

## Simulation of Scour Depth Around Twin and Three Piers Using Group Method of Data Handling

EHSAN MORADI<sup>1</sup>, SAEID SHABANLOU<sup>1\*</sup>, BEHROUZ YAGHOUBI<sup>1</sup>

1. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

(Received: Feb. 26, 2021- Revised: June. 19, 2021- Accepted: June. 23, 2021)

### ABSTRACT

Estimation and computation of scouring around structures such as piers has a significant importance. In this study, scour depth in the vicinity of twin and three piers was simulated using Group Method of Data Handling (GMDH). First, effective parameters on scour depth were identified and then four different GMDH models were defined. To verify the simulation results, some experimental measurements were applied and 70% of these data were utilized to train the GMDH models, whereas 30% of the data were employed to test the models. Subsequently, the best GMDH model and the most influencing input parameters were introduced by conducting a sensitivity analysis. The sensitivity analysis showed that the GMDH models estimated the scour depth with acceptable accuracy. For instance, the correlation coefficient (R), scatter index (SI), and variance accounted for (VAF) for the best GMDH model were respectively calculated to be 0.949, 0.212, and 90.129. In addition, the Froude number was detected as the most important input variable to estimate the scour depth through GMDH model. Moreover, the mean discrepancy ratio ( $DR_{ave}$ ) for the superior GMDH model was computed to be 1.228. For different GMDH models, four equations were presented and lastly a computer code was provided to simulate scour depth by means of the GMDH model.

**Keywords:** Twin and Three Piers, Scouring, Group Method Of Data Handling, Sensitivity Analysis, Simulation.

## شبیه‌سازی عمق آبخستگی در اطراف پایه‌های پل جفت و سه‌تایی با استفاده از روش دست بندی

### گروهی داده‌ها

احسان مرادی<sup>۱</sup>، سعید شعبانلو<sup>۱\*</sup>، بهروز یعقوبی<sup>۱</sup>

۱. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

(تاریخ دریافت: ۱۳۹۹/۱۲/۱۸ - تاریخ بازنگری: ۱۴۰۰/۳/۲۹ - تاریخ تصویب: ۱۴۰۰/۴/۲)

### چکیده

تخمین و محاسبه آبخستگی در اطراف سازه‌ها از قبیل پایه پل‌ها از اهمیت بسزایی برخوردار است. در این مطالعه، با استفاده از روش دسته‌بندی گروهی داده‌ها (GMDH) عمق آبخستگی در اطراف پایه پل‌های دوقلو و سه‌تایی شبیه‌سازی گردید. در ابتدا، موثرترین پارامترها بر روی عمق آبخستگی شناسایی شدند و سپس چهار مدل مختلف GMDH تعریف گردید. برای صحت‌سنجی نتایج مدل‌های GMDH از مقادیر آزمایشگاهی استفاده گردید که ۷۰٪ مقادیر آزمایشگاهی برای آموزش مدل‌های GMDH و ۳۰ درصد باقیمانده برای آزمون این مدل‌ها به کار گرفته شدند. در ادامه با انجام یک تحلیل حساسیت، مدل‌های برتر و موثرترین پارامترهای ورودی معرفی شدند. نتایج تحلیل حساسیت نشان داد که مدل‌های GMDH مقادیر آبخستگی‌ها را با دقت قابل قبولی پیش‌بینی کردند. به‌عنوان مثال، مقادیر ضریب همبستگی ( $R$ )، شاخص پراکندگی ( $SI$ ) و شاخص عملکرد ( $VAF$ ) برای مدل برتر در شرایط آزمون به ترتیب برابر با ۰/۹۴۹، ۰/۲۱۲ و ۹۰/۱۲۹ محاسبه شدند. علاوه بر این، عدد فرود به‌عنوان مهمترین پارامتر ورودی برای تخمین عمق آبخستگی توسط مدل GMDH معرفی گردید. همچنین، مقدار ضریب اختلاف متوسط برای مدل برتر معادل با ۱/۲۲۸ بود. برای مدل‌های GMDH مختلف چهار رابطه ارائه گردید و در انتها یک کد کامپیوتری برای شبیه‌سازی عمق آبخستگی توسط مدل GMDH ارائه گردید.


