

Evaluation of Different Weighting Methods to Predict Scour Depth on Grade Control Structures

Somayeh Ghaznavi ¹, Seyed Morteza Seyedian ^{2*}, Abolhasan Fathabadi ³, Masoomeh Farasati ⁴

1- Graduate Student, Natural Resources Department, Faculty of Agriculture & Natural Resources, University of Gonbad-Kavous, Gonbad-Kavous.

2- Assistant Professor in Hydraulic Structures, Natural Resources Department, Faculty of Agriculture & Natural Resources, University of Gonbad-Kavous, Gonbad-Kavous.

3- Assistant Professor in Watershed Management, Natural Resources Department, Faculty of Agriculture & Natural Resources, University of Gonbad-Kavous, Gonbad-Kavous.

4- Associated Professor in Hydraulic Engineering, Natural Resources Department, Faculty of Agriculture & Natural Resources, University of Gonbad-Kavous, Gonbad-Kavous.

*s.m.seyedian@gmail.com

Received: 8 April 2019, Accepted: 26 March 2020  J. Hydraul. Homepage: www.jhyd.iha.ir

Abstract

Introduction: The scour at the downstream of the structure may cause structural instability and finally structural damage. Therefore, it is necessary to estimate and predict the depth of scour downstream of structures before constructed. Empirical equation to predict the depth of scour is always has error and reduces the accuracy of the results. Therefore, in last decade, the method of combining models has been used to increase the accuracy of predictions in different sciences. Instead of choosing the best single model for a specific condition, which is a traditional task, it is recommended to use a single model combination method, which will result outputs of the combination model is better in all conditions. The purpose of this study is to estimate scour depth using different combination methods by combining empirical equations (single). The single equations were also compared before and after bias correction.

Methodology: In this study 306 data set are used, including 264 laboratory and 42 field data. Randomly, 75% (230 data set) of the total data were choose for training and the remaining 25% (76 data) were choose for testing the combination models. Different technique including Shu and burn, EWA, GRA, BGA, AICA, BICA, KNN and LS-SVM have been used to combine single model. Bias correction has been performed to each model before using combination models. It was determined by the ordinary least squares estimator (OLS) using training data set in each model.

Results and discussion: In this study bias correction was perform on single model. In general, the slope and intercept of the single equation indicate that the scour depth predicted by a single equation is greater than measured scour depth. The best estimation before bias correction is Mason and Arumugam and the National Institute of Hydraulic Laboratory Science and Technology (National Institute) equation. The National Institution's equation is chosen as the best single model before bias correction. After bias correction, the error of all single equations has been reduced and Mason and Arumugam equation with correlation

coefficient of 0.74 and error value of 0.23 m has the highest correlation and least error among single equations. The error values of the Machado, Martins, and National Institute equations are approximately the same, with very little difference (about 0.01) with the Mason and Arumugam equation. The results showed that after bias correction the Mason and Arumugam predicted scour depth more accurately and selected as the best single equation after bias correction. The equations of Martins, Machado, National Institute, Mason and Arumugam, D'Agostino and Ferro were considered as inputs (independent variable) and scour depth as outputs (dependent variable) of combination methods. Before bias correction, the correlation coefficient and error of the direct weighting methods showed that the GRA method has the least error in predicting scour depth (RMSE = 0.25) and the W2 method has more error than this method (RMSE = 0.31). Comparison of direct weighted combination methods with single equations before bias correction showed that the GRA method has much less error than the best single equation (National Institute). The AICA and BICA combination methods provided the best estimate before bias correction in indirect weighting methods and the results are similar to the best single equation before bias correction ($R^2 = 0.70$, RMSE = 0.87). All three indirect weighting methods produce approximately the same results after bias correction. The error of indirect weighting methods decreased about 70% after bias correction compared to pre-correction. The results showed that artificial intelligence combination method (LS-SVM) scour depth prediction after bias correction are similar to the results before bias correction.

Conclusion: Due to the scour depth uncertainty estimation by the empirical equations, the purpose of this study was to estimate scour depth downstream of structures using combination of empirical equations (combined methods). The National Institute and Mason and Arumugam equations was selected as the best single (empirical) equations before and after bias correction, respectively. The accuracy of combination methods increased because of low accuracy of single equations before bias correction, but after bias the accuracy of combination methods did not much change with single equations. Comparison of direct weighting methods showed that GRA is the best method and has much less error than the best single equation before bias correction, but after bias correction the EWA method is the best combination method and its almost similar to the best single equation after bias correction. The results of the artificial intelligence method (LS-SVM) were same as the local weighting method before and after bias correction. LS-SVM was able to greatly increase the accuracy of the estimation by combining the single equation before bias correction, but after bias correction the effect of the combination of the individual relations was reduced and the scour depth estimation as same to the single equation.

Keywords: Bias correction, Combined methods, Empirical equations, Scour depth.

ارزیابی روش‌های مختلف وزن‌دهی برای پیش‌بینی عمق آبشستگی پایین دست سازه‌های تثبیت بستر

سمیه غزنوی^۱، سیدمرتضی سیدیان^{۲*}، ابوالحسن فتح‌آبادی^۳، معصومه فراستی^۴

۱- دانش آموخته کارشناسی ارشد، دانشکده کشاورزی، دانشگاه گنبدکاووس

۲- استادیار مهندسی آب، دانشکده کشاورزی، دانشگاه گنبدکاووس

۳- استادیار آبخیزداری، دانشکده کشاورزی، دانشگاه گنبدکاووس

۴- دانشیار مهندسی آب، دانشکده کشاورزی، دانشگاه گنبدکاووس

*s.m.seyedian@gmail.com

دریافت: ۱۳۹۸/۰۱/۱۹، پذیرش: ۱۳۹۹/۰۱/۰۷ ☪ وب‌گاه نشریه هیدرولیک: www.jhyd.iha.ir

چکیده: تخمین عمق آبشستگی سازه از اهمیت زیادی برخوردار است. محققین بر مبنای کارهای آزمایشگاهی و صحرایی روابط تجربی متعددی ارائه داده‌اند ولی تاکنون رابطه‌ای که در شرایط مختلف نتایج قابل قبولی داشته باشد شناخته نشده است. در این پژوهش دقت روابط مختلف تجربی (منفرد) در دو مرحله‌ی قبل و بعد از اصلاح آریبی مورد ارزیابی قرار گرفتند. نتایج نشان می‌دهد قبل و بعد از اصلاح آریبی به ترتیب روابط منفرد مؤسسه ملی و ماسون با میانگین مربعات خطای ۰/۸۷ و ۰/۲۳ متر بیشترین دقت را دارند. ترکیب روابط منفرد با مدل‌های ترکیبی نشان می‌دهد از بین روش‌های مستقیم در مرحله‌ی قبل و بعد از اصلاح آریبی به ترتیب روش GRA و EWA با میانگین مربعات خطای ۰/۲۵ و ۰/۲۳ متر بیشترین دقت را داشته است. خطای روش‌های ترکیبی غیرمستقیم AICA و BICA در مرحله‌ی قبل و بعد از اصلاح آریبی مشابه بهترین رابطه‌ی منفرد است و نتوانسته‌اند نتایج روابط منفرد را بهبود بخشند. نتایج روش موضعی (KNN) و روش هوش مصنوعی (LS-SVM) قبل و بعد از اصلاح آریبی برابر بوده و عمق آبشستگی را با دقت بیشتری نسبت به روابط منفرد برآورد کرده‌اند. مقایسه‌ی روش‌های مختلف ترکیبی در مرحله‌ی قبل و بعد از اصلاح آریبی نشان داد که کم‌ترین خطا با میانگین مربعات خطای ۰/۱۸ و ۰/۱۹ متر به ترتیب مربوط به LS-SVM و KNN می‌باشد. در این پژوهش مشخص شد که ترکیب روابط منفرد حداکثر عمق آبشستگی با استفاده از روش‌های مختلف ترکیبی می‌تواند دقت پیش‌بینی را بهبود بخشد.

کلید واژگان: اصلاح آریبی، روابط تجربی، روش‌های ترکیبی، عمق آبشستگی.

۱- مقدمه

می‌شود. بنابراین از اوایل دهه‌ی قبل، روش ترکیب مدل‌ها برای افزایش دقت پیش‌بینی‌های کوتاه‌مدت و بلندمدت زمانی، مکانی و زمانی- مکانی در علوم مختلف به کار گرفته شده است. هر یک از مدل‌های منفرد که به عنوان ورودی به مدل ترکیبی معرفی می‌شوند دارای نقاط قوت و ضعفی هستند. به جای انتخاب بهترین مدل منفرد برای یک شرایط مشخص که یک کار سنتی و تکراری می‌باشد توصیه می‌شود از روش ترکیب مدل‌های منفرد استفاده شود که باعث می‌شود خروجی‌های مدل ترکیبی دارای نتایج بهتری در تمام شرایط باشد (Diks and Vrugt, 2010).

جریان عمودی رو به پایین آب و ایجاد جریان‌های متلاطم موضعی، باعث ایجاد حفره و فرسایش در پایین دست سازه‌ها می‌شود و پدیده‌ی پیچیده‌ی آبشستگی رخ می‌دهد. آبشستگی ایجاد شده در پایین دست سازه ممکن است باعث ناپایداری سازه و در نهایت تخریب سازه شود. بنابراین تخمین و پیش‌بینی عمق آبشستگی ایجاد شده در پایین دست سازه‌ها قبل از ساخت آن‌ها امری لازم و ضروری می‌باشد (Shafai Bajestan, 2011). استفاده از روابط تجربی برای پیش‌بینی عمق آبشستگی همواره با خطا همراه می‌باشد که غیرقابل اجتناب است و باعث کاهش دقت نتایج

شده است. (Pourreza Bilondi et al. (2015) رواناب روزانه را با دو مدل LS-SVM⁸ و مدل هیدرولوژیکی و مفهومی Hymod شبیه‌سازی کردند. نتایج بیانگر برتری نسبی LS-SVM می‌باشد.

Jovanovic et al. (2015) برای پیش‌بینی مصرف انرژی گرمایی دانشگاه از روش‌های ترکیبی و شبکه‌های عصبی استفاده کردند و نشان دادند شبکه‌ی عصبی با ترکیب مدل‌های منفرد دارای دقت زیادی است. Tahmasebi (2016) از شبکه‌های عصبی و تکنیک ترکیب داده‌ها برای تخمین دبی سیلاب استفاده کردند. نتایج نشان داد که فرآیند بارش-رواناب با استفاده از ترکیب داده‌های چند مدل منفرد، نتایجی با دقت بالا ارائه می‌کند.

