

تخمین بیشترین عمق آبشستگی در اطراف پایه‌ی پل تحت اثر انباشت موانع با استفاده از مدل NF-GMDH و الگوریتم‌های تکاملی

محمد نجف‌زاده و محمد محمودی‌راد


دوره ۵، شماره ۳، پاییز ۱۳۹۸، صفحات ۲۱۳ - ۲۲۵

Vol. 5(3), Autumn 2019, 213 - 225

DOI: 10.22034/jewe.2019.192130.1326

**Estimation of the Maximum Scour Depth at
Bridge Pier under Effects of Debris
Accumulations using NF-GMDH Model and
Evolutionary Algorithms**

Najafzadeh M. and Mahmaudi-Rad M.



www.jewe.ir

OPEN ACCESS

ارجاع به این مقاله: نجف‌زاده م. و محمودی‌راد م. (۱۳۹۸). تخمین بیشترین عمق آبشستگی در اطراف پایه‌ی پل تحت اثر انباشت موانع با استفاده از مدل NF-GMDH و الگوریتم‌های تکاملی. مجله محیط‌زیست و مهندسی آب، دوره ۵، شماره ۳، صفحات: ۲۱۳-۲۲۵.

Citing this paper: Najafzadeh M. and Mahmaudi-Rad M. (2019). Estimation of the maximum scour depth at bridge pier under effects of debris accumulations using NF-GMDH model and evolutionary algorithms. J. Environ. Water Eng., 5(3), 213-225. DOI: 10.22034/jewe.2019.192130.1326.

تخمین بیشترین عمق آبشستگی در اطراف پایه‌ی پل تحت اثر انباشت موانع با استفاده از مدل NF-GMDH و الگوریتم‌های تکاملی

محمد نجف‌زاده^{۱*} و محمد محمودی راد^۲

استادیار، گروه مهندسی آب، دانشکده مهندسی عمران و نقشه برداری، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران
 آدانش‌آموخته دکتری مهندسی عمران-سازه‌های هیدرولیکی، گروه مهندسی عمران دانشکده مهندسی دانشگاه شهید باهنر کرمان، ایران

*نویسنده مسئول: m.najafzadeh@kgut.ac.ir

مقاله اصلی

تاریخ پذیرش: [۱۳۹۸/۰۷/۳۰]

تاریخ بازنگری: [۱۳۹۸/۰۷/۱۹]

تاریخ دریافت: [۱۳۹۸/۰۴/۰۹]

چکیده

انباشت موانع شناور جریان رودخانه‌ها، نظیر تنه و شاخ و برگ درختان منجر به افزایش عمق آبشستگی موضعی در اطراف پایه‌های پل می‌شود. تاکنون جهت درک سازوکار پدیده آبشستگی تحت اثر موانع شناور، مطالعات آزمایشگاهی و میدانی بسیاری انجام شده است. در دو دهه‌ی اخیر از انواع روش‌های هوش مصنوعی جهت تخمین بیشترین عمق آبشستگی در اطراف پایه پل استفاده شده است. در این مطالعه از مدل فازی-عصبی مبتنی بر روش دسته‌بندی گروهی داده‌ها (NF-GMDH) جهت تخمین آبشستگی تحت اثر انباشت موانع استفاده شد. شبکه NF-GMDH با استفاده از الگوریتم‌های تکاملی شامل الگوریتم وراثتی (GA)، الگوریتم بهینه‌ساز ازدحام ذرات (PSO) و الگوریتم جستجوی گرانشی (GSA) توسعه داده شد. پارامترهای مؤثر بر حداکثر عمق آبشستگی به صورت سرعت متوسط جریان بالادست پایه پل، سرعت بحرانی رسوبات بستر رودخانه، عمق جریان در مقطع بدون حضور موانع، ضخامت مستغرق موانع، قطر موانع، اندازه متوسط ذرات، قطر پایه و عرض کانال در نظر گرفته شد. بعد از انجام مراحل آموزش و آزمایش هر مدل NF-GMDH، عملکرد آن‌ها با استفاده از شاخص‌های آماری ارزیابی شد. نتایج نشان داد که مدل‌های پیشنهادی دارای عملکرد بهتر نسبت به روابط تجربی است. همچنین دو مدل NF-GMDH-PSO ($R=0/84$ و $RMSE=0/37$) و NF-GMDH-GA ($R=0/8407$ و $RMSE=0/3640$) دارای عملکرد مشابه بودند. در نهایت آنالیز حساسیت نشان داد که نسبت بدون بعد قطر پایه (D) به اندازه متوسط ذرات (d_{50}) بیشترین تأثیر را در تعیین پارامتر حداکثر عمق آبشستگی دارد.

واژه‌های کلیدی: آبشستگی؛ الگوریتم‌های تکاملی؛ انباشت موانع؛ پایه پل؛ روش دسته‌بندی؛ گروهی داده‌ها.

۱- مقدمه

تجربی در پیش‌بینی حداکثر عمق آبشستگی، ممکن است باعث ایجاد خطای قابل‌توجهی در تخمین این پارامتر شود؛ زیرا هر یک از روابط تجربی در شرایط آزمایشگاهی کنترل‌شده و برای محدوده خاصی از پارامترها و داده‌های آزمایشگاهی صادق هستند. از این‌رو، در دهه‌های اخیر از روش‌های هوشمند نظیر؛ شبکه‌های عصبی مصنوعی (ANN⁵)، سیستم‌های استنتاج فازی عصبی-تطبیقی (ANFIS⁶)، برنامه‌نویسی وراثتی (GP⁷)، مدل درخت (MT⁷)، ماشین بردار پشتیبان (SVM⁷) و روش دسته‌بندی گروهی داده‌ها (GMDH) به‌منظور تخمین آبشستگی اطراف سازه‌های هیدرولیکی در معرض فرسایش استفاده‌شده است (Bateni and Jeng 2007; Etemad-Shahidi and Ghaemi 2011; Azamathulla et al. 2010; Najafzadeh et al. 2014). در میان روش‌های مذکور، الگوریتم GMDH یک شبکه پرکاربرد بوده که توسط پژوهش‌گران زیادی به‌منظور تخمین حداکثر عمق آبشستگی در اطراف سازه‌های هیدرولیکی مورد‌استفاده قرار گرفته است (Najafzadeh et al. 2013a and b; Najafzadeh, 2015). GMDH یک الگوریتم بسیار انعطاف‌پذیر بوده که می‌تواند به‌راحتی با الگوریتم‌های تکاملی توسعه یابد و همچون سایر روش‌های هوشمند نتایج را با دقت قابل قبولی ارائه دهد (Najafzadeh et al. 2014). کاربردهای موفقیت‌آمیز مدل NF-GMDH را می‌توان در پیش‌بینی آبشستگی پایین‌دست دریچه کشویی (Najafzadeh and Lim 2015) و آبشستگی پایین‌دست سرریزهای اوجی (Najafzadeh et al. 2014) مشاهده کرد.

