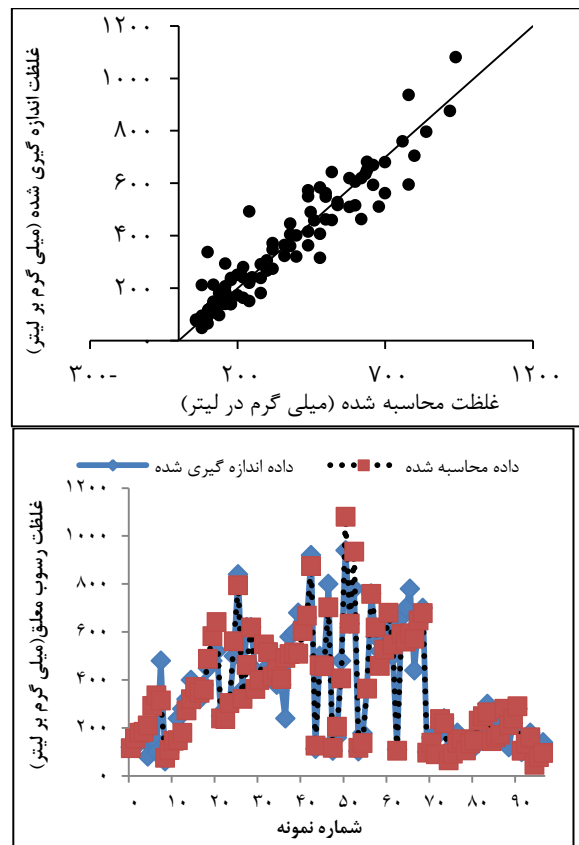
جدول ۳. بررسی تاثیر لایه میانی با استفاده از تابع سیگموئید

تست			آموزش			تعداد لایه‌های میانی
R ²	RMSE(mg/l)	MAE(mg/l)	R ²	RMSE(mg/l)	MAE(mg/l)	
۰/۷۵۲	۲۰۳/۰۲۵	۱۲۴/۲۳	۰/۹۵۳	۶۳/۳۷	۴۶/۴۳	۱
۰/۷۱۶	۲۳۳/۴۵	۱۵۴/۷۶	۰/۹۴۹	۶۴/۴۵	۴۹/۹۸	۲
۰/۶۹	۲۴۵/۱۵	۱۵۶/۷۱	۰/۹۵	۶۳/۸۲	۴۶/۸۶	۳
۰/۷۱۳	۲۴۵/۴۱	۱۴۵/۲۶	۰/۹۳۵	۷۴/۹۶	۵۲/۴۱	۴
۰/۶۵۸	۲۵۶/۰۲	۱۲۶/۹۷	۰/۹۴	۷۲/۸۳	۵۷/۸۴	۵
۰/۶۵۲	۲۵۶/۷۳	۱۲۷/۲۱	۰/۹۴	۷۳/۳۴	۵۸/۴۱	۶
۰/۶۴۱	۲۵۸/۹۱	۱۳۱/۴۳	۰/۹۳۴	۷۸/۵۴	۶۲/۶۲	۷
۰/۶۲۸	۲۵۹/۸۵	۱۳۷/۸۷	۰/۹۳۱	۸۱/۳۷	۶۴/۹۵	۸

ورودی انجام شد که نتایج بدست آمده در جدول ۴ نشان داده شده است.



شکل ۴. پراکندگی داده‌های اندازه‌گیری شده و برآورد شده در مرحله صحت سنجی



شکل ۵. پراکندگی داده‌های اندازه‌گیری شده و برآورد شده در مرحله آموزش

کم کردن تعداد متغیرهای ورودی به مدل اگرچه ممکن است دقت مدل را کاهش دهد(البته تا حد قابل قبول) ولی از طرفی می‌تواند هزینه اندازه‌گیری پارامتر(های) ورودی را کاهش دهد. برای دستیابی به این هدف، آنالیز حساسیت بر روی پارامترهای

سرعت جریان با داشتن ضریب تبیین ۰/۶۱۶ و ۰/۶۳۵ بیشترین تاثیر را در یادگیری مدل در پیش بینی با غلظت رسوب داشتند در حالی که کمترین همبستگی مربوط به نزدیکترین فاصله از ساحل بود. افزایش سرعت جریان موجب آشفتگی جریان و در نتیجه افزایش قدرت حمل رسوب می‌گردد که این امر با نتیجه بدست آمده همخوانی دارد.