Moazami et al. (2017) قابلیت روش‌های هوش مصنوعی را ارزیابی و نتیجه گرفتند که برای پیش‌بینی سایر پدیده‌ها در زمینه‌های مختلف علوم و مهندسی استفاده می‌شوند. هدف از انجام این پژوهش تخمین و برآورد آبشستگی پایین‌دست سازه‌ها با ترکیب روابط تجربی (منفرد) با استفاده از روش‌های ترکیبی مختلف می‌باشد. همچنین روابط منفرد قبل و بعد از اصلاح اریبی ترکیب و نتایج مقایسه می‌گردد.

۲- مواد و روش

۲-۱- روابط تجربی (روابط منفرد)

فرایند شماتیک آبشستگی در شکل ۱ آورده شده است. جدول ۱ روابط تجربی مورد استفاده در این تحقیق شامل (Martins (1975), Machado (1980), Panahi et al. (2014), INCYTH LHA (1981), Mason and Arumugam (1985), D'Agostino and Ferro (2004) را نشان می‌دهد.

در این روابط، S عمق آبشستگی، H اختلاف عمق بالادست و عمق پایین‌دست، q دبی آب در واحد عرض، d_{90} قطر مشخصه‌ی مصالح که ۹۰ درصد وزن مصالح از آن ریزتر است، g شتاب گرانشی، d_{50} قطر مشخصه‌ی مصالح که ۵۰ درصد وزن مصالح از آن ریزتر است، h عمق آب در

(Vrugt (2010) هفت روش ترکیبی (EWA^1 , $AICA^2$, $BICA^3$, BGA^4 , GRA^5 , BMA^6 , MMA^7) را مقایسه کردند و نشان دادند عملکرد روش‌های بدون محدودیت (وزن‌ها فقط محدود به جمع نیستند) بهتر از روش‌های محدود است و به‌طور کلی روش GRA بهتر است زیرا سریع‌تر از MMA و BMA می‌باشد در حالی که عملکرد مشابهی دارد. (Malone et al. (2014) برای ترکیب نقشه از روش‌های میانگین مدل و کریجینگ استفاده کردند و نشان دادند دقت پیش‌بینی‌ها بهبود یافته است. آن‌ها روش GRA را برای نقشه‌های دیجیتالی پیشنهاد دادند زیرا عملکرد آن برابر یا بهتر از روش BMA می‌باشد و محاسبات آن بسیار ساده‌تر و مؤثرتر است. (Dobarco et al. (2017) با استفاده از ۲ مدل ترکیبی، نقشه‌ی بافت خاک سطحی را بررسی کردند. نتایج نشان داد مدل‌های ترکیبی در بعضی موارد دارای خطای کمتر و همبستگی بیشتر می‌باشد. (Arsenault et al. (2015) جریان مداوم هیدرولوژیکی را با ۹ روش شبیه‌سازی کردند و نشان دادند روش میانگین‌گیری مدل‌ها مؤثرتر و کاراتر از مدل‌های منفرد می‌باشد. (Dehghani and Abdi Dehkordi (2014) و (Mehraein and Meraji (2017) روابط تجربی آبشستگی را با استفاده از الگوریتم‌های بهینه‌سازی بهبود دادند.

در صورتی که ارتباط بین ورودی و خروجی از قبل به‌طور کامل مشخص نباشد استفاده از الگوریتم‌های غیرپارامتریک سودمند و مؤثر خواهد بود (Sharma and O'Neill, 2002; Yakowitz, 1993). کاربردهای وسیع تکنیک‌های غیرپارامتریک در زمینه‌های مختلف بیانگر کارایی بالای این تکنیک می‌باشد. (Ayoubi et al. (2016) به‌منظور پیش‌بینی شوری خاک از مقایسه‌ی مدل نزدیک‌ترین همسایه و شبکه‌ی عصبی به این نتیجه رسیدند که روش نزدیک‌ترین همسایه دارای دقت بیشتری است. (Zolfaghari et al. (2016) پیش‌بینی عملکرد ظرفیت تبادل کاتیون خاک را با استفاده از روش شبکه‌ی عصبی و روش نزدیک‌ترین همسایه مقایسه کردند و نشان دادند که تفاوت معنی‌داری بین روش نزدیک‌ترین همسایه و شبکه‌ی عصبی وجود ندارد و هر دو روش از کارایی بالایی برخوردار هستند. در دهه‌ی اخیر از هوش مصنوعی در کارهای مختلف استفاده

⁵ Granger Ramanathan Averaging

⁶ Bayesian Model Averaging

⁷ Mallows Model Averaging

⁸ Least Square Support Vector Machines

¹ Equal Weights Averaging

² Akaike's Information Criteria Averaging

³ Bayes Information Criteria Averaging

⁴ Bates Granger Averaging




Fig. 1 Sketch of the scour downstream of grade control structures (Güven and Günel, 2008)

شکل ۱ طرح شماتیک آبشستگی پایین دست سازه های تثبیت

بستر (Güven and Günel, 2008)

پایین دست، Z ارتفاع سازه، b عرض سرریز، B عرض سازه و A₅₀ با استفاده از رابطه ۱ محاسبه می شود.

$$A_{50} = \frac{Q}{bz \left[g d_{50} \left(\frac{\rho_s - \rho}{\rho} \right) \right]^{\frac{1}{2}}} \quad (1)$$

در این رابطه Q دبی آب، ρ_s چگالی ذرات بستر و ρ چگالی آب می باشند.

جدول ۱ روابط تجربی تخمین عمق آبشستگی پایین دست سازه های تثبیت بستر

Table 1 Empirical relationships for scour depth prediction downstream of grade control structures

Number	Relationships	Author
1	$S = 1.5H^{0.1}q^{0.6}$	Martins (1975)
2	$S = \frac{1.35q^{0.5}H^{0.3145}}{d_{90}^{0.0645}}$	Machado (1980)
3	$S = 1.413q^{0.5}H^{0.25}$	National Institute of Science and Technology Laboratory of Hydraulics (1981)
4	$\frac{S}{\left(\frac{q^2}{g}\right)^{\frac{1}{3}}} = (6.42 - 3.10H^{0.1})g^{\frac{-H}{600}} \left(\frac{gH^3}{q^2}\right)^{20 + \frac{H}{600}} \left(\frac{H}{d_{50}}\right)^{\frac{1}{10}} \left(\frac{h}{H}\right)^{\frac{3}{20}}$	Mason and Arumugam (1985)
5	$\frac{S}{z} = 0.540 \left(\frac{b}{z}\right)^{0.593} \left(\frac{h}{H}\right)^{-0.126} (A_{50})^{0.544} \left(\frac{d_{90}}{d_{50}}\right)^{-0.856} \left(\frac{b}{B}\right)^{-0.751}$	D'Agostino and Ferro (2004)

صحرائی شامل داده های رودخانه میسیاگا و Falciai and Giacomini (1978) می باشد (جدول ۲). به صورت تصادفی، ۷۵ درصد (۲۳۰ داده) از مجموع داده ها برای آموزش و ۲۵ درصد (۷۶ داده) باقیمانده برای آزمون مدل های ترکیبی انتخاب گردید.

۲-۲- داده های مورد استفاده

در این پژوهش ۳۰۶ داده مورد استفاده قرار گرفته است که شامل ۲۶۴ داده آزمایشگاهی شامل Veronese (1937)، D'Agostino and Ferro (1994)، Lenzi et al. (2000)، Mossa (1998) و Bormann and Julien (1991) و ۴۲ داده

جدول ۲ مجموعه داده های آزمایشگاهی و صحرائی مورد استفاده

Table 2 used Laboratory and field data sets

investigator	Number	data type
Veronese (1937)	36	Laboratory
Borman and Julien (1991)	82	Laboratory
D'Agostino and Ferro (1994)	114	Laboratory
Mossa (1998)	19	Laboratory
Lenzi et al (2000)	13	Laboratory
Falciai and Giacomini (1978)	29	Field data
Missiga stream	13	Field data

جدول ۳ مشخصات آماری پارامترهای مؤثر بر آبشستگی برای کل داده‌ها

Table 3 Statistical characteristics of scour effective parameters in all of data

Parameters	Minimum	Maximum	Average	Standard deviation	Coefficient of Variation	Skewness
Difference in upstream depth and the tail water depth (H) (m)	0.02	5.17	0.75	0.80	1.06	2.98
Water discharge per unit weir width (q) ($\frac{m^2}{s}$)	0.005	13.40	0.88	1.74	1.96	3.42
Particle diameter (d_m) (m)	0.0030	0.10	0.01	0.02	1.51	2.09
Tail water depth (h) (m)	0.03	5.00	0.61	0.75	1.22	2.57
Channel width (B) (m)	0.30	25.00	2.12	4.17	1.97	2.97
Weir width (b) (m)	0.15	25.00	2.03	4.21	2.07	2.95
Weir height (Z) (m)	0.02	6.20	0.73	0.97	1.32	3.40

از تابع رابطه ۴ را به‌عنوان تابع هدف پیشنهاد دادند.

$$V = \sum_{i=1}^m \left[\frac{\hat{y}_i - \sum_{k=1}^K w_k X_{i,t}}{\hat{y}_i} \right]^2 \quad w_i > 0 \quad (4)$$

V مقدار خطا، w_i وزن مدل i ام

۲-۳-۱-۲ روش میانگین وزن‌های برابر (EWA)

در این روش وزن هر ورودی به‌صورت یکسان با ورودی‌های دیگر تعیین می‌گردد که این وزن‌ها مستقل از داده‌ی آموزش هستند و نتایج پیش‌بینی به‌صورت رابطه‌ی ۵ که معادل مجموع متوسط (میانگین) پیش‌بینی است، می‌باشد.

$$\hat{y}_i = \frac{1}{K} \sum_{k=1}^K X_{i,t} \quad (5)$$

که در این رابطه K تعداد مدل‌ها است.

۲-۳-۱-۳ روش میانگین گرنجر - راماناتان (GRA)

این روش طرح‌های وزنی توصیف شده قبلی کواریانس را که ممکن است در خطاهای پیش‌بینی مدل‌های انفرادی ارائه شوند به‌کار نمی‌برد. یک راه طبیعی برای حضور کواریانس استفاده از تخمین‌گر حداقل مربعات معمولی^۱ (OLS) در مدل رگرسیون خطی می‌باشد. روش OLS توسط Granger and Ramanathan (1984) برای ترکیبی پیشنهاد شده است که با استفاده از OLS وزن‌های مدل رگرسیون خطی را تخمین بزند. تحت فرضیات استاندارد اساسی مدل رگرسیون خطی، تخمین‌گر OLS نشان‌دهنده‌ی بهترین تخمین‌گر خطی غیر مستقیم β می‌باشد.