پژوهش‌های اخیر نشان داد که مدل پیشرفته NF-GMDH بسیار انعطاف‌پذیر بوده و به‌سادگی قابل ترکیب با الگوریتم‌های تکاملی می‌باشد و نتایجی را با سطح دقت بالایی ارائه می‌دهد. همچنین، پژوهش‌ها در مورد عملکرد مدل‌های ترکیبی NF-GMDH جهت

همواره پایداری پل‌ها در معرض عوامل مخرب زیادی نظیر؛ بارهای هیدرودینامیکی، آبشستگی بستر (کلی یا موضعی یا هر دو)، آبشستگی دیواره جانبی و تأثیر کشتی قرار دارد. از این بین، دلیل اصلی خرابی پل‌ها آبشستگی موضعی می‌باشد (Feranzetti et al. 2011) یکی از عوامل تشدیدکننده پدیده آبشستگی، انباشت اجسام شناور (موانع چوبی) در اطراف پایه‌های پل می‌باشد. هندسه انباشت موانع به خصوصیات فیزیکی موانع، میزان موانع انتقال‌یافته به محل پایه پل، شرایط جریان، هندسه پل و کانال بستگی دارد. بسته به شرایط جریان در بالادست پایه پل، تغییر مسیر جریان در اثر انباشت موانع باعث انقباض و انسداد جریان شده و سرعت جریان در محل پایه پل را افزایش می‌دهد. این موضوع افزایش انتقال رسوبات و عمق آبشستگی را به‌دنبال دارد (Lagaase et al. 2010). در دهه‌های اخیر، پژوهش‌های آزمایشگاهی و میدانی متعددی جهت شناخت سازوکار پدیده آبشستگی تحت اثر موانع صورت گرفته است. Toch (1956) و Laursen and آبشستگی را به‌صورت آزمایشگاهی مورد مطالعه قرار دادند. آن‌ها مشاهده کردند که حضور موانع منجر به افزایش عمق حفره‌ی آبشستگی می‌گردد.

Sutherland and Melville (1988) یک روش طراحی به‌منظور تخمین حداکثر عمق آبشستگی در اطراف پایه‌های پل ارائه کردند. برای اهداف طراحی، حداکثر عمق آبشستگی تحت اثر انباشت اجسام شناور می‌تواند با در نظر گرفتن یک قطر پایه پل بزرگ‌تر، نسبت به قطر پایه پل حقیقی تخمین زده شود. این قطر پایه بزرگ‌تر، قطر مؤثر نامیده می‌شود. (1992) Melville and Dongol با استفاده از معادله آب-شستگی (1988) Sutherland and Melville و مفهوم قطر مؤثر پایه، معادله‌ای به‌منظور تخمین حداکثر عمق آبشستگی ارائه کردند. استفاده از روابط

⁵ Model Tree⁶ Support Vector Machine⁷ Group Method of Data Handling¹ Debris² Artificial Neural Network³ Adaptive Neuro-Fuzzy Inference System⁴ Genetic Programming

پایه، b عرض کانال و t مدت زمان انجام آزمایش می باشد. تحقیقات پیشین نشان داده اند که، بی بعد سازی پارامترهای ورودی شبکه های هوشمند جهت تخمین عمق آبستگي در اطراف سازه های هیدرولیکی باعث افزایش دقت روش می شود. لذا در این تحقیق پارامترهای مؤثر بر حداکثر عمق آبستگي را می توان با استفاده از تئوری باکینگهام^۴، به صورت رابطه بدون بعد (۲) بیان نمود (Pagliara and Carnacina 2011):

$$\frac{d_s}{D} = \frac{Z_{max}}{D} = f\left(\frac{D}{d_{50}}, \frac{h}{D}, \frac{D}{b}, \frac{U}{U_c}, \frac{d_d}{b}, T^*, \Delta A\right) \quad (2)$$

در این رابطه، $T^* = Uht/A_b$ فاکتور زمانی بی بعد در حضور موانع است که در آن $A_b = Dh + \Delta A$ مجموع سطح انسداد پل و موانع و همین طور $\Delta A = [(d_d - D) \cdot t_d] / (b \cdot h)$ در ادامه رابطه (۲) را می توان با استفاده از مفهوم فاکتور انقباض ($K_d(T^*)$) به صورت رابطه (۳) تعریف کرد (Pagliara and Carnacina 2011):

$$= f\left(\frac{D}{d_{50}}, \frac{h}{D}, \frac{D}{b}, \frac{U}{U_c}, \frac{d_d}{b}, T^*, \Delta A\right) \quad (3)$$

$$K_d(T^*) = \frac{Z_{max}(T^*)}{Z_{max-0}(T^*)}$$

در رابطه (۳)، پارامتر $Z_{max}(T^*)$ حداکثر عمق حفرة آبستگي تحت اثر موانع در زمان T^* و همچنین پارامتر $Z_{max-0}(T^*)$ حداکثر عمق حفرة آبستگي بدون حضور موانع در زمان T^* است. در جدول (۱) محدوده ۷ پارامتر مؤثر در پیش بینی عمق آبستگي آورده شده است. به منظور توسعه مدل های NF-GMDH از دو سری داده آزمایشگاهی، مربوط به هر یک از پارامترهای رابطه (۳) شامل ۱۷۳ داده مربوط به مرحله آموزش شبکه (معادل ۷۵ درصد کل داده ها) و ۵۸ داده مربوط به مرحله آزمایش شبکه (معادل ۲۵ درصد کل داده ها)، استفاده شد.