بر اساس نتایج حاصل، حذف تک تک پارامترهای ورودی (غلظت کف، سرعت، نزدیکترین فاصله از ساحل، عمق کل جریان و عمق جریان) موجب کاهش ضریب تبیین و مقدار آن از ۰/۷۵ تا ۰/۶۱۶ می‌باشد. به عبارتی نتیجه بدست آمده بیانگر اهمیت نسبتا یکسان پارامترهای ورودی بر خروجی مدل دارد. در مجموع نتیجه بدست آمده نشان می‌دهد عمق و

جدول ۴. آنالیز حساسیت پارامترهای ورودی در نتیجه شبکه عصبی مصنوعی

ردیف	ساختار مدل	تست		
		R ²	RMSE(mg/l)	MAE(mg/l)
۱	مدل با ۵ ورودی (سرعت، فاصله، ...)	۰/۷۵	۲۰۳/۰۲۵	۱۲۴/۲۳
۲	مدل بدون پارامتر غلظت کف	۰/۶۳۹	۲۰۲/۱۲۷	۱۴۴/۵۸
۳	مدل بدون پارامتر سرعت	۰/۶۳۵	۲۳۲/۶۶	۱۳۷/۳۶
۴	مدل بدون پارامتر نزدیکترین فاصله از ساحل	۰/۶۷۶	۱۷۵/۶۳	۱۳۴/۲۲
۵	مدل بدون پارامتر عمق کل	۰/۶۴۸	۲۱۵/۸۷	۱۲۶/۷۴
۶	مدل بدون پارامتر عمق جریان	۰/۶۱۶	۱۹۸/۹۰	۱۴۳/۱۱۱

انجام شده بر روی پارامترهای ورودی به مدل (غلظت کف، سرعت نقطه ای، نزدیکترین فاصله از ساحل، عمق کل جریان و عمق نقطه ای جریان) نشان می‌دهد دو پارامتر عمق نقطه ای و فاصله از ساحل بیشترین کمترین تاثیر را در یادگیری شبکه عصبی مصنوعی داشتند. با توجه به تاثیر نیروی ثقل و گرادیان رو به پایین غلظت ذرات رسوب و نیز اثر نیروی محرک جریان که در پروفیل سرعت هم مشاهده میشود؛ تاثیر بالاتر سرعت و عمق جریان قابل توجه است. ضمناً غلظت نزدیک بستر نیز به عنوان عامل محدود کننده حداکثر غلظت در هر محور قائم، قاعدتا از پارامترهای بسیار تاثیر گذار خواهد بود. به نظر میرسد با توجه به مقاطع عرضی که همگی در بازه‌های مستقیم رودخانه انتخاب شده بودند، فاصله از ساحل بدلیل عدم وجود جریانهای عرضی، کمتر از سایر پارامترها موثر واقع شده است.

قدردانی و تشکر:

۴. بحث و نتیجه گیری

در مباحث انتقال رسوبات، پیش بینی غلظت معلق جریان بسیار مهم و کاربردی است. با توجه این موضوع، در تحقیق حاضر مدل هوش مصنوعی شبکه عصبی مصنوعی چند لایه (MLP/ANN) برای مدلسازی غلظت رسوب معلق مورد استفاده قرار گرفت. از داده‌های صحرائی شامل غلظت کف، سرعت نقطه‌ای، نزدیکترین فاصله از ساحل، عمق کل جریان و عمق نقطه ای جریان برای آموزش و صحت سنجی مدل استفاده گردید. استفاده از مدل ANN/MLP نشان می‌دهد مدل مذکور توانایی شبیه سازی غلظت رسوب معلق را دارد؛ بنابراین این مدل را می‌توان برای میان‌یابی و پیش بینی غلظت رسوب معلق مورد استفاده قرار داد. مدلسازی با ساختارهای مختلف ANN/MLP با توجه به معیارهای خطا مانند R²، RMSE و MAE نشان می‌دهد، مدل مذکور با تابع سیگموئید، یک لایه پنهان و ۵ نرون، دارای بالاترین دقت و کمترین خطا نسبت به سایر ساختارهای شبکه می‌باشد. همچنین آنالیز حساسیت