۲-۳-۲ روش‌های ترکیبی

مدل کلی برای روش‌های ترکیبی به‌صورت رابطه ۲ می‌باشد (Malone et al, 2014).

$$Y_i = \sum_{k=1}^K w_k X_{ik} \quad (2)$$

که K تعداد مدل‌های منفرد، X_{ik} خروجی مدل منفرد k ام می‌باشد که به‌عنوان ورودی به مدل ترکیبی معرفی می‌گردد w_k وزن‌هایی که به مدل‌های منفرد داده می‌شود و Y_i خروجی مدل ترکیبی برای ورودی i می‌باشد.

۲-۳-۱-۲ روش وزنی مستقیم

۲-۳-۱-۱-۲ روش Shu and burn (w_2)

در این تحقیق از تکنیک Shu and burn برای محاسبه‌ی وزن مدل‌های منفرد استفاده شده است. در اولین سطح هر یک از مدل‌های منفرد آموزش داده می‌شوند و ساختار بهینه‌ی آن‌ها تعیین می‌گردد. در دومین سطح با در نظر گرفتن وزن برای هر مدل منفرد، خروجی هر یک از مدل‌های منفرد با یکدیگر ترکیب می‌شوند تا خروجی نهایی محاسبه شود.

$$\hat{y}_i = \sum_{i=1}^k w_i X_{i,t} \quad i=1 \dots m \quad (3)$$

\hat{y}_i خروجی مدل ترکیبی با استفاده از وزن‌های بهینه در زمان t ، K تعداد مدل‌ها و $X_{i,t}$ مقادیر خروجی مدل i در زمان t .

برای بهینه‌سازی تابع فوق (Shu and Burn (2004) استفاده

¹ Ordinary Least Squares

در این روابط K تعداد پارامترهای مدل، n تعداد داده‌های مشاهداتی دوره‌ی واسنجی و $l(M|data)$ تابع احتمال مدل با توجه به داده‌های مشاهداتی است.

۲-۳-۳- وزن‌دهی موضعی

۲-۳-۳-۱- روش K- نزدیک‌ترین همسایه (KNN)
الگوریتم نزدیک‌ترین همسایه یکی از الگوریتم‌های غیرپارامتریک می‌باشد. این روش برخلاف توابع انتقالی کلاسیک از هیچ تابع ریاضیاتی از پیش تعیین شده برای تخمین متغیرهای مختلف استفاده نمی‌کند. برای اجرای این روش از داده‌های مرجع (همان تعداد K همسایه) استفاده می‌شود که داده‌های مرجع مشابه داده‌های آموزش یا واسنجی در روش‌های انتقالی کلاسیک می‌باشد (Jalali and Homaei, 2011).

۲-۳-۴- هوش مصنوعی

۲-۳-۴-۱- روش حداقل مربعات ماشین بردار پشتیبان (LS-SVM)
روش حداقل مربعات ماشین بردار پشتیبان اولین بار توسط وپنیک با نام ماشین بردار پشتیبان در سال ۱۹۹۵ تا ۱۹۹۸ بر پایه‌ی تئوری یادگیری آماری که از حداقل‌سازی ریسک ساختاری تبعیت می‌کند، ارائه شده است (Vapnik, 1998). برای حل مدل ماشین بردار پشتیبان از برنامه‌ریزی درجه دو استفاده می‌شود. زمانی که بخواهیم مسئله‌ای در ابعاد بزرگ محاسبه شود، ممکن است محاسبات دارای پیچیدگی زیادی شود. به همین دلیل روش حداقل مربعات توسط Suykens and Vandewalle (1999) برای ماشین‌های بردار پشتیبان طراحی شد که مسئله‌ی بهینه‌سازی رگرسیون غیرخطی را از طریق حداقل‌سازی تابع هدف در رابطه‌ی ۱۱ و محدودیت با رابطه‌ی ۱۲ تعیین می‌کند.

$$\min_{w,e,b} j(w,e) = \frac{1}{2} w^T w + \frac{\lambda}{2} \sum_{i=1}^N e_i^2 \quad (11)$$

$$y_i = w^T \varphi(x_i) + b + e_i \quad (12)$$

که در این رابطه γ و e به ترتیب پارامتر تنظیم‌کننده‌ی بخش خطا و میزان خطا می‌باشد. مقدار γ همواری تابع تقریب را کنترل می‌کند که مقدار بزرگتر آن خطای بیشتری ایجاد می‌کند و ماشین یادگیری را پیچیده‌تر می‌سازد و مقدار کوچکتر آن منجر به خطاهایی می‌شود که مجاز می‌باشد اما

$$\hat{\beta}_{gra} = (X^T X)^{-1} X^T Y \quad (6)$$

۲-۳-۲- وزن‌دهی غیر مستقیم

۲-۳-۲-۱- روش میانگین بیتز- گرنجر (BGA)

روش BGA اولین بار توسط Bates and Granger (1969) پیشنهاد شد. در این روش وزن هر مدل متناسب با مقدار واریانس پیش‌بینی (σ_i^2) در دوره‌ی آموزش است. وزن‌ها در جهتی بهینه می‌شوند که خروجی مدل کم‌ترین ریشه‌ی میانگین مربعات ممکن را تولید کنند. اگر برآوردها نارباب باشند و مقادیر باقیمانده فاقد همبستگی باشند این وزن‌ها با ایجاد یک برآوردها که خروجی با کم‌ترین مقدار ریشه‌ی میانگین مربعات را تولید می‌کند، وزن‌های بهینه هستند. با این حال وزن هر عضو به‌عنوان معکوسی از واریانس اعضا به‌صورت رابطه ۷ محاسبه می‌شود.

$$w_i = \frac{1/\sigma_i^2}{\sum_{i=1}^k 1/\sigma_i^2} \quad (7)$$

w_i وزن هر مدل، $\hat{\sigma}_i^2$ نشان‌دهنده‌ی واریانس پیش‌بینی مدل i که به‌عنوان واریانس نمونه از خطای پیش‌بینی در دوره آموزش به‌صورت رابطه ۸ تخمین زده می‌شود (Diks and Vrugt, 2010).

$$\hat{\sigma}_i^2 = \frac{1}{k} \sum_{i=1}^k (\tilde{y}_i - X_i)^2 \quad (8)$$

\tilde{y}_i مقدار مشاهداتی است.

۲-۳-۲-۲- روش میانگین معیار اطلاعات آکایک و بیکا (AICA and BICA)

در این دو روش علاوه بر کارایی مدل، ساختار مدل نیز در وزن‌دهی روش‌های مختلف در نظر گرفته می‌شود. در این حالت فرض می‌شود چنانچه دو مدل کارایی یکسانی در دوره‌ی آموزش داشته باشند مدلی بهتر است که ساختار ساده و تعداد پارامتر کم‌تری دارد. اختلاف بین روش‌های AICA و BICA در نحوه‌ی اعمال تعداد پارامترها در تعیین وزن‌ها است. در روش AICA تابع جریمه دو برابر تعداد پارامترهای آموزش است (رابطه‌ی ۹). برای BICA تابع جریمه برابر با ضرب تعداد پارامترهای مدل در لگاریتم تعداد داده‌های مشاهداتی در دوره‌ی آموزش است (رابطه‌ی ۱۰) (Burnham and Anderson, 2002; Hansen, 2008).

$$AICA = -2 \log(l(M|data)) + 2K \quad (9)$$

$$BICA = -2 \log(l(M|data)) + \ln(n)K \quad (10)$$

در این روابط P شامل مقادیر محاسباتی (پیش‌بینی شده)، O شامل مقادیر مشاهداتی (اندازه‌گیری شده)، \bar{O} میانگین مقادیر مشاهداتی و n تعداد داده‌ها می‌باشد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (14)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (15)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i) \quad (16)$$

اگر تمامی داده‌های محاسباتی و مشاهداتی یکسان باشند نتایج شاخص‌های آماری به صورت $MBE=0$, $RMSE=0$ و $R^2=1$ خواهد بود.

۴- نتایج و بحث

۴-۱- روابط تجربی (مدل‌های منفرد)

تاکنون روابط متعددی برای برآورد حداکثر عمق آبستنگی با استفاده از داده‌های آزمایشگاهی و صحرایی در پایین دست سازه‌های تثبیت‌کننده‌ی بستر ارائه شده است. در این تحقیق با استفاده از رابطه (۱۳) بر روی روابط منفرد اصلاح اریبی صورت گرفت. ضرایب اصلاح اریبی برای هر رابطه در جدول ۴ آورده شده است. میانگین پارامتر شیب در این روابط حدود ۰/۳ می‌باشد که نشان می‌دهد این روابط بیش-برآوردی قابل توجهی دارند. همچنین مقدار عرض از مبدأ روابط منفرد به جز رابطه داگوستینو و فروو (۲۰۰۴) حدود ۰/۷ می‌باشد که مقدار کمی است. به طور کلی شیب و عرض از مبدأ روابط منفرد نشان می‌دهد مقدار عمق آبستنگی پیش‌بینی شده توسط روابط منفرد بیشتر از مقدار عمق آبستنگی اندازه‌گیری شده می‌باشد. نتایج مربوط به ۵ رابطه تجربی برآورد عمق آبستنگی (مدل‌های منفرد) قبل و بعد از اصلاح اریبی در جدول ۵ آورده شده است.

ممکن است قدرت ماشین یادگیری کاهش یابد (Saifi, 2011).

۲-۴- اصلاح اریبی^۱

قبل از استفاده از روش‌های ترکیبی اصلاح اریبی بر روی مدل‌های منفرد براساس رابطه‌ی ۱۳ انجام می‌شود.

$$Y_{i,t} = a_i + b_i X_{i,t} \quad i=1, \dots, k \quad (13)$$

ضرایب a_i و b_i برای هر مدل توسط تخمین‌گر کوچک‌ترین مربعات معمولی (OLS) و با استفاده از داده‌های مرحله‌ی آموزش تعیین می‌شود. در صورتی که a_i نزدیک به صفر و b_i نزدیک به یک باشد نشان می‌دهد اصلاح اریبی تأثیر کمی بر روی مدل‌های منفرد داشته است.

۳- معیارهای ارزیابی

برای ارزیابی روابط تجربی آبستنگی و روش‌های ترکیبی از نمایه‌های ضریب همبستگی^۲ (R^2) و ریشه‌ی میانگین مربعات خطا^۳ (RMSE) و میانگین خطای اریب^۴ (MBE) استفاده شده است. هر چه ضریب همبستگی به ۱ نزدیک‌تر باشد عملکرد مدل بهتر می‌باشد. آماره‌ی MBE میزان اریبی را نشان می‌دهد و در شرایط ایده‌آل باید برابر صفر باشد. مقادیر مثبت یا منفی به ترتیب نشان‌دهنده‌ی بیش‌برآوردی^۵ و یا کم‌برآوردی^۶ نسبت به مقدار اندازه‌گیری شده است. آماره‌های RMSE و MBE نشان‌دهنده‌ی میزان خطای پیش‌بینی مدل‌ها می‌باشد. هر چه مقادیر RMSE و MBE اندک و به صفر نزدیک‌تر باشد دقت مدل بالاتر بوده و تخمین‌های آن به واقعیت نزدیک‌تر می‌باشد. نحوه محاسبه شاخص‌های آماری به صورت روابط ۱۴ تا ۱۶ می‌باشد.