تخمین حداکثر عمق آبستگي تحت اثر موانع هنوز به ندرت صورت گرفته است. لذا در مطالعه حاضر، با استفاده از داده های آزمایشگاهی، مدل NF-GMDH با به کارگیری الگوریتم های بهینه ساز ازدحام ذرات^۱ (PSO)، جستجوی گرانشی^۲ (GSA) و وراثتی^۳ (GA) در محیط برنامه نویسی MATLAB توسعه داده شد. در واقع، الگوریتم های بهینه ساز، ضرایب وزنی در هر توصیفگر جزئی (نرون) را تخمین می زنند طوری که، خطای محاسباتی در هر توصیفگر موجود در هر لایه کمینه شود. در نهایت نتایج حاصل از سه مدل پیشنهادی با استفاده از پارامترهای آماری ارزیابی و با عمق های آبستگي به دست آمده از روابط تجربی مقایسه شدند.

۲- مواد و روش ها

۲-۱- تحلیل داده های آزمایشگاهی و آنالیز ابعادی

در این پژوهش به منظور توسعه مدل ها، از داده های مربوط به مجموعه آزمایش های انجام شده توسط Lagasse et al. (1992)، Melville and Dongol (2010) و Pagliara and Carnacina (2011) استفاده شد. این آزمایش ها در شرایط جریان یکنواخت، بستر "آب زلال" و رسوبات غیر چسبیده، انجام گرفتند. سایر شرایط آزمایشگاهی و جزئیات آن، در مطالعات آزمایشگاهی مربوطه آورده شده است. در ادامه، با توجه به پژوهش های صورت گرفته در این زمینه، پارامترهای مؤثر بر حداکثر عمق آبستگي تحت اثر موانع (d_s) در رابطه (۱) آورده شده است (Pagliara and Carnacina 2011):

$$d_s = \varphi(U, U_c, h, t_d, d_d, d_{50}, D, b, t) \quad (1)$$

که در این رابطه، d_s حداکثر عمق آبستگي موضعی، U سرعت جریان، U_c سرعت بحرانی جریان، h عمق جریان در مقطع بدون حضور مانع، t_d ضخامت مستغرق موانع، d_d قطر موانع، d_{50} اندازه متوسط ذرات، D قطر

³ Genetic Algorithm

⁴ Buckingham

¹ Particle Swarm Optimization

² Gravitational Search Algorithm

$$K_{d(T^*)} = 1 + 0.018\Delta A^{1.5} \quad (5)$$

$$K_{d(T^*)} = \frac{1.872(h/D_e)^{0.225} \cdot D_e}{2.4D} \quad (6)$$

$$K_{d(T^*)} = \left(\frac{D_e}{D}\right)^{0.745} \quad (7)$$

در روابط اخیر، ΔA سطح انسداد موانع، h عمق جریان در مقطع بدون حضور مانع، D قطر پایه، $K_{d(T^*)}$ فاکتور انقباض و D_e حداکثر عمق آبشستگی تحت اثر موانع می‌باشد.

۲-۲- روش دسته‌بندی گروهی داده‌ها (GMDH)

الگوریتم GMDH یکی از مدل‌های شبکه عصبی می‌باشد که، دارای لایه‌های ورودی، میانی و لایه خروجی می‌باشد. تحقیقات مختلف در زمینه کاربرد GMDH نشان می‌دهند که استفاده از ترکیب‌های تقریب ساز و بهینه‌ساز در ساختار این روش، باعث ایجاد نتایج دقیق‌تری از پیش‌بینی رفتار فیزیکی پدیده‌ها می‌شود (Najafzadeh 2013). در این شبکه ارتباط بین پارامترهای ورودی و خروجی هر سیستم را می‌توان با سری توابع ولترا که مشابه با چندجمله‌ای گسسته شده کولموگروف-گابور می‌باشد، به صورت رابطه (۸) بیان کرد (Najafzadeh 2013):

$$y = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ijk} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (8)$$

استفاده تابع محرک که می‌تواند به صورت یک چندجمله‌ای خطی یا غیرخطی باشد، بیان می‌گردد. در ساختار پایه مدل GMDH از چندجمله‌ای درجه دوم همراه با دو متغیر ورودی به صورت رابطه (۹) بیان می‌شود:

$$y = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1^2 + w_4 x_2^2 + w_5 x_1 x_2 \quad (9)$$

$$E = \frac{1}{n} \sum_{i=1}^n (y_{Obs(i)} - y_{Pre(i)})^2 \quad (10)$$

که در آن y_{Obs} ، y_{Pre} ، n و E به ترتیب شامل مقادیر مشاهداتی، مقادیر محاسباتی حاصل از مدل عددی، تعداد داده‌های مشاهداتی و مقدار خطای محاسباتی در هر نرون (توصیفگر جزئی) می‌باشند.

جدول ۱- محدوده پارامترهای بی‌بعد ورودی و خروجی به‌منظور پیش‌بینی عمق آبشستگی

Table 1. Range of input-output parameters for prediction of the scour depth

محدوده	پارامتر
6057.108 – 6760000	T^*
0.49 – 166	U/U
0 – 12.91	$\Delta A/c$
0.038 – 26.083	D/b
11.36 – 172.414	D/d_{50}
1.724 – 6.035	h/D
0.043 – 1	d_d/b
0.083 – 2.95	$K_{d(T^*)}$

به‌منظور مقایسه و ارزیابی عملکرد مدل‌های پیشنهادی در تخمین عمق آبشستگی موضعی پایه پل تحت اثر موانع، از مدل ANN و همین‌طور چهار رابطه تجربی شامل، دو رابطه (۴) و (۵) مربوط به مطالعات Pagliara and Carnacina (2011) و دو رابطه (۶) و (۷) مربوط به مطالعه Melville and Sutherland (1988) استفاده شد.