**واژه‌های کلیدی:** پایه‌های جفت و سه‌تایی، آبخستگی، روش دسته‌بندی گروهی داده‌ها، تحلیل حساسیت، شبیه‌سازی.

### مقدمه

آبخستگی موضعی به‌عنوان یکی از عوامل مهم که باعث گسیختگی سازه پل‌ها، موج‌شکن‌ها و اسکله‌ها می‌شود شناسایی شده است. پیچیدگی مکانیزم آبخستگی باعث شده است که این موضوع یکی از مهمترین زمینه‌های مطالعاتی مهندسی عمران باشد. به دلیل اهمیت زیاد پیش‌بینی و تخمین الگوی آبخستگی در مجاورت پایه‌های پل مطالعات فراوانی بر روی این نوع از سازه‌ها انجام شده است. علاوه بر این، در سال‌های اخیر استفاده از محاسبات نرم برای پیش‌بینی مسائل پیچیده و غیرخطی به شکل قابل ملاحظه‌ای گسترش یافته است. از طرف دیگر مطالعات مختلفی نیز جهت پیش‌بینی الگوی آبخستگی در اطراف پل‌ها انجام گرفته است. (Trent et al. (1993 الگوی آبخستگی در اطراف پایه‌های پل را در شرایط هیدرولیکی آب شفاف و بستر متحرک با استفاده از شبکه عصبی مصنوعی مدل‌سازی نمودند. (Liriano & Day (2001 توسط مدل‌های شبکه عصبی مصنوعی عمق آبخستگی در خروجی کالورت‌ها را مدل‌سازی نمودند. آن‌ها

برای تخمین آبخستگی دو مدل مختلف ارائه نمودند و نشان دادند مدل‌های شبکه عصبی آنها مقادیر آبخستگی را با دقت مناسبی تخمین زد. برای پیش‌بینی عمق آبخستگی در مجاورت گروه پایه‌های پل با استفاده از مدل نرو-فازی، (Bateni & Jeng (2007 یک مدل عددی توسعه دادند. آنها نشان دادند که ارتفاع موج و عدد Keulegan-Carpenter موثرترین پارامترها بر روی عمق آبخستگی می‌باشند. آبخستگی پایه‌های پل دایروی شکل با استفاده از الگوریتم‌های شبکه عصبی رگرسیون کلی<sup>۱</sup> و شبکه عصبی پیش‌خور<sup>۲</sup> توسط (Firat and Gungor (2009 مدل‌سازی گردید. آنها نشان دادند که مدل شبکه عصبی رگرسیون کلی آبخستگی را با دقت بیشتری پیش‌بینی می‌کند. (Azamathulla (2012 عمق آبخستگی در اطراف تکیه‌گاه جانبی پایه پل با شکل مختلف را با استفاده از مدل‌های برنامه نویسی بیان ژن و شبکه عصبی مصنوعی مدل‌سازی کرد که بررسی نتایج شبیه‌سازی نشان دهنده برتری مدل برنامه نویسی بیان ژن است. همچنین (Sharafi et al. (2016 با استفاده از ماشین بردار پشتیبان آبخستگی موضعی در مجاورت پایه‌های پل را مدل‌سازی کردند. (Azimi et


\* نویسنده مسئول: saeid.shabanlou@gmail.com



شکل ۱- طرح کلی مدل آزمایشگاهی (Wang et al. (2016a) و Wang et al. (2016b)

#### روش گروهی دست بندی داده‌ها

شبکه عصبی GMDH، شبکه ای خودسازمانده و یک سوپه است که از چندین لایه و هر لایه نیز از چندین نرون تشکیل یافته است (Anastasakis and Mort (2001)) تمامی نرون‌ها از ساختار مشابهی برخوردارند. به گونه ای که هر نرون دارای دو ورودی و یک خروجی می باشد. هر نرون با پنج وزن و یک بایاس، عمل پردازش را مطابق رابطه ۱ بین داده‌های ورودی و خروجی برقرار می‌کند. ساختار ورودی‌ها و خروجی‌های هر نرون در شبکه عصبی از نوع GMDH در شکل (۲) به تصویر کشیده شده است.