جدول ۴ مقادیر ضرایب اصلاحی روابط منفرد

Table 4 Bias correction coefficient of individual relations

Bias correction coefficient	Martins (1975)	Machado (1980)	National Institute of Science and Technology Laboratory of Hydraulics (1981)	Mason and Arumugam (1987)	D'Agostino and Ferro (2004)
a	0.080	0.069	0.068	0.066	0.198
b	0.336	0.288	0.375	0.360	0.263

⁴ Mean bias error

⁵ Over estimate

⁶ Under estimate

¹ Bias Correction

² Correlation Coefficient

³ Root Mean Square Error

جدول ۵ مقادیر ضریب همبستگی و خطای روابط مختلف تجربی آبشستگی قبل و بعد از اصلاح اریبی

Table 5 Correlation coefficient and error of empirical relationships of scouring before and after bias correction

Individual models	Train						Test					
	Before bias correction			After bias correction			Before bias correction			After bias correction		
	R ² (-)	RMSE (m)	MBE (m)	R ² (-)	RMSE (m)	MBE (m)	R ² (-)	RMSE (m)	MBE (m)	R ² (-)	RMSE (m)	MBE (m)
Martins (1975)	0.77	1.12	0.60	0.77	0.26	0.00	0.72	0.98	0.57	0.72	0.23	-0.01
Machado (1980)	0.75	1.41	0.80	0.75	0.27	0.00	0.73	1.31	0.79	0.73	0.23	-0.01
National Institute of Science and Technology Laboratory of Hydraulics (1981)	0.76	0.97	0.52	0.76	0.26	0.00	0.70	0.87	0.49	0.70	0.24	-0.01
Mason and Arumugam (1987)	0.73	1.02	0.57	0.73	0.28	0.00	0.74	0.97	0.58	0.74	0.23	0.00
D'Agostino and Ferro (2004)	0.66	1.31	0.43	0.66	0.31	0.00	0.46	1.24	0.38	0.46	0.33	-0.02

تمامی شکل‌ها نقطه چین بیانگر دامنه ± 0.25 می‌باشد). شکل ۲-الف نشان می‌دهد رابطه‌ی منفرد ماسون و آراماگام پراکندگی نسبتاً کمتری نسبت به روابط تجربی دیگر دارد. هر دو رابطه‌ی ماسون و آراماگوم و مؤسسه‌ی ملی عمق آبشستگی را بیشتر از مقدار اندازه‌گیری شده برآورد کرده‌اند اما بیش‌برآوردی در رابطه‌ی ماسون و آراماگام بیشتر قابل مشاهده می‌باشد. با توجه به نتایج جدول ۵ و شکل ۲-الف، رابطه‌ی منفرد مؤسسه‌ی ملی به‌عنوان بهترین مدل منفرد قبل از اصلاح اریبی انتخاب می‌گردد.

بهترین برآورد قبل از اصلاح اریبی براساس داده‌های تصادفی آموزش و آزمون مربوط به روابط منفرد ماسون و آراماگام و مؤسسه‌ی ملی علم و فناوری آزمایشگاهی هیدرولیک (مؤسسه‌ی ملی) است. رابطه‌ی منفرد ماسون و آراماگام بیشترین ضریب همبستگی را در مرحله‌ی آزمون دارد و مقدار آن حدود 0.4 بیشتر از رابطه‌ی مؤسسه‌ی ملی است اما خطای رابطه‌ی ماسون و آراماگام حدود 10% درصد بیشتر از رابطه‌ی مؤسسه‌ی ملی می‌باشد. پراکندگی مقادیر عمق آبشستگی پیش‌بینی شده توسط روابط تجربی، قبل و بعد از اصلاح اریبی در شکل ۲ آورده شده است (در

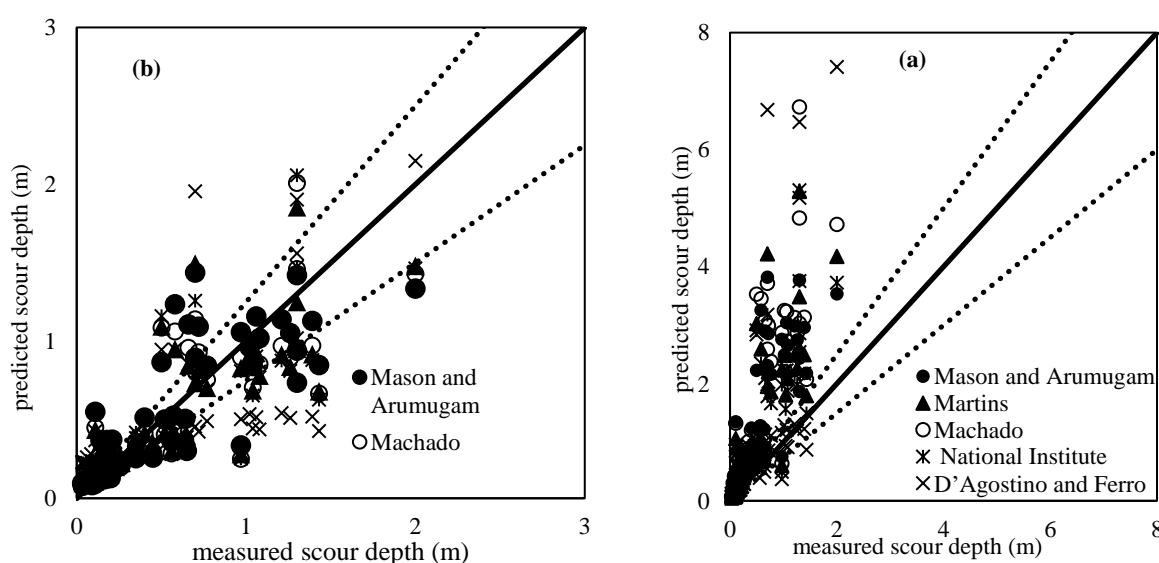


Fig. 2 Comparison of measured and predicted scour depth of different researchers' empirical relationships: (a) before bias Correction and (b) after bias correction

شکل ۲ مقایسه عمق آبشستگی اندازه‌گیری شده و پیش‌بینی شده‌ی حاصل از روابط تجربی محققان مختلف: (الف) قبل از اصلاح اریبی و (ب) بعد از اصلاح اریبی

با مقایسه روابط منفرد در مرحله‌ی قبل و بعد از اصلاح اریبی جدول ۵ مشاهده می‌شود که بعد از اصلاح اریبی خطای روابط منفرد در مرحله‌ی آموزش و آزمون کاهش یافته است اما ضریب همبستگی تغییری نکرده است. اصلاح اریبی تمامی مقادیر را در یک عدد ثابت ضرب و سپس با یک عدد ثابت جمع می‌کند. بنابراین ضریب همبستگی ثابت می‌ماند اما مقدار خطا کاهش می‌یابد. اصلاح اریبی پراکندگی نقاط نسبت به یکدیگر را تغییر نمی‌دهد اما نقاط را به خط ۱:۱ نزدیک می‌کند (شکل ۲-ب). بعد از اصلاح اریبی خطای تمام روابط منفرد کاهش یافته است و رابطه‌ی منفرد ماسون و آراماگام با ضریب همبستگی برابر 0.74 و مقدار خطای 0.23 متر دارای بیشترین همبستگی و کمترین خطا در بین روابط منفرد می‌باشد. مقادیر خطای روابط ماچادو، مارتینز و مؤسسه‌ی ملی تقریباً یکسان است و تفاوت بسیار کمی (حدود 0.01) با رابطه‌ی ماسون و آراماگام دارد. مقادیر خطای MBE روابط منفرد قبل از اصلاح اریبی در مرحله‌ی آزمون جدول ۵ نشان می‌دهد تمامی روابط دارای بیش‌برآوردی می‌باشند و مقادیر عمق آبشستگی را بیشتر از مقدار اندازه‌گیری شده تخمین می‌زنند. بعد از اصلاح اریبی در مرحله‌ی آزمون مقدار خطای MBE در تمامی روابط تقریباً مشابه یکدیگر است و به صفر نزدیک شده است. در مرحله‌ی آزمون مقدار خطای MBE رابطه‌ی ماسون و آراماگام صفر است و در دیگر روابط نیز مقدار بسیار کمی کم‌برآوردی (حدود 0.01 متر) مشاهده می‌شود. جدول ۵ و شکل ۲-ب نشان می‌دهد بعد از اصلاح اریبی رابطه‌ی منفرد ماسون و آراماگام نسبت به روابط دیگر، مقادیر آبشستگی را با دقت بیشتری پیش‌بینی می‌کند و به‌عنوان بهترین رابطه‌ی منفرد بعد از اصلاح اریبی انتخاب می‌شود.