$$K_{d(T^*)} = 1 + 0.036\Delta A^{1.5} \quad (4)$$

که در آن $(x = x_0, x_1, x_2, \dots, a_m)$ و $(A = a_0, a_1, a_2, \dots, a_m)$ به ترتیب بردارهای پارامترهای ورودی و ضرایب وزنی در هر نرون می‌باشند. در ساختار GMDH هر نرون حداقل دارای دو ورودی می‌باشد. ارتباط بین متغیرهای ورودی و خروجی در هر نرون با

که در آن w_0 تا w_5 ضرایب چندجمله‌ای هستند. برای ساخت شبکه GMDH، ابتدا ترکیب‌های دوتایی از پارامترهای ورودی را باید در نظر گرفت. بعد از آن، در هر نرون با استفاده از روش حداقل مربعات خطا، ضرایب وزنی هر نرون و مقدار خطای مربوطه محاسبه می‌شوند. در هر لایه برای انتخاب نرون‌های برتر از نظر ویژگی طبقه‌بندی، از معیار خطای رابطه (۱۰) استفاده می‌گردد (Najafzadeh 2013):

در رابطه (۱۱) a_{KJ} و b_{KJ} مقادیر ثابت برای هر قانون فازی هستند. همچنین بردار خروجی هر نرون از مدل NF-GMDH به صورت رابطه‌ی (۱۲) تعریف می‌شود (Takashi 1988):

$$y = \sum_{k=1}^K u_k \cdot w_k \quad (12)$$

در رابطه‌ی (۱۲)، w_k مقدار واقعی برای قانون فازی K ام و u_k تابع گوسین است که به شکل رابطه (۱۳) تعریف می‌شود:

$$u_k = \prod_J F_{KJ}(x_J) \quad (13)$$

در این مدل هر توصیفگر جزئی (نرون) دارای دو متغیر ورودی و یک متغیر خروجی است و خروجی هر نرون به عنوان متغیر ورودی در لایه‌ی بعدی در نظر گرفته می‌شود. در آخر خروجی نهایی با استفاده از میانگین خروجی‌های لایه‌ی آخر به دست می‌آید. شکل (۱) ساختار کلی شبکه جلو رونده NF-GMDH را نشان می‌دهد بطوریکه ورودی‌های مدل m ام (نرون m ام) در لایه‌ی p ام، متغیرهای خروجی مدل $m-1$ ام و m ام در لایه‌ی p ام هستند.


۲-۳- مدل ترکیبی روش دسته‌بندی گروهی داده‌ها و عصبی-فازی (NF-GMDH)

در این شبکه تعداد نرون‌ها در هر لایه برابر تعداد ترکیب‌های دوتایی حاصل‌شده از متغیرهای ورودی شبکه می‌باشد. هر نرون دارای دو متغیر ورودی و یک متغیر خروجی است. همچنین قوانین فازی به کاررفته در هر نرون بیانگر توصیفات جزئی می‌باشد و در هر نرون، تشکیل توصیفات جزئی نیازمند قوانین فازی است. حال به منظور توسعه شبکه GMDH و تبدیل آن به مدل NF-GMDH از قاعده‌ی استدلال فازی ساده‌شده زیر استفاده شده است (Takashi 1998):

" اگر x_1 برابر F_{k1} و x_2 برابر F_{k2} باشد، آنگاه خروجی y برابر W_k است."

در قاعده‌ی استدلال فازی بالا، x_1 و x_2 متغیرهای ورودی بوده و تابع گوسین بکار رفته برحسب F_{KJ} است که به قانون فازی K ام در دامنه‌ی J ام مقادیر ورودی x ام مربوط می‌شود و به شکل رابطه (۱۱) نوشته می‌شود (Takashi 1988):

$$F_{KJ}(x_J) = \exp\left(-\frac{(x_J - a_{KJ})^2}{b_{KJ}}\right) \quad (11)$$



شکل ۱- مثالی از ساختار شبکه‌ی سه لایه NF-GMDH (Najafzadeh 2014)

Fig. 1 A schematic diagram of a three-layered NF-GMDH

در ادامه، ارتباط بین نرون لایه جاری (کنونی) با نرون‌های لایه پیشین به صورت رابطه (۱۴) بیان می‌شود:

$$y^{pm} = f(y^{p-1,m-1}, y^{p-1,m}) = \sum_{k=1}^K u_k^{pm} \cdot w_k^{pm} \quad (14)$$

در رابطه (۱۴)، u_k^{pm} حاصل ضرب توابع عضویت تشکیل شده در هر نرون می‌باشد که از رابطه (۱۵) حاصل می‌شود:

$$u_k^{pm} = \exp\left\{-\frac{(y^{p-1,m-1}-a_{k,1}^{pm})^2}{b_{k,1}^{pm}} - \frac{(y^{p-1,m}-a_{k,2}^{pm})^2}{b_{k,1}^{pm}}\right\} \quad (15)$$

بهینه مشخص می‌گردد. تمامی ذرات از نقطه‌نظر تابع برازش و دستیابی به بهترین جواب مسئله ارزیابی می‌گردند و در صورت ارضا نشدن شرایط مسئله (خطای معیار)، موقعیت و سرعت ذرات نیز بروز رسانی می‌شوند توضیحات روش بهینه‌ساز PSO در مراجع ارائه گردیده است. (Kennedy and Eberhart, 1995). روند ترکیب بین شبکه‌ی NF-GMDH و الگوریتم PSO به این صورت است که، ابتدا در نرون اول لایه‌ی اول، الگوریتم PSO اجرا می‌شود. بعد تکرارهای مختلف صورت می‌گیرند و در هر تکرار با استفاده از رابطه‌ی (۱۰) پارامتر خطا به دست می‌آید. در نهایت شش ضریب نامعلوم نرون موردنظر به دست می‌آید. حال در نرون بعدی دوباره الگوریتم PSO اجرا می‌شود. این روند برای کل نرون‌های لایه‌ی اول ادامه می‌یابد و خروجی هر نرون جداگانه به دست می‌آید. شکل (۲) ساختار شبکه NF-GMDH پیشنهادی در این پژوهش را نشان می‌دهد. همچنین در جدول (۲) محدوده پارامترهای الگوریتم PSO جهت توسعه ساختار NF-GMDH ارائه شده است.