دریایی خرمشهر می‌باشد. بدین ترتیب از دانشگاه علوم و فنون دریایی خرمشهر تقدیر و تشکر بعمل می‌آید.

Galappatti R. (1983), "A Depth Integrated Model for Suspended Transport." Report no 83-7, Delft University of Technology, Delft, The Netherlands.

Gard R.J. & K.G. Ranga Raju (2000), "Mechanics of sediment transportation and alluvial stream problems." New International (P) Ltd Publishers, Third Edition, Chapter 14.

Haykin, S., 1994. Neural networks. In: A comprehensive foundation. IEEE press, MacMillan, New York.

Minasny, B., and A. B. McBratney. 2002. The neuro-m methods for fitting neural network parametric pedotransfer functions. Soil Science Society of America Journal 66: 352-61.

این مقاله مستخرج از طرح تحقیقاتی اجرا شده از محل اعتبارات ویژه پژوهشی دانشگاه علوم و فنون

منابع

Mohanty S, Jha K, Kumar A, Sudheer K (2010) Artificial neural network modeling for groundwater level forecasting in a river island of eastern India. J Water Resour Manag 24:1845-1865

Nayak P, Satyaji Rao Y, Sudheer K (2006) Groundwater level forecasting in a shallow aquifer using artificial neural network. J Water Resour Manag 20:77-90.

Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. Learning internal representation by error back propagation. In: Rumelhart, D.E., McClelland, J.L. (Eds.), Parallel Distributed Processing. MIT Press, Cambridge, MA, pp. 318-362

Prediction of suspended sediment distribution of Karoon River using artificial neural network

Bahrami, Hossein^{1*}, emamgholi zadeh, samad²

1. Department of Marine Structures, Faculty of Engineering, Khorramshahr University of marine science and technology
2. Department of Soil and Water, Faculty of Agriculture, shahrood industrial University

Abstract

Accurate estimation of sediment concentrations in hydraulic sediment transport from different viewpoint such as sediment discharge estimation of river, selection of hydraulic structures and etc. are important. With respect to importance of this issue in this study for prediction of sediment concentration of Karun river multi-layer perceptron artificial neural network (ANN / MLP) was used. For this purpose 125 field data including bottom concentration, flow velocity, nearest distance from the beach, and the total depth of flow and flow depth was used. Three statistical metrics namely mean absolute error (MAE), root mean square error (RMSE) and coefficient of determination (R^2) were used to evaluate the performance of ANN model. The result shows that MLP model with one hidden layer, Sigmoid transfer function and 5 neurons have best structure in the modeling of sediment concentration of Keroon River. The R^2 and RMSE value is equal to 0.953 and 63.37 mg/l in training stage and 0.752 and 203.02 mg/l in testing stage, respectively. Finally, the sensitive analysis also showed that the nearest distance from the beach and flow depth had the most and the least effect on the sediment concentration, respectively.

Keywords: Modeling, sediment concentration, artificial neural network, Karoon River

Figure 1. Schematic of the concentration and velocity profile

Figure 2. Multi-layer neural network structure

Table 1. Statistical parameters of the used data

Table 2. Investigating the Effect of Transfer Function on Artificial Neural Network Learning

Table 3. Investigating the effect of the middle layer using the sigmoid function

Figure 4. Scattering of measured and estimated data in the training step

Figure 4. Scattering of measured and estimated data in the validation step

Table 4. Sensitivity analysis of input parameters in artificial neural network results

*Corresponding author E-mail: hossein_bahrami1979@yahoo.com