۴-۲- روش‌های ترکیبی

یکی از عوامل مؤثر بر دقت روش ترکیبی انتخاب روابط منفرد می‌باشد. به‌صورت کلی انتخاب بهترین روابط منفرد براساس روابط و به‌صورت کمی قابل ارائه نمی‌باشد و انتخاب بهترین روابط منفرد بسیار پیچیده است (Andrawis et al. 2011). در صورتی که تعداد روابط کم باشد یک رابطه منفرد

که نتیجه خیلی خوب و یا خیلی بد داشته باشد می‌تواند بر روی نتیجه روش ترکیبی تأثیر قابل توجهی داشته باشد اما هنگامی که از چند رابطه منفرد متفاوت استفاده می‌شود نتایج بر اساس ترکیب تمام روابط به‌دست می‌آید. ترکیب روابط منفرد که دارای ناهمگنی زیادی می‌باشند باعث افزایش کارایی روش ترکیبی می‌گردد (Nourani et al. 2019). گاهی اوقات به‌منظور ساده‌کردن موضوع و جلوگیری از پیچیدگی و ایجاد خطا در ترکیب روابط منفرد نیاز است قضاوت مهندسی بر روی روابط صورت گیرد. (Menezes et al. 2000). نشان داد استفاده از دو رابطه منفرد به جای سه رابطه در تخمین میزان برق مصرفی روزانه انگلستان اگرچه باعث می‌گردد مقدار خطای روش ترکیبی مقداری افزایش پیدا کند اما چولگی ترکیب دو رابطه بسیار کمتر از سه رابطه خواهد بود. (Newbold and Granger (1974) پیشنهاد دادند در ترکیب روابط حداکثر از چهار رابطه استفاده شود. در بسیاری از تحقیقات تعداد روابط منفرد بیش از چهار می‌باشد. (Zhou et al. 2002; kiran and Ravi 2008; Spiliotis et al. 2019; Zhang et al. 2020) با توجه به توضیحات ارائه شده در این تحقیق از ۵ رابطه منفرد استفاده شد. در این روابط از پارامترهای با بعد و بی‌بعد استفاده شده است و تنوع پارامترهای مورد استفاده در این روابط نیز قابل توجه می‌باشد. در رابطه مارتینز (۱۹۷۵) از ۲ پارامتر و در رابطه داگوستینو و فروو (۲۰۰۴) از ۱۱ پارامتر استفاده شده است. همچنین برخی از این روابط بر اساس داده‌های آزمایشگاهی و برخی ترکیب داده‌های آزمایشگاهی و میدانی ارائه شده‌اند. در برخی از روابط تئوری آبشستگی و فرایند آبشستگی مورد توجه بوده و در بعضی فقط بر اساس آنالیز ابعادی ارائه شده‌اند. این روابط بر مبنای تنوع در تمام زمینه‌ها انتخاب شده‌اند. در نهایت روابط مارتینز، ماچادو، مؤسسه‌ی ملی، ماسون و آراماگام، داگوستینو و فروو به‌عنوان ورودی‌های روش‌های ترکیبی و متغیر مستقل و عمق آبشستگی اندازه‌گیری شده به‌عنوان خروجی روش‌های ترکیبی و متغیر وابسته در نظر گرفته می‌شوند.

با توجه به روابط سه تا ده مقدار ضریب هر رابطه منفرد تعیین گردید. مقادیر ضرایب در جدول ۶ آورده شده است.

مقدار منفی می‌باشد و کمترین ضریب مربوط به روش داگوستینو و فروو است. دامنه تغییرات ضرایب در روش BGA بسیار کم می‌باشد. در این روش نیز حداقل ضریب مربوط به روش داگوستینو و فروو می‌باشد. ضرایب دو روش AICA و BICA بسیار به هم نزدیک می‌باشد و تقریباً مشابه است. ضریب رابطه مارتینز در هر دو روش ۰/۵۲ می‌باشد و روابط موسسه ملی و داگوستینو و فروو ضریب حدود ۰/۰۱ دارند.

مقدار خروجی روابط منفرد با استفاده از ضرب ضرایب در هر رابطه منفرد و جمع جبری آن‌ها تعیین می‌شود. در روش W_2 ضرایب دو رابطه مارتینز و ماچادو منفی می‌باشد که نشان می‌دهد نتایج این دو روش رابطه غیر مستقیم با عمق آبستگی این روش ترکیبی دارد. روش EWA ضرایب تمامی روابط منفرد را مقدار ثابتی در نظر گرفته است. نتیجه این روش میانگین نتایج روابط منفرد خواهد بود. در روش GRA و W_2 ضرایب روش‌های منفرد مارتینز و ماچادو

جدول ۶ ضرایب روش‌های ترکیبی

Table 4 Coefficients of combination methods

Combination methods	Martins (1975)	Machado (1980)	National Institute of Science and Technology Laboratory of Hydraulics (1981)			Mason and Arumugam (1987)	D'Agostino and Ferro (2004)
W_2	-0.89	-0.93	1.81			0.52	0.12
EWA	0.2	0.2	0.2			0.2	0.2
GRA	-3.53	-4.47	6.75			2.1	0.23
BGA	0.22	0.21	0.22			0.19	0.15
AICA	0.52	0.30	0.01			0.16	0.01
BICA	0.52	0.30	0.02			0.16	0.00

نتایج روش‌های مختلف ترکیبی قبل و بعد از اصلاح اریبی براساس شاخص‌های آماری مختلف در جدول ۷ ارائه شده است.

روش‌های ترکیبی مورد استفاده دارای ویژگی‌های متفاوتی می‌باشند. مجموع ضرایب روش‌های ترکیبی AICA، BICA، EWA و BGA باید یک باشد که جزء محدودیت‌های این روش‌ها می‌باشد.

جدول ۷ مقادیر ضریب همبستگی و خطای مدل‌های ترکیبی مختلف قبل و بعد از اصلاح اریبی

Table 7 Correlation coefficient and error of differential combination methods before and after bias correction

Combination methods	Train						Test					
	Before bias correction			After bias correction			Before bias correction			After bias correction		
	R^2 (dimensionless)	RMSE (m)	MBE (m)	R^2 (dimensionless)	RMSE (m)	MBE (m)	R^2 (dimensionless)	RMSE (m)	MBE (m)	R^2 (dimensionless)	RMSE (m)	MBE (m)
direct weight												
W_2	0.78	0.31	-0.13	0.77	0.34	-0.15	0.62	0.31	-0.15	0.72	0.31	-0.16
EWA	0.77	1.11	0.59	0.77	0.25	0.00	0.71	1.01	0.56	0.72	0.23	-0.01
GRA	0.80	0.24	0.01	0.80	0.24	0.03	0.69	0.25	-0.01	0.70	0.24	0.01
Indirect weight												
BGA	0.77	1.07	0.57	0.77	0.25	0.00	0.72	0.97	0.55	0.73	0.23	-0.01
AICA	0.76	0.97	0.52	0.77	0.26	0.00	0.70	0.87	0.49	0.74	0.23	-0.01
BICA	0.76	0.97	0.52	0.77	0.26	0.00	0.70	0.87	0.49	0.74	0.23	-0.01
Local weight												
KNN	0.32	0.44	-0.23	0.29	0.45	0.02	0.80	0.19	-0.01	0.81	0.19	-0.01
Artificial intelligence												
LS-SVM	0.95	0.12	0.00	0.95	0.12	-0.03	0.84	0.18	0.01	0.83	0.18	0.01

قبل از اصلاح اریبی مقادیر ضریب همبستگی و خطای روش‌های وزن‌دهی مستقیم نشان می‌دهد روش GRA دارای کمترین خطا در پیش‌بینی عمق آبستگی

قبل از اصلاح اریبی مقادیر ضریب همبستگی و خطای روش‌های وزن‌دهی مستقیم نشان می‌دهد روش GRA دارای کمترین خطا در پیش‌بینی عمق آبستگی

(2015) و (2010) Diks and Vrugt مطابقت دارد. همچنین در شکل ۳ الف مشخص می‌باشد پراکندگی نقاط پیش‌بینی شده روش GRA در اطراف خط ۱:۱ نسبت به روش مؤسسه ملی کم‌تر است و مقادیر پیش‌بینی شده به مقادیر اندازه‌گیری شده نزدیک می‌باشند و مقدار MBE نیز بسیار کم و نزدیک به صفر می‌باشد.

به‌طور کلی مقدار آبستگی را بیشتر از مقدار اندازه‌گیری شده تخمین زده است و دقت کمی دارد. مقایسه‌ی روش‌های ترکیبی وزن‌دهی مستقیم با روابط منفرد قبل از اصلاح اریبی نشان می‌دهد روش GRA در مقایسه با بهترین رابطه‌ی منفرد (مؤسسه ملی) خطای بسیار کمتری دارد که با نتایج Arsenault and et al.

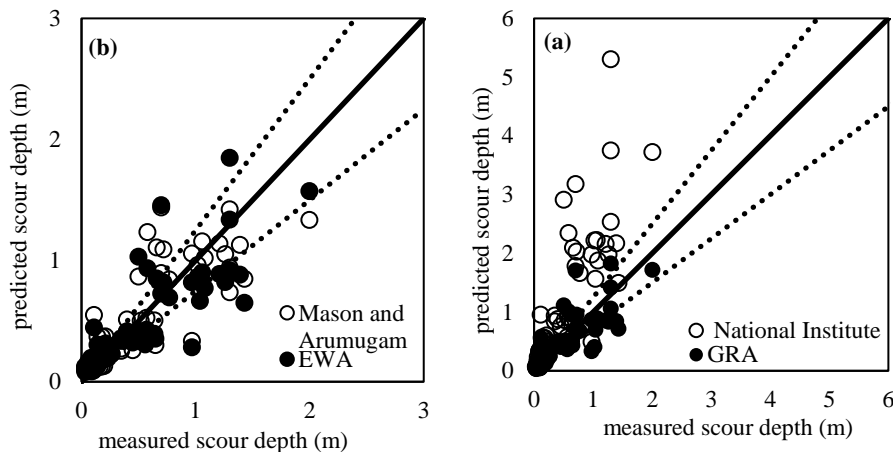


Fig. 3 Comparison of best direct weight method with best Individual relation: (a) before bias Correction and (b) after bias correction

شکل ۳ مقایسه بهترین روش وزن‌دهی مستقیم با بهترین رابطه‌ی منفرد: (الف) قبل از اصلاح اریبی و (ب) بعد از اصلاح اریبی

به رابطه‌ی منفرد مؤسسه ملی وزن یک و دیگر روابط وزن صفر داده‌اند و بنابراین نتایج این دو روش ترکیبی مشابه بهترین روش منفرد قبل از اصلاح اریبی شده است. شکل ۴-الف نشان می‌دهد در عمق آبستگی کمتر از ۱ متر مقادیر پیش‌بینی شده نزدیک به مقادیر اندازه‌گیری شده می‌باشد اما در عمق آبستگی بیشتر از ۱ متر مقادیر پیش‌بینی شده بیشتر از مقادیر اندازه‌گیری شده می‌باشند و تمرکز نقاط در بالای خط ۱:۱ است.

بعد از اصلاح اریبی هر سه روش وزن‌دهی غیرمستقیم تقریباً نتایج یکسانی را ارائه می‌دهند. ضریب همبستگی مدل‌های AICA و BICA اندکی بیشتر از مدل BGA است. نتایج مدل‌های AICA و BICA مشابه بهترین مدل منفرد (ماسون و آراماگام) است ($R^2=0.74$, $RMSE=0.23$). شکل ۴-ب نشان می‌دهد بیشتر نقاط در اطراف خط ۱:۱ پراکنده هستند و مقادیر پیش‌بینی شده نزدیک به مقادیر اندازه‌گیری شده می‌باشند. قبل از اصلاح اریبی خطای روش ترکیبی BGA با AICA و BICA متفاوت است اما بعد از اصلاح اریبی خطای این روش‌ها مشابه می‌باشد.