شکل ۲- ساختار ورودی‌ها و خروجی‌های هر نرون در شبکه عصبی از نوع GMDH

ANFIS مدل (2017) را برای پیش‌بینی آبشستگی در مجاورت گروه پایه‌های پل در شرایط آب صاف بهینه‌سازی نمودند. آنها برای بهینه‌سازی از الگوریتم تکامل تفاضلی استفاده نمودند. علاوه بر این، Azimi et al. (2019) با توسعه یک مدل ترکیبی هوش مصنوعی مقادیر عمق حفره آبشستگی را در مجاورت تکیه‌گاه پل‌ها شبیه‌سازی نمودند. آنها با انجام یک تحلیل حساسیت، مدل برتر و موثرترین پارامترهای ورودی را معرفی نمودند. همچنین، Shamsirband et al. (2020) با استفاده از بهینه‌سازی ازدحام ذرات مقدار آبشستگی در مجاورت پایه‌های پل را شبیه‌سازی کردند. آنها با تجزیه و تحلیل نتایج شبیه‌سازی-ها، یک معادله برای تخمین عمق آبشستگی ارائه کردند. آنها با انجام یک تحلیل حساسیت نشان دادند که پارامتر بدون بعد عرض پایه پل به عمق جریان موثرترین پارامتر ورودی شناسایی شد.

در این مطالعه برای اولین بار با روش گروهی دست بندی داده‌ها عمق آبشستگی در مجاورت پایه‌های پل دوقلو و سه‌تایی به صورت همزمان شبیه‌سازی می‌گردند. ابتدا پارامترهای موثر شناسایی گردید و چهار مدل روش گروهی دست بندی داده‌ها توسعه داده می‌شوند. سپس با انجام یک تحلیل حساسیت، مدل برتر و موثرترین پارامترهای ورودی معرفی می‌شوند.

#### مواد و روش‌ها

##### مدل فیزیکی

در این مطالعه برای اعتبار سنجی نتایج مدل‌های عددی از مقادیر آزمایشگاهی (Wang et al. (2016a) و Wang et al. (2016b)) استفاده می‌شود. مدل آزمایشگاهی آنها شامل یک کانال مستطیلی به طول، عرض و ارتفاع ۱۲، ۰/۴۲ و ۰/۷ متر می‌باشد. مدل پایه‌های جفت، آنها با نصب دو پایه پل به قطر ۶ سانتیمتر مقدار آبشستگی در اطراف آنها را گزارش نمودند. لازم به ذکر است که عمق اولیه لایه رسوب در این مطالعه آزمایشگاهی ۱۵ سانتیمتر و طول آن ۶ متر است و پایه‌های جفت با فاصله  $d$  در وسط لایه رسوبات واقع شده است. قطر پایه پل ( $D$ ) در حالت جفت مساوی ۶ سانتیمتر اما در حالتی که سه پایه پل در مجاورت یکدیگر قرار داشتند، قطر آنها مساوی ۳ سانتیمتر بود. در مدل با سه پایه پل، فاصله بین پایه‌ها بین صفر، یک، ۲، ۳، ۵، ۶، ۷، ۹، ۱۱، ۱۲، ۱۳ تا ۱۵ (در مجموع ۱۲ حالت مختلف) برابر قطر پایه‌های در نظر گرفته شد. آنها در مجموع ۲۱۰ آزمایش در مطالعه خود اجرا نمودند. در شکل (۱) طرح کلی مدل آزمایشگاهی (Wang et al. (2016a) و Wang et al. (2016b)) نشان داده شده است.

به همین خاطر تابع  $G$  بر اساس قاعده کمترین مربعات خطا پایه‌ریزی می‌گردد (Azimi et al. 2018).

$$\sum_{k=1}^N \left[ (G(x_{ki}, x_{kj}) - y_k)^2 \right] \rightarrow \text{Min} \quad (\text{رابطه ۵})$$