همچنین بردار خروجی نهایی در مدل NF-GMDH به صورت میانگین لایه‌بردارهای خروجی لایه ماقبل، از طریق رابطه (۱۶) محاسبه می‌شود:

$$y = \frac{1}{M} \sum_{m=1}^M y^{pm} \quad (16)$$

در شبکه‌ی NF-GMDH، در هر نرون دو قانون فازی وجود دارد و در مجموع دو قانون فازی همراه با شش ضریب مجهول که شامل چهار پارامترهای گوسین و دو ضریب وزنی می‌باشند. شش پارامتر مجهول در هر نرون که با استفاده از الگوریتم‌های بهینه‌ساز به دست می‌آیند.

۲-۴- ترکیب شبکه NF-GMDH و الگوریتم PSO

الگوریتم بهینه‌سازی جمعیت ذرات توسط Kennedy and Eberhart (1995) معرفی شد که از نحوه زندگی پرندگان الهام گرفته شده است. در واقع، جهت حل مسائل بهینه‌سازی با استفاده از الگوریتم بهینه‌ساز ازدحام ذرات در ابتدا تعداد ذرات مشخص می‌گردند و موقعیت و سرعت هر ذره نیز در فضای جستجوی مسئله



شکل ۲- ساختار شبکه‌ی سه لایه جلو رونده NF-GMDH جهت تخمین عمق آبشستگی اطراف پایه پل همراه با اجسام شناور
Fig. 2 A three-layered NF-GMDH Network for estimation of the local scour depth at bridge pier under debris flow

الگوریتم وراثتی که اولین بار توسط (Holland 1967) ارائه گردید، یک مدل محاسباتی بر مبنای تکامل موجودات در طبیعت می‌باشد. در الگوریتم مذکور ابتدا مسئله موردنظر به صورت رشته دودویی که پارامترهای مسئله را رمزگذاری می‌کنند، نشان داده می‌شود. در واقع جمعیتی از رشته‌ها با پارامترهای تصادفی اولیه به کار برده می‌شوند. تعدادی از نسل‌ها با عملگرهایی که نشان‌دهنده اجزاء مهم تکامل می‌باشند، شبیه‌سازی می‌گردند. بدین طریق، روند تکاملی منجر به فیلتر شدن عناصر جمعیت که از نظر مقداری به تابع هدف مسئله بهینه‌سازی نزدیک‌تر می‌باشند، می‌گردد. توضیحات بیشتر الگوریتم وراثتی در منابع موجود می‌باشد (Keshavarz-Mehr 2012).

جدول ۳- مقادیر پارامترهای الگوریتم GSA به منظور پیش‌بینی عمق آبستنگی

Table 3 Values of control parameters related to GSA algorithm for the scour depth prediction

مقدار	پارامتر
0.8	P_c (ضریب همبری)
0.01	P_m (ضریب جهش)
6	تعداد متغیرها
50	تعداد جمعیت
0.00001	خطا
0.05-1	پارامترهای گوسین و ضرایب وزنی

جدول ۴- مقادیر پارامترهای الگوریتم GA به منظور پیش‌بینی عمق آبستنگی

Table 4 Values of control parameters related to GSA algorithm for the scour depth prediction

مقدار	پارامتر
20	α
100	G_0
6	تعداد متغیرها
0.00001	خطا
50	تعداد اجرام
0.015-1	پارامترهای گوسین و ضرایب وزنی

در جدول (۴)، محدوده پارامترهای کنترلی الگوریتم وراثتی بکار رفته در توصیفگرهای جزئی مدل NF-GMDH ارائه گردیده است. همچنین نحوه توسعه مدل

جدول ۲- مقادیر پارامترهای تنظیمی الگوریتم PSO به منظور پیش‌بینی عمق آبستنگی

Table 2 Values of control parameters related to PSO algorithm for the scour depth prediction

مقدار	پارامتر
0.0885	ω
50	تعداد ذرات
6	تعداد متغیرها
0.00001	خطا
2	c_1 و c_2
0.05-1	پارامترهای گوسین و ضرایب وزنی

۲-۵- ترکیب شبکه NF-GMDH و الگوریتم جستجوی گرانشی (GSA)


اخیراً الگوریتم بهینه‌ساز جدیدی به نام الگوریتم جستجوی گرانشی توسط (Rashedi et al. (2009 ارائه گردیده است. الگوریتم مذکور جهت حل مسئله بهینه‌سازی از قوانین جاذبه و حرکت استفاده می‌کند. علاوه بر آن، در الگوریتم مذکور به منظور یافتن جواب مسائل بهینه از مجموعه‌ای از عامل‌ها که جرم نامیده می‌شوند، استفاده می‌گردد. حال اگر سیستم را به صورت مجموعه‌ای مشخصی از جرم تصور نمود، موقعیت هر جرم نقطه‌ای از فضا بوده که جوابی از مسئله می‌باشد. سایر توضیحات الگوریتم جستجوی گرانشی در منابع ارائه گردیده است (Rashedi et al., 2009). الگوریتم GSA همانند روش بهینه‌سازی PSO دارای پارامترهای تنظیمی نظیر تعداد اجرام، محدوده پارامترهایی که باید بهینه شوند و شتاب ثابت گرانش می‌باشد. شرط توقف در الگوریتم GSA می‌تواند پس از تعداد تکرارهای تعیین شده توسط شخص برنامه‌نویس، مشخص گردد. جدول (۳) محدوده پارامترهای کنترلی الگوریتم GSA جهت توسعه مدل NF-GMDH را ارائه می‌دهد. روند ترکیب بین شبکه NF-GMDH و الگوریتم GSA، مشابه آنچه در قسمت ۲-۴ توضیح داده شد، می‌باشد.

۲-۶- ترکیب شبکه NF-GMDH و الگوریتم وراثتی


در این قسمت، شکل‌های (۳) تا (۵) مقادیر پارامتر حداکثر عمق آبشستگی مشاهداتی و محاسبه‌شده‌ی نظیر آن را برای مراحل آموزش و آزمایش هر سه مدل پیشنهادی نشان می‌دهند.