بعد از اصلاح اریبی فقط خطای یکی از روش‌های وزن‌دهی مستقیم کاهش یافته است و بهبودی در نتایج دو روش دیگر مشاهده نمی‌شود (جدول ۷). مدل ترکیبی EWA که در مرحله قبل از اصلاح اریبی بیشترین خطا را در برآورد عمق آبستگی دارد بعد از اصلاح اریبی روابط منفرد، عمق آبستگی را با کم‌ترین خطا در بین روش‌های وزن‌دهی مستقیم پیش‌بینی کرده است. مقادیر خطای روش EWA با نتایج بهترین رابطه‌ی منفرد بعد از اصلاح اریبی (ماسون و آراماگام) تقریباً یکسان است.

قبل از اصلاح اریبی در روش‌های وزن‌دهی غیرمستقیم، مدل‌های ترکیبی AICA و BICA بهترین برآورد را ارائه داده‌اند (جدول ۷) که نتایج آن مشابه بهترین رابطه‌ی منفرد قبل از اصلاح اریبی است ($R^2=0.70$, $RMSE=0.87$). شکل ۴-الف نشان می‌دهد نتایج روش‌های ترکیبی AICA و BICA کاملاً مشابه روش مؤسسه ملی است. با توجه به این که مقادیر خطای روابط منفرد قبل از اصلاح اریبی تفاوت زیادی با یکدیگر دارند (خطای ضعیف‌ترین مدل، $1/5$ برابر بهترین مدل است) روش‌های ترکیبی AICA و BICA

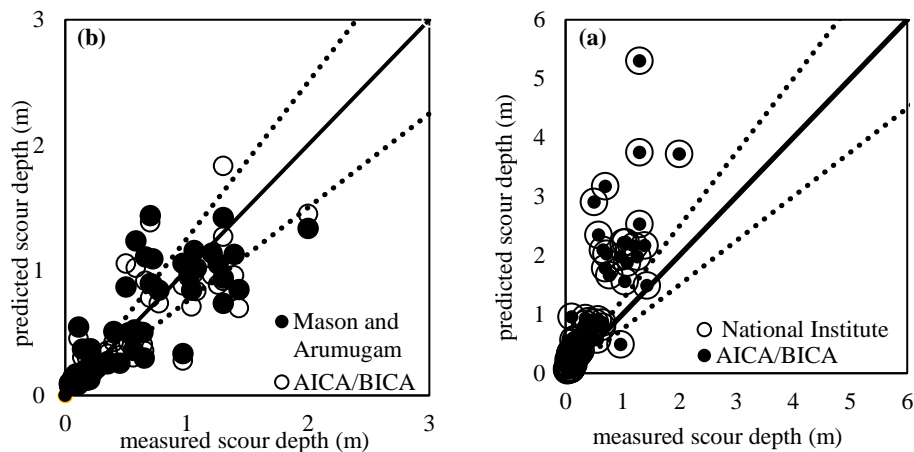


Fig. 4 Comparison of best indirect weight method with best Individual relation: (a) before bias correction and (b) after bias correction

شکل ۴ مقایسه‌ی بهترین روش وزن‌دهی غیرمستقیم با بهترین رابطه‌ی منفرد: (الف) قبل از اصلاح اریبی و (ب) بعد از اصلاح اریبی

به صفر است. شکل ۵-الف اختلاف قابل توجه روش ترکیبی وزن‌دهی موضعی (نزدیک‌ترین همسایه) با بهترین رابطه‌ی منفرد را قبل از اصلاح اریبی نشان می‌دهد. اصلاح اریبی روابط منفرد تأثیری بر خطای روش ترکیبی KNN ندارد (RMSE=0.19). شکل ۵-ب نشان می‌دهد بعد از اصلاح اریبی دقت روش KNN در پیش‌بینی اعماق آبستگي بیشتر از ۰/۵ متر اندکی بیشتر از بهترین رابطه‌ی منفرد است.

روش‌های وزن‌دهی غیرمستقیم بعد از اصلاح اریبی حدود ۷۰٪ نسبت به قبل از اصلاح کاهش یافته است. نتایج مربوط به روش ترکیبی KNN در جدول ۷ آورده شده است. قبل از اصلاح اریبی روش KNN توانسته خطای پیش‌بینی عمق آبستگي را به مقدار قابل توجهی کاهش دهد. روش KNN مقدار خطا را قبل از اصلاح اریبی به کم‌تر از یک چهارم بهترین مدل منفرد کاهش داده است. مقدار MBE آن نیز در قبل و بعد از اصلاح اریبی یکسان است و تقریباً نزدیک

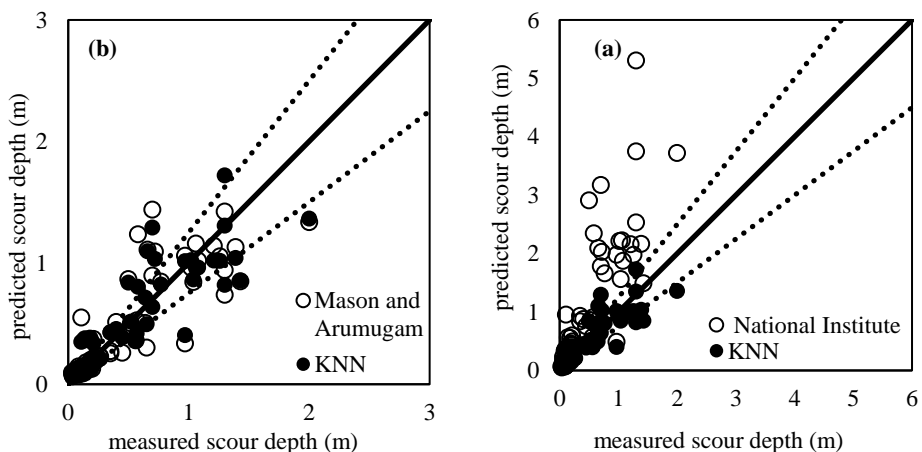


Fig. 5 Comparison of best local weight method with best Individual relation: (a) before bias Correction and (b) after bias correction

شکل ۵ مقایسه‌ی وزن‌دهی موضعی با بهترین رابطه‌ی منفرد: (الف) قبل از اصلاح اریبی و (ب) بعد از اصلاح اریبی

است. نتایج روش ترکیبی هوش مصنوعی (LS-SVM) بعد از اصلاح اریبی مشابه نتایج قبل از اصلاح می‌باشد. شکل ۶-الف اختلاف قابل توجه روش ترکیبی LS-SVM را با بهترین رابطه‌ی منفرد قبل از اصلاح اریبی نشان می‌دهد. شکل ۶-ب

نتایج حاصل از ترکیب مدل‌های منفرد با استفاده از هوش مصنوعی (LS-SVM) در جدول ۷ آورده شده است. قبل از اصلاح اریبی روش LS-SVM مانند روش KNN با ترکیب مدل‌های منفرد، نتایج را به مقدار قابل توجهی بهبود داده

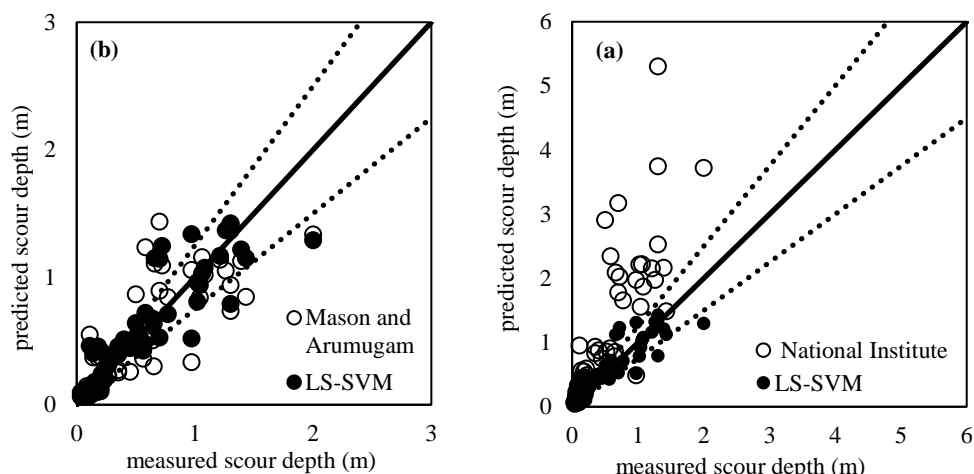


Fig. 6 Comparison of best artificial intelligence weight method with best Individual relation: (a) before bias Correction and (b) after bias correction

شکل ۶ مقایسه هوش مصنوعی با بهترین رابطه‌ی منفرد: (الف) قبل از اصلاح اریبی و (ب) بعد از اصلاح اریبی

بر نتایج این دو روش ندارد. مقایسه‌ی بهترین روش‌های ترکیبی قبل و بعد از اصلاح اریبی در شکل ۷ آورده شده است. شکل ۷-الف نشان می‌دهد تمامی اعمال آبخستگی پیش‌بینی شده بیشتر از یک متر توسط روش AICA در بالای خط ۱:۱ قرار دارند و این روش بیش‌برآوردی قابل ملاحظه‌ای دارد. پراکندگی زیاد نقاط نیز در این روش بیانگر دقت کم این روش می‌باشد. در شکل ۷-ب هر دو روش LS-SVM و KNN دارای نتایج قابل قبولی می‌باشند و توانسته‌اند عمق آبخستگی را با دقت زیادی پیش‌بینی نمایند.

ب نشان می‌دهد دقت روش LS-SVM بعد از اصلاح اریبی اندکی بیشتر از بهترین رابطه‌ی منفرد (ماسون و آراماگوم) است.