با شرایط حاکم بر مسئله، دستگاه معادله شامل شش مجهول و  $N$  معادله حاصل خواهد شد. (رابطه ۶)

$$\begin{cases} a_0 + a_1 x_{1p} + a_2 x_{1q} + a_3 x_{1p} x_{1q} + a_4 x_{1p}^2 + a_5 x_{1q}^2 = y_1 \\ a_0 + a_1 x_{2p} + a_2 x_{2q} + a_3 x_{2p} x_{2q} + a_4 x_{2p}^2 + a_5 x_{2q}^2 = y_2 \\ \dots \\ a_0 + a_1 x_{Np} + a_2 x_{Nq} + a_3 x_{Np} x_{Nq} + a_4 x_{Np}^2 + a_5 x_{Nq}^2 = y_N \end{cases}$$

دستگاه معادله فوق را می‌توان به فرم ماتریسی زیر نیز

نمایش داد:

$$Aa = Y \quad (\text{رابطه ۷})$$

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\}^T \quad (\text{رابطه ۸})$$

$$Y = \{y_1, y_2, y_3, \dots, y_N\} \quad (\text{رابطه ۹})$$

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}^2 & x_{1q}^2 & x_{1p}^2 x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p}^2 x_{2q}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & x_{Np} & x_{Nq} & x_{Np}^2 & x_{Nq}^2 & x_{Np}^2 x_{Nq}^2 \end{bmatrix} \quad (\text{رابطه ۱۰})$$

برای حل معادله لازم است که معکوس ماتریس غیر مربعی  $A$  محاسبه گردد.

### آبشستگی در مجاورت پایه پل

عمق آبشستگی در مجاورت گروه پایه‌های پل ( $d_s$ ) تابعی از  $d_{50}$ ،  $m$ ،  $D$ ،  $d$ ،  $S_n$ ،  $h$ ،  $U$  و  $U_e$  که به ترتیب برابر عمق آبشستگی، قطر متوسط ذرات رسوب، تعداد پایه‌های پل موازی با جهت جریان، قطر پایه‌های پل، فاصله مرکز به مرکز پایه‌های پل در جهت موازی با جریان، فاصله مرکز به مرکز پایه‌های پل در جهت عمود بر جریان، عمق جریان، سرعت متوسط جریان و سرعت بحرانی به علت حرکت اولیه بر روی رسوبات است (Ataie-Ashtiani et al. 2010):

$$d_s = f(d_{50}, m, n, D, d, S_n, h, U, U_e) \quad (\text{رابطه ۱۱})$$

Wang et al. (2016a) و Wang et al. (2016b) آبشستگی

را در مجاورت پایه‌ها که به فاصله  $d$  از هم قرار دارند اندازه‌گیری نمودند. در مطالعه آنها مقادیر  $d_{50}$ ،  $m$ ،  $n$ ،  $D$ ،  $d$ ،  $S_n$  و  $U_e$  تقریباً ثابت هستند. با در نظر گرفتن گروه‌های بدون بعد رابطه معادله ۱۱ به صورت زیر بازنویسی می‌شود:

$$ds/h = f(D/h, d/h, Fr) \quad (\text{رابطه ۱۲})$$

در اینجا  $Fr = U/\sqrt{gh}$  عدد فرود می‌باشد. بنابراین

$$y_{ik}^* = N(x_i \alpha, x_i \beta) = b^k + w_1^k x_i \alpha + w_2^k x_i \beta + w_3^k x_i^2 \alpha + w_4^k x_i^2 \beta + w_5^k x_i \alpha x_i \beta \quad (\text{رابطه ۱})$$

در رابطه فوق  $N$  ( $i=1, 2, 3, \dots, N$ ) تعداد نمونه‌های ورودی و خروجی،  $m$  تعداد نرون‌های لایه قبلی،  $k$  وابسته به پارامتر  $C_m^2 = \frac{m(m-1)}{2}$  است که به صورت  $K=1, 2, 3, \dots, C_m^2$  ارائه می‌شود و  $\alpha$  و  $\beta$  به صورت  $\alpha, \beta \in \{1, 2, 3, \dots, m\}$  تعریف می‌شوند. وزن‌ها بر اساس روش‌های کمترین مربعات خطا محاسبه شده و سپس به عنوان مقادیر مشخص و ثابت در داخل هر نرون جایگذاری می‌شود. ویژگی بارزی که در این نوع از شبکه‌ها مشاهده می‌گردد، حاکی از آن است که نرون‌های مرحله قبلی و یا لایه قبلی عامل و یا مولد تولید نرون‌های جدید به تعداد  $C_m^2 = \frac{m(m-1)}{2}$  می‌باشند که از میان نرون‌های تولید شده، لزوماً بایستی تعدادی از آنها حذف گردند تا بدین وسیله از واگرایی شبکه جلوگیری به عمل آید. اصطلاحاً به اینگونه نرون‌های حذف شده، نرون مرده یا غیر فعال گفته می‌شود. معیاری که برای گزینش و حذف مجموعه‌ای از نرون‌ها در یک لایه در نظر گرفته می‌شود، میزان مجموع مربعات خطا ( $r_j^2$ ) میان مقادیر خروجی واقعی ( $y_i$ ) و خروجی نرون  $j$  ام ( $y_{ij}^*$ ) می‌باشد.