مشابه مکانیسم مدل‌های NF-GMDH-GA و NF-GMDH-GSA و NF-GMDH- PSO می‌باشد.

۳- یافته‌ها و بحث



شکل ۳- مقایسه مقادیر پیش‌بینی‌شده و واقعی پارامتر حداکثر عمق آبشستگی مربوط به مدل NF-GMDH-PSO
Fig. 3 Comparison of predicted values and observed maximum scour depth related to the NF-GMDH-PSO



شکل ۴- مقایسه مقادیر پیش‌بینی‌شده و واقعی پارامتر حداکثر عمق آبشستگی مربوط به مدل NF-GMDH-GSA
Fig. 4 Comparison of predicted values and observed maximum scour depth related to the NF-GMDH-GSA

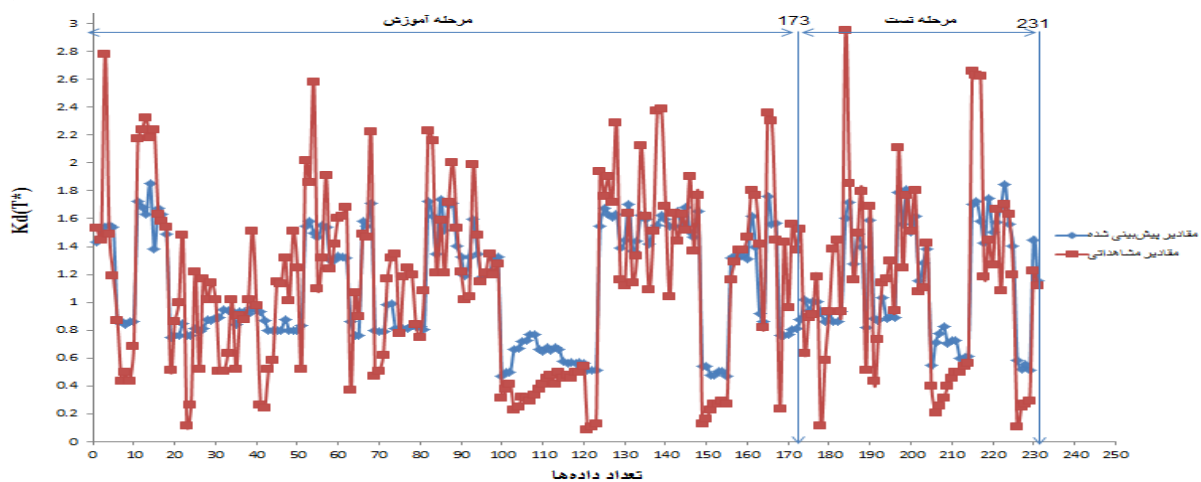
(RMSE)^۲، تابع بایاس (BIAS) و شاخص پراکندگی (SI)^۳ استفاده شد. نتایج آماری مراحل آموزش و آزمایش در جدول (۵) نشان داده شده است.

نتایج حاصل از ارزیابی سطح دقت مدل‌های هوشمند با نتایج روابط تجربی (۴) تا (۷) مورد مقایسه قرار می‌گیرند. بدین منظور، از شاخص‌های آماری ضریب همبستگی (R)^۱، ریشه میانگین مربعات خطا

³ Scatter Index

¹ Correlation Coefficient

² Root Mean Square Error



شکل ۵- مقایسه مقادیر پیش‌بینی شده و واقعی پارامتر حداکثر عمق آبشستگی مربوط به مدل NF-GMDH-GA
 Fig. 5 Comparison of predicted values and observed maximum scour depth related to the NF-GMDH-GA

جدول ۵- ارزیابی آماری عملکرد مدل‌های ترکیبی NF-GMDH و روابط تجربی

Table 5 Statistical evaluation of performance related to the NF-GMDH networks and empirical equations

SI	BIAS	RMSE	R	روش‌ها
0.32	-0.02	0.37	0.84	مدل NF-GMDH-PSO (آموزش)
0.36	-0.04	0.41	0.85	مدل NF-GMDH-GSA (آموزش)
0.32	-0.04	0.36	0.84	مدل NF-GMDH-GA (آموزش)
0.34	0.06	0.39	0.84	مدل NF-GMDH-PSO (آزمایش)
0.34	0.04	0.45	0.85	مدل NF-GMDH-GSA (آزمایش)
0.36	0.03	0.40	0.83	مدل NF-GMDH-GA (آزمایش)
0.37	0.13	0.43	0.80	$K_{d(T^*)} = 1 + 0.036\Delta A^{1.5}$
0.46	0.0056	0.51	0.799	$K_{d(T^*)} = 1 + 0.018\Delta A^{1.5}$
0.52	0.075	0.66	0.72	$K_{d(T^*)} = \frac{1.872(h/D_e)^{0.225} \cdot D_e}{2.4D}$
0.53	0.036	0.53	0.73	$K_{d(T^*)} = \left(\frac{D_e}{D}\right)^{0.745}$

آماري سه مدل پیشنهادی در مرحله آزمایش هم‌روندی مشابه مرحله آموزش داشت که در آن، دو الگوریتم PSO و GA دارای عملکرد نزدیک به هم بوده و مدل GSA دارای بهترین عملکرد در ضریب همبستگی می‌باشد. با این تفاوت که، شاخص‌های آماری مربوط به مرحله آموزش، دارای دقت پایین‌تری می‌باشند. در واقع، مقادیر R و RMSE برای مدل NF-GMDH-PSO

جدول (۵) نشان داد که، دو مدل NF-GMDH-PSO و NF-GMDH-GA ($R = 0.84$ و $RMSE = 0.37$) و NF-GMDH-GA ($R = 0.84$ و $RMSE = 0.36$) دارای عملکرد مشابه هستند. همچنین مدل NF-GMDH-GSA دارای بیشترین مقدار ضریب همبستگی ($R = 0.85$) است. و حال آنکه در دیگر شاخص‌های آماری عملکرد ضعیف‌تری نسبت به دو مدل دیگر دارد. پارامترهای