نتایج دو روش ترکیب موضعی و هوش مصنوعی مشابه یکدیگر است. هر دو روش قبل از اصلاح اریبی پیش‌بینی بسیار بهتری نسبت به بهترین رابطه‌ی منفرد انجام داده‌اند. همچنین نتایج هر دو روش قبل و بعد از اصلاح اریبی تفاوت زیادی ندارد. این دو روش با استفاده از روابط و توابع مورد استفاده خود توانسته‌اند روابط اولیه را اصلاح و سپس عمق آبخستگی را پیش‌بینی نمایند بنابراین اصلاح اریبی تأثیری

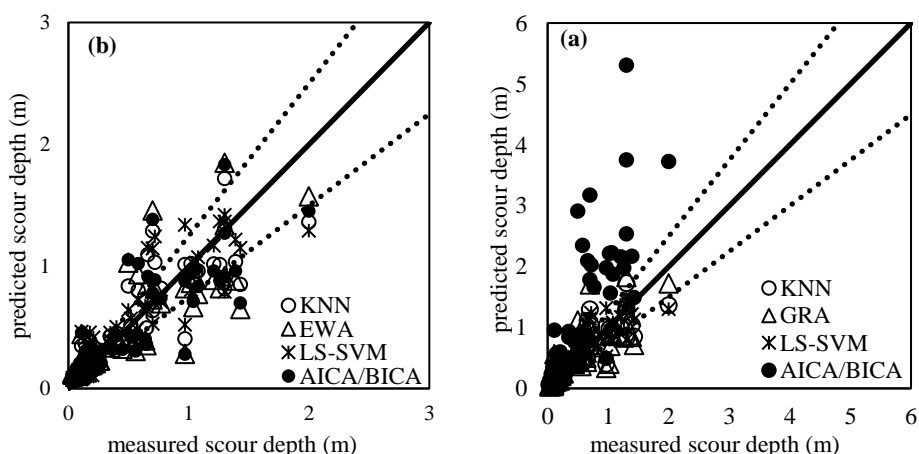


Fig. 7 Comparison of best combination methods: (a) before bias Correction and (b) after bias correction

شکل ۷ مقایسه برترین روش‌های ترکیبی مختلف: (الف) قبل از اصلاح اریبی و (ب) بعد از اصلاح اریبی

از اصلاح اریبی می‌باشد. در این تحقیق قبل از اصلاح اریبی خطای روش غیرمستقیم BGA چند برابر خطای روش

Dobarco et al. (2017) نشان دادند خطای روش ترکیبی GRA کمتر از BGA است که مشابه نتایج این تحقیق، قبل

مشاهده کردند که وزن‌های دو روش AICA و BICA برای بهترین رابطه‌ی منفرد برابر یک و دیگر روابط برابر صفر است که مشابه نتایج این تحقیق قبل از اصلاح اریبی می‌باشد. بعد از اصلاح اریبی که نتایج روابط منفرد مشابه یکدیگر می‌شود، ضرایب روابط منفرد به غیر از صفر می‌باشد و این دو روش ترکیبی از تمامی روابط منفرد برای پیش‌بینی عمق آبستنگی استفاده می‌کنند. Arsenault et al. (2015) نتیجه گرفتند که روش‌های AICA، BICA و BGA سطح عملکردشان در مقایسه با بهترین مدل‌های منفرد بهبود نیافته است. در این پژوهش نیز نتایج BGA در مقایسه با بهترین مدل‌های منفرد قبل و بعد از اصلاح اریبی خطای بالایی داشته است ولی نتایج AICA و BICA مشابه مدل‌های منفرد قبل و بعد از اصلاح اریبی می‌باشد. Draper (1995)، Padarian et al. (2014) و Dobarco et al. (2017) به این نتیجه رسیدند که عملکرد مدل‌های ترکیبی وابسته به کیفیت داده‌های اولیه (مدل‌های منفرد) است و دقت پیش‌بینی مدل‌های ترکیبی زمانی افزایش می‌یابد که مدل‌های منفرد دقت کمی داشته باشند و هنگامی که مدل‌های اولیه اصلاح می‌شوند مدل‌های ترکیبی خطای پیش‌بینی را کاهش نمی‌دهند. نتایج این پژوهشگران با نتایج این پژوهش مطابقت دارد. روابط منفرد قبل از اصلاح اریبی خطای زیادی دارند و روش‌های ترکیبی خطای پیش‌بینی را کاهش می‌دهند اما بعد از اصلاح اریبی و کاهش خطای روابط منفرد، نتایج مدل‌های ترکیبی بهبود نداشته و به‌جز دو روش وزن‌دهی موضعی و هوش مصنوعی نتایج روش‌های ترکیبی دیگر تقریباً مشابه روابط منفرد می‌باشد. Siwek et al. (2009)، Chou and pham (2013) و Jovanovic et al. (2015) به‌طور کلی به این نتیجه رسیدند که انواع مختلف شبکه‌های عصبی که مبتنی بر هوش مصنوعی می‌باشند در مقایسه با مدل‌های منفرد عملکرد بهتری را ارائه می‌دهند که با نتایج بدست آمده از روش ترکیبی هوش مصنوعی (Is-svm) قبل و بعد از اصلاح اریبی مطابقت دارد. de Menezes et al. (2000) به این نتیجه رسیدند که خطاهای روابط منفرد به‌شدت بر خطای روش‌های ترکیبی اثر می‌گذارد که مطابق با روش‌های وزن‌دهی غیر مستقیم و روش EWA است.

مستقیم GRA می‌باشد. Seifert et al. (2012) نشان دادند روش‌های ترکیبی ساده‌ی EWA و BGA عملکردشان در مقایسه با روش‌های منفرد بهتر است. جدول ۷ نشان می‌دهد قبل از اصلاح اریبی دو روش EWA و BGA نسبت به بعضی از روش‌های منفرد نتایج بهتری ارائه کرده‌اند. بعد از اصلاح اریبی که خطای روابط منفرد کاهش یافته است روش‌های EWA و BGA عمق آبستنگی را با خطای ریشه‌ی میانگین مربعات برابر $0/23$ متر پیش‌بینی کرده‌اند که مشابه بهترین رابطه‌ی منفرد می‌باشد. Diks and Vrugt. (2010) مشاهده کردند که تمام روش‌های ترکیبی وزن‌دهی از جمله روش‌های EWA و BGA پیش‌بینی‌های دقیق‌تری نسبت به بهترین رابطه‌ی منفرد ارائه نمی‌دهند و عملکرد ضعیف‌تری نسبت به بهترین رابطه دارند. در این پژوهش قبل از اصلاح اریبی روش EWA در مقایسه با بهترین رابطه‌ی منفرد (مؤسسه ملی) خطای بیشتری دارد و بعد از اصلاح اریبی نیز خطای EWA تقریباً مشابه بهترین رابطه‌ی منفرد (ماسون و آراماگام) به‌دست آمده است. روش BGA نیز قبل از اصلاح اریبی در مقایسه با بهترین رابطه‌ی منفرد خطای زیادی داشته و بعد از اصلاح اریبی خطای روش BGA تقریباً مشابه بهترین مدل منفرد به‌دست آمده است. Malone et al. (2014) و Diks and Vrugt. (2010) نشان دادند که روش ترکیبی GRA خطای کم‌تری نسبت به دیگر روش‌های ترکیبی دارد. در این پژوهش نیز روش GRA در مرحله‌ی قبل از اصلاح اریبی نسبت به روش مستقیم EWA و ۳ روش غیرمستقیم دیگر، خطای کم‌تری دارد. Arsenault and Brissette. (2016) به‌طور کلی به این نتیجه رسیدند که مدل‌های ترکیبی همواره نتایج را به‌طور قابل توجهی بهبود نمی‌بخشند اما روش AICA این مزیت را دارد که با ترکیب روابط منفرد خوب یا متوسط، معمولاً دارای خطای پیش‌بینی کمی می‌باشد. نتایج AICA قبل و بعد از اصلاح اریبی نسبت به مدل‌های منفرد در حد ناچیزی بهبود داشته است. در کل نتایج AICA قبل و بعد از اصلاح اریبی نزدیک به نتایج روابط منفرد قبل و بعد از اصلاح اریبی به‌دست آمده است و نتوانسته نتایج روابط منفرد را به مقدار قابل توجهی بهبود بخشد. Diks and Vrugt. (2010)

۵- نتیجه‌گیری

تخمین آبخستگی پایین‌دست سازه‌های تثبیت بستر برای جلوگیری از تخریب سازه‌ها امری لازم و ضروری محسوب می‌شود. با توجه به عدم قطعیت اعماق آبخستگی برآورد شده توسط روابط تجربی، هدف از انجام این پژوهش برآورد آبخستگی پایین‌دست سازه‌ها با استفاده از ترکیب روابط تجربی (روش‌های ترکیبی) می‌باشد. رابطه‌ی مؤسسه‌ی ملی و ماسون به ترتیب به عنوان بهترین رابطه‌ی منفرد (تجربی) قبل و بعد از اصلاح اریبی انتخاب شدند. مقایسه‌ی روابط منفرد قبل و بعد از اصلاح اریبی نشان می‌دهد که خطای روابط منفرد بعد از اصلاح اریبی کاهش یافته و نقاط به خط ۱:۱ نزدیک شدند اما پراکندگی نقاط نسبت به یکدیگر تغییری نکرده است. روابط منفرد ارائه شده در این پژوهش به عنوان ورودی و عمق آبخستگی اندازه‌گیری شده به عنوان خروجی روش‌های ترکیبی در نظر گرفته شدند. قبل از اصلاح اریبی با توجه به دقت کم روابط منفرد، دقت پیش‌بینی مدل‌های ترکیبی افزایش داشته ولی بعد از اصلاح اریبی به دلیل اصلاح روابط منفرد، دقت پیش‌بینی مدل‌های ترکیبی تغییرات زیادی با روابط منفرد نداشته است. مقایسه‌ی روش‌های وزن‌دهی مستقیم قبل از اصلاح اریبی نشان می‌دهد که بهترین روش GRA بوده و در مقایسه با بهترین رابطه منفرد خطای بسیار کمتری دارد اما بعد از اصلاح اریبی روش EWA بهترین روش ترکیبی می‌باشد و تقریباً مشابه بهترین رابطه‌ی منفرد بعد از اصلاح اریبی است.

مقایسه‌ی روش‌های وزن‌دهی غیرمستقیم قبل و بعد از اصلاح اریبی نشان می‌دهد روش‌های ترکیبی AICA و BICA نتایج بهتری ارائه می‌دهند و تقریباً مشابه بهترین رابطه‌ی منفرد قبل و بعد از اصلاح اریبی می‌باشند. نتایج روش وزن‌دهی موضعی (KNN) قبل و بعد از اصلاح اریبی یکسان بوده و در مقایسه با بهترین رابطه‌ی منفرد قبل از اصلاح اریبی اختلاف قابل توجهی دارد اما بعد از اصلاح اریبی خطای KNN نسبت به قبل از اصلاح اریبی تفاوت کمی دارد و در اعماق آبخستگی بیشتر از ۰/۵ متر نقاط KNN نسبت به روابط منفرد به خط ۱:۱ نزدیک‌تر می‌باشد. نتایج روش هوش مصنوعی نیز مانند روش وزن‌دهی موضعی

قبل و بعد از اصلاح اریبی یکسان بوده است. LS-SVM توانسته با ترکیب روابط منفرد قبل از اصلاح اریبی دقت برآورد را به مقدار زیادی افزایش دهد اما بعد از اصلاح اریبی تأثیر ترکیب روابط منفرد کاهش یافته است و عمق آبخستگی برآورد شده نسبت به روابط منفرد به مقدار کمی بهبود یافته است. مقایسه‌ی نتایج بهترین روش‌های ترکیبی نشان می‌دهد که روش‌های ترکیبی LS-SVM و سپس KNN قبل و بعد از اصلاح اریبی نسبت به دیگر روش‌های ترکیبی، عمق آبخستگی را با دقت بیشتری پیش‌بینی کرده‌اند.