استخراج مقادیر پیش‌بینی شده از مدل NF-GMDH-PSO، به‌منظور انجام آنالیز حساسیت از روابط (۱۹) و (۲۰) استفاده می‌شود (Gandomi et al 2013):

$$N_i = f_{maz}(x_i) - f_{maz}(x_i) \quad (19)$$

$$S_i = \frac{N_i}{\sum_j^n N_j} \times 100 \quad (20)$$

در روابط (۱۹) و (۲۰)، $f_{maz}(x_i)$ و $f_{maz}(x_i)$ به ترتیب حداکثر و حداقل مقدار خروجی پیش‌بینی شده‌ی مربوط به دامنه ورودی Δ (تعداد پارامترهای ورودی) می‌باشد. در نهایت جدول (۶) درصد حساسیت پارامترهای ورودی را نشان می‌دهد. نتایج نشان داد که، درصد آنالیز حساسیت پارامترهای ورودی D/d_{50} و d_i/b با درصد حساسیت ۱۵/۲۴ و ۱۳ به ترتیب دارای بیشترین و کمترین تأثیر بر عمق آبشستگی می‌باشند. همچنین T^* به‌عنوان دومین پارامتر تأثیرگذار بر مقدار بیشترین عمق آبشستگی با درصد حساسیت ۱۵/۲۴ شناخته شد.

به‌ترتیب برابر ۰/۸۴۰ و ۰/۳۹، برای مدل NF-GMDH-GA برابر ۰/۸۳۲ و ۰/۴۰۳ و برای مدل NF-GMDH-GSA برابر ۰/۸۵ و ۰/۴۵۷ به‌دست آمد.

پارامترهای آماری به‌دست‌آمده نشان می‌دهد که روابط تجربی دارای عملکرد ضعیف‌تر و دقت کمتری نسبت به سه مدل پیشنهادی می‌باشند. به‌عنوان مثال پارامترهای خطای R و RMSE برای رابطه (۴) به‌ترتیب برابر ۰/۸۰ و ۰/۴۳۲ و همین‌طور برای رابطه (۵) به‌ترتیب برابر ۰/۷۹۹ و ۰/۵۱ به دست آمدند. در صورتی که مقادیر این پارامترها برای ضعیف‌ترین مدل از بین سه مدل پیشنهادی (NF-GMDH-GSA) به‌ترتیب برابر ۰/۸۵۹ و ۰/۴۵۷ می‌باشد.

در ادامه به‌منظور تعیین مؤثرترین متغیر ورودی در تخمین حداکثر عمق آبشستگی، آنالیز حساسیت صورت می‌گیرد. بدین منظور، ابتدا ۷ مدل مختلف در غیاب ۷ متغیر ورودی به ترتیب توسعه داده می‌شود. بعد از

جدول ۶- آنالیز حساسیت پارامترهای ورودی در مدل NF-GMDH-PSO با استفاده از روابط (۱۹) و (۲۰)
Table 6 Sensitivity analysis of input parameters used in NF-GMDH-PSO by the Eqs.(19) and (20)

h/d_a	h/D	D/d_{50}	D/b	ΔA	U/U_c	T^*	ورودی
13	13.54	15.34	14.03	14.63	14.22	15.24	درصد حساسیت

همبستگی نزدیک به هم (به ترتیب $R=0/8414$ و $R=0/8407$) بوده و عملکرد بهتر نسبت به مدل NF-GMDH-GSA می‌باشند.

۲- پارامترهای خطای محاسبه‌شده در مرحله آزمایش روش‌های پیشنهادی، بیان‌گر این مطلب بود که الگوریتم جامعه پرندگان و الگوریتم وراثتی دارای عملکرد مشابه و دقت بیشتر نسبت به الگوریتم جستجوی گرانشی بودند. در واقع مقادیر پارامترهای آماری بیانگر این مطلب می‌باشند به‌طوری‌که مقادیر R و RMSE برای مدل NF-GMDH-PSO به ترتیب ۰/۸۴ و ۰/۳۹، مدل NF-GMDH-GA برابر ۰/۸۳۲ و ۰/۴۰۳ و برای مدل NF-GMDH-GSA برابر ۰/۸۵ و ۰/۴۵۷ حاصل شدند.

۴- نتیجه‌گیری

در پژوهش حاضر، بیش‌ترین عمق آبشستگی اطراف پایه پل تحت اثر موانع شناور با استفاده از ساختار شبکه جلو رونده NF-GMDH تخمین زده شد. ساختار مدل پیش‌بینی کننده NF-GMDH با استفاده از الگوریتم‌های بهینه‌ساز PSO، GSA و GA توسعه یافت و شبکه‌ای سه لایه متشکل از ۶۳ توصیفگر جزئی ایجاد شد. بر این اساس، یافته‌های پژوهش حاضر را می‌توان به‌صورت زیر بیان نمود:

۱- در مرحله آموزش عملکرد ترکیب‌های بهینه‌ساز NF-GMDH نشان داد که دو مدل NF-GMDH-PSO و NF-GMDH-GA دارای دقت مشابه با ضریب

۴- نتایج حاصل‌شده از آنالیز حساسیت نشان دادند که پارامترهای بدون بعد D/d_{50} (نسبت قطر پایه به‌اندازه متوسط رسوبات) و d_a/b (نسبت قطر موانع به عرض کانال) به ترتیب دارای بیشترین و کمترین تأثیر بر روی عمق آبشستگی می‌باشند.

۳- روابط تجربی مربوط به مطالعات Melville and Pagliara and Carnacina و Sutherland (1988) (2011) که بر مبنای رگرسیونی بودند، نتوانستند تقریب دقیقی به‌منظور پیش‌بینی پارامتر حداکثر عمق آبشستگی ایجاد کنند.

References

- Azamathulla H. Md., Ghani A. A., Zakaria N.A. and Guven A. (2010). Genetic programming to predict bridge pier scour. *J. Hydraul. Eng.*, 136 (3), 165-169.
- Bateni S. M., and Jeng D. S. (2007). Estimation of pile group using adaptive neuro-fuzzy approach. *Ocean. Eng.*, 34(8-9), 1344-1354.
- Etemad-Shahidi A. and Ghaemi, N. (2011). Model tree approach for prediction of pile groups scour due to waves. *Ocean. Eng.*, 38(13), 1522-1527.
- Holland, J. H. (1976). *Adaptation, "Progress in Theoretical Biology, 4,"* R. Rosen and F. M. Snell, eds., Academic Press, New York.
- Keshavarz-Mehr M. (2012). *Neural Networks, Fuzzy Logic, and Genetic Algorithm: Combination and application.* Noorpardazan Press [In Persian].
- Kennedy J. and Eberhart, R. C. (1995). Particle swarm optimization. *Proceedings of IEEE International Conference on Neural Networks 4.*
- Lagasse P. F., Zevenbergen L. W. and Clopper P. E. (2010). Impacts of Debris on Bridge Pier Scour. *Proceedings of the 33rd IAHR Congress, IAHR, Madrid, 3967-3974.*
- Laursen E. M. and Toch A. (1956). Scour around bridge piers and abutments. Iowa Highway Research Board Ames, IA, USA.
- Melville B. W. and Sutherland A. J. (1988). Design method for local scour at bridge piers. *J. Hydraul. Eng.*, 114 (10), 1210-1226.
- Melville B. W. and Dongol D. M. (1992). Bridge pier scour with debris accumulation. *J. Hydraul. Eng.*, 118 (9), 1306-1310.
- Melville B. W. and Chiew Y. M. (1999). Time scale for local scour at bridge piers. *J. Hydraul. Eng.*, 125(1), 59-65.
- Nagasaka K., Ichihashi H. and Leonard R. (1995). Neuro-fuzzy GMDH and its application to modeling grinding characteristics. *Int. J. Prod. Res., Production Research.* 33(5), 1229-1240.
- Najafzadeh M., Barani G. A. and Hessami M. R. (2013a). Group method of data handling to predict scour depth around vertical piles under regular waves. *Iran. J. Sci. Technol.*, 20(3), 406-413.
- Najafzadeh M., Barani G. A. and Hessami M. R. (2013b). Abutment scour in clear-water and live-bed conditions by GMDH network. *Water. Sci. Technol.*, 67(5), 1121-1128.
- Najafzadeh M., Barani G. A. and Hessami M. R. (2014). Group method of data handling to predict scour at downstream of a ski-jump bucket spillway. *J. Earth.Inform.*, 7(4), 231-248.
- Najafzadeh M., Barani G. A. and Hessami M. R. (2015). Evaluation of GMDH networks for prediction of local scour depth at bridge abutments in coarse sediments with thinly armored beds. *Ocean. Eng.*, 104, 387-396.
- Najafzadeh M. (2015). Neuro-fuzzy GMDH systems based evolutionary algorithms to predict scour pile groups in clear water conditions. *Ocean. Eng.*, 99, 85-4.

- Najafzadeh M. and Lim S. Y. (2015). Application of improved neuro-fuzzy GMDH to predict scour depth at sluice gates. *Earth. Sci. Inform.*, 8(1), 187-196.
- Pagliara S. and Carnacina I. (2011). Influence of Wood Debris Accumulation on Bridge Pier Scour. *J. Hydraul. Eng.*, 137(2), 254-261.
- Rashedi E., Nezamabadi-pour H. and Saryazdi S. (2009). GSA: a gravitational search algorithm. *J. Inform. Sci.*, 179 (13), 2232-2248.
- Takashi O., Hidetomo I., Tetsuya M. and Kazunori N. (1998). Orthogonal and successive projection methods for the learning of neurofuzzy GMDH. *J. Inform. Sci.*, 10 (1-2), 5-24.
- Zounemat-Kermani M., Beheshti A. A., Ataie-Ashtiani B. and Sabbagh-Yazdia S. R. (2009). Estimation of current-induced scour depth around pile groups using neural network and adaptive neuro-fuzzy inference system. *Appl. Soft. Comput.*, 9 (2), 746-755.

Estimation of the Maximum Scour Depth at Bridge Pier under Effects of Debris Accumulations using NF-GMDH Model and Evolutionary Algorithms

Mohammad Najafzadeh^{1*} and Mohammad Mahmoudi-rad²

¹Assist. Professor, Department of Water Engineering, Faculty Civil and Surveying Engineering, Graduate University of Advanced Industrial Technology, Kerman, Iran

²Alumni, Department of Water Engineering, Faculty of Civil and Surveying Engineering, Graduate University of Advanced Technology, Kerman, Iran

*Corresponding author: m.najafzadeh@kgut.ac.ir

Original Paper

Received: June 30, 2019

Revised: October 11, 2019

Accepted: October 22, 2019

Abstract

Rivers accumulate huge amounts of floating debris including the trunk, branches and leaves during the floods, leading to increase the depth of local scour around bridge piers. A large number of the laboratorial and field studies have been performed to understand the mechanism of scouring phenomenon under floating debris. Over two past decades, different types of the artificial intelligence methods have been used to estimate the maximum scour depth around bridges piers. In this study, the Neuro-Fuzzy model based on group method data handling (NF-GMDH) was used to estimate the scour under effect of debris accumulations. The NF-GMDH network was developed using evolutionary algorithms: genetic algorithm (GA), particle swarm optimization (PSO), and gravitational search algorithm (GSA). Parameters effective on the maximum scour depth included average velocity of upstream flow of the bridge pier, critical velocity of river bed sediments, depth of flow in section without debris, thickness of submerged debris, debris diameter, average particle size, pier diameter, and channel width. After training and experiencing each NF-GMDH models, the performances of each one was evaluated through statistical parameters. The results showed that the models proposed had better performance compared with empirical relationships. NF-GMDH-PSO ($R=0.8413$ and $RMSE=0.37$) and NF-GMDH-GA ($R=0.8407$ and $RMSE=0.3640$) had relatively similar performance. Finally, sensitivity analysis indicated that the ratio of pile diameter (D) to mean diameter of bed sediments (d_{50}) has the most influence on determination of maximum scour depth.

Key word: Bridge Pier; Debris Accumulation; Evolutionary Algorithms; NF-GMDH Scour.