۷- فهرست علائم

b	عرض سرریز
B	عرض سازه
d_{50}	قطر مشخصه‌ی مصالح که ۵۰ درصد وزن مصالح از آن ریزتر است
d_{90}	قطر مشخصه‌ی مصالح که ۹۰ درصد وزن مصالح از آن ریزتر است
e	میزان خطا
g	شتاب گرانشی
h	عمق آب در پایین‌دست
H	اختلاف عمق بالادست و عمق پایین‌دست
K	تعداد مدل‌های منفرد
$I(M data)$	تابع احتمال مدل
n	تعداد داده
O	مقادیر مشاهداتی
\bar{O}	میانگین مقادیر مشاهداتی
OLS	تخمین‌گر حداقل مربعات معمولی
P	مقادیر محاسباتی
q	دبی آب در واحد عرض
Q	دبی آب
S	عمق آبخستگی
V	مقدار خطا
w_k	وزن‌های مدل‌های منفرد
X_{ik}	خروجی مدل منفرد

De Menezes, L. M., Bunn, D. W. and Taylor, J. W. (2000). Review of guidelines for the use of combined forecasts. *European Journal of Operational Research*, 120(1), 190-204.

Dehghani, A.A. and Abdi, Dehkordi, M. (2014). Application of genetic algorithms in the optimization of empirical relations to estimate of geometrical characteristics of the scour hole downstream of grade control structures. *Modares Civil Engineering Journal*, 14(2), 165-211. (In Persian)

Diks, C.G.H. and Vrugt, J.A. (2010). Comparison of point forecast accuracy of model averaging methods in hydrologic applications. *Stochastic Environmental Research and Risk Assessment*, 24(6), 809-820.

Dobarco, M.R., Arrouays D., Lagacherie P., Ciampalini, R. and Saby N. P. (2017). Prediction of topsoil texture for Region Centre (France) applying model ensemble methods. *Geoderma*, 298, 67-77.

Draper, D. (1995). Assessment and propagation of model uncertainty. *Journal of the Royal Statistical Society. Series B (Methodological)*, 45-97.

Granger, C.W. and Ramanathan, R. (1984). Improved methods of combining forecasts. *Journal of Forecasting*, 3(2), 197-204.

Guven, A. and Gunal, M. (2008). Prediction of scour downstream of grade-control structures using neural networks. *Journal of Hydraulic Engineering*, 134(11), 1656-1660.

Hansen, B.E. (2008). Least-squares forecast averaging. *Journal of Econometrics*, 146(2), 342-350.

INCYTH LHA. Instituto Nacional de Ciencia y Técnicas Hidricas Laboratorio de Hidraulica. (1981). Estudio sobre modelo del aliviadero de la presa de piedra. Informe Final. DOH-044-03-82. Ezeiza. Argentina.

Jalali, V. R. and Homaei, M. (2011). Introducing a Nonparametric Model Using k-Nearest Neighbor Technique for Predicting Soil Bulk Density. *JWSS-Isfahan University of Technology*, 15(56), 181-191. (In Persian)

Jovanović, R. Ž., Sretenović, A.A. and Živković B. D. (2015). Ensemble of various neural networks for prediction of heating energy consumption. *Energy and Buildings*, 94, 189-199.

Y_i	خروجی مدل ترکیبی برای ورودی i
Z	ارتفاع سازه
$\hat{\sigma}_i^2$	واریانس پیش‌بینی مدل i
γ	پارامتر تنظیم‌کننده‌ی بخش خطا
ρ_s	چگالی ذرات بستر
ρ	چگالی آب

۸- منابع

Andrawis, R.R., Atiya, A.F. and El-Shishiny, H. (2011). Forecast combinations of computational intelligence and linear models for the NN5 time series forecasting competition. *International Journal of Forecasting*, 27(3), 672-688.

Arsenault, R. and Brissette, F. (2016). Multi-model averaging for continuous streamflow prediction in ungauged basins. *Hydrological Sciences Journal*, 61(13), 2443-2454.

Arsenault, R., Gatién, Ph., Renaud, B., Brissette, F. and Martel, J.L. (2015). A comparative analysis of 9 multi-model averaging approaches in hydrological continuous streamflow simulation. *Journal of Hydrology*, 529, 754-767.

Ayoubi, S., Taghizadeh, R., Namazi, Z., Zolfaghari, A. and Roustae Sadrabadi, F. (2016). The Comparison of k-NN and ANN for Digital Mapping of Salinity in Chahafzal Ardekan. *Journal of Water and Soil Science (Journal of Science and Technology of Agriculture and Natural Resources)*, 20(76), 59-71. (in Persian)

Bates J.M. and Granger C.W.J. (1969). The combination of forecasts. *Journal of the Operational Research Society*, 20(4), 451-468.

Bormann N.E. and Julien, P.Y. (1991). Scour downstream of grade-control structures. *Journal of Hydraulic Engineering*, 117(5), 579-94.

Burnham, K. P. and Anderson, D. R. (2002). Model selection and multi model inference: a practical information-theoretic approach, Second ed. Springer-Verlag, New-York, United-States, 487p.

Chou, J.S. and Pham, A.D. (2013). Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength. *Construction and Building Materials*, 49, 554-563.

D'Agostino, V. and Ferro, V. (2004). Scour on alluvial bed downstream of grade control structures. *Journal of Hydraulics Engineering*, 130(1), 24-37.

- Pourreza Bilondi, M., Khashei-Siuki, A. and Sadeghi, Tabas S. (2015). Daily rainfall-runoff modeling with Least Square Support Vector Machine (LS-SVM). *Journal of Water and Soil Conservation*, 21(6), 293-304. (In Persian)
- Saifi, A. (2011). Development of an expert system for estimating daily reference evapotranspiration using a backup vector machine (SVM) and comparing its results with ANFIS, ANN and experimental methods. Master's thesis, Faculty of Agriculture, Tarbiat Modares University. 147 p. (In Persian)
- Seifert, D., Sonnenborg, T.O., Refsgaard, J.C., Højberg, A. L. and Troldborg, L. (2012). Assessment of hydrological model predictive ability given multiple conceptual geological models. *Water Resources Research*, 48(6), 1-16.
- Shafai Bajestan, M. (2011). Theoretical and practical principles of hydraulic transmission of sediment. First edition, Shahid Chamran University Press, Ahvaz. (In Persian)
- Sharma, A. and O'Neill, R. (2002). A nonparametric approach for representing interannual dependence in monthly streamflow sequences. *Water resources research*, 38(7), 51-60.
- Shu, C. and Burn, D. H. (2004). Artificial neural network ensembles and their application in pooled flood frequency analysis. *Water Resources Research*, 40(9), 1-10.
- Siwek, K., Osowski, S. and Szupiluk, R. (2009). Ensemble neural network approach for accurate load forecasting in a power system. *International Journal of Applied Mathematics and Computer Science*, 19(2), 303-315.
- Spiliotis, E., Petropoulos, F. and Assimakopoulos, V. (2019). Improving the forecasting performance of temporal hierarchies. *Plos One*, 14(10), 1-21.
- Suykens, J.A. and Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9(3), 293-300.
- Tahmasebi Biragani, Y., Yazdandoost, F. and Ghalkhani, H. (2016). Flood Forecasting Using Artificial Neural Networks: An Application of Multi-Model Data Fusion technique. *Journal of Hydraulic Structures*, 2(2), 62-73.
- Vapnik, V. (1998). *Statistical learning theory*. Wiley, New York. 768P.
- Yakowitz, S. (1993). Nearest neighbor regression estimation for null-recurrent Markov time series.
- Kiran, N.R. and Ravi, V. (2008). Software reliability prediction by soft computing techniques. *Journal of Systems and Software*, 81(4), 576-583.
- Machado, L.I. (1980). Formulas para calcular o limite da erosao em leitos rochosos ou granulares. XIII Seminario Nacional de Grandes Barragens. Rio de Janeiro. Brazil. Apr. 35-52.
- Malone, B.P., Minasny, B., Odgers, N.P. and McBratney, A.B. (2014). Using model averaging to combine soil property rasters from legacy soil maps and from point data. *Geoderma*, 232, 34-44.
- Martins, R.B. F. (1975). Scouring of rocky river beds by free jet spillways. *International Water Power and Dams Construction*, 27(4), 152-153.
- Mason, P.J. and Arumugam, K. (1985). Free jet scour below dams and flip buckets. *Journal of Hydraulic Engineering*, 111(2), 220-235.
- Mehraein, M. and Meraji, S.H. (2017). Application of PSO Algorithm in estimating the formation of scour holes caused by 2D wall jets. *Modares Civil Engineering Journal*, 17(4), 229-239. (In Persian)
- Moazami, S., Noori, R., Salimian, M., Momeni, M.R. and Vesali Naseh, M. R. (2017). Evaluation of Support Vector Machine Performance for Carbon Monoxide Prediction. *Modares Civil Engineering Journal*, 17(3), 195-202. (In Persian)
- Mossa, M. (1998). Experimental study on the scour downstream of grade-control structures. *Proc., 26th Convegno di Idraulica e Costruzioni Idrauliche*, 581-94.
- Newbold, P. and Granger, C.W.J. (1974). Experience with forecasting univariate time series and the combination of forecasts (with discussion). *Journal of the Royal Statistical Society Series A (General)*, 137(2), 131-149.
- Nourani, V., Elkiran, G., Abdullahi, J. and Tahsin, A. (2019). Multi-region modeling of daily global solar radiation with artificial intelligence ensemble. *Natural Resources Research*, 28(4), 1217-1238.
- Padarian, J., Minasny, B., McBratney, A.B. and Dalgliesh, N. (2014). Predicting and mapping the soil available water capacity of Australian wheatbelt. *Geoderma Regional*, 2, 110-118.
- Panahi, S., Farsadzadeh, D., Hosseinzadeh Dalir, A., Salmasi, F. and Nazemi, A.H. (2014). Investigating the effect of cup angle on scour dimensions in the downstream of submerged jar. *Iran Water Research*, 7(13), 185-195. (In Persian)

Zhou, Z.H., Wu, J, and Tang, W. (2002). Ensembling neural networks: many could be better than all. *Artificial intelligence*, 137(1-2), 239-263.

Zolfaghari, A.A., Taghizadeh-Mehrjardi, R., Moshki, A.R., Malone, B.P., Weldeyohannes, A.O., Sarmadian, F. and Yazdani, M.R. (2016). Using the nonparametric k-nearest neighbor approach for predicting cation exchange capacity. *Geoderma*, 265, 111-119.

Stochastic Processes and their Applications, 48(2), 311-318.

Zhang, Z., Han, H., Cui, X. and Fan, Y. (2020). Novel application of multi-model ensemble learning for fault diagnosis in refrigeration systems. *Applied Thermal Engineering*, 164, 1-11.