$$r_j^2 = \frac{\sum_{i=1}^N (y_i - y_{ij}^*)^2}{N} \quad (\text{رابطه ۲})$$

در رابطه فوق  $j \in \{1, 2, 3, \dots, C_m^2\}$  می‌باشد که در آن  $m$  تعداد نرون‌های گزینش شده در لایه قبلی می‌باشد (Noori et al., 2010). نگاشتی که بین متغیرهای ورودی و خروجی توسط شبکه عصبی از نوع GMDH برقرار می‌شود، به صورت تابع غیرخطی ولترا به فرم رابطه زیر است:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i X_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} X_i X_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} X_i X_j X_k + \dots \quad (\text{رابطه ۳})$$

ساختار نرون‌ها به فرم خلاصه شده دو متغیره درجه دوم به شکل زیر است:

$$y_i = f(x_{ip}, x_{iq}) = a_0 + a_1 x_{ip} + a_2 x_{iq} + a_3 x_{ip}^2 + a_4 x_{iq}^2 + a_5 x_{ip} x_{iq} \quad (\text{رابطه ۴})$$

تابع  $f$  دارای شش ضریب مجهول می‌باشد، لذا بایستی آنها را طوری تنظیم کنیم که به ازای تمام نمونه‌های دو متغیره وابسته به سیستم  $\{(x_{ip}, x_{iq}), i=1, 2, 3, \dots, N\}$  خروجی مطلوب  $\{(y_i), i=1, 2, \dots, N\}$  برقرار گردد (Atashkari et al., 2007).

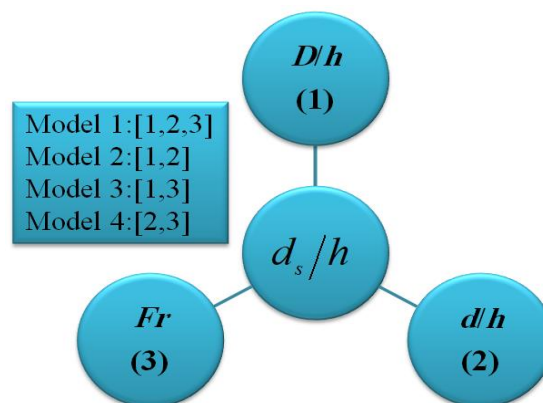
است. همچنین، محدوده مقادیر آزمایشگاهی مورد استفاده در این مطالعه در جدول (۱) قابل مشاهده است.

پارامترهای معادله ۱۲ به عنوان پارامترهای ورودی مدل‌های عددی در این مطالعه در نظر گرفته می‌شوند. در شکل (۳) نحوه ترکیب پارامترهای ورودی برای مدل‌های مختلف نشان داده شده

جدول ۱- محدوده مقادیر آزمایشگاهی مورد استفاده در این مطالعه

پارامتر	حداکثر	حداقل	میانگین	انحراف معیار	واریانس
$ds/h$	۰/۶۲۵	۰/۰۰۸	۰/۲۲۷	۰/۱۵۲	۰/۰۲۳
$D/h$	۰/۵۰۰	۰/۲۵۰	۰/۳۵۹	۰/۱۰۷	۰/۰۱۱
$d/h$	۷/۵۰	۰/۲۵۰	۲/۵۸۸	۱/۹۵۴	۳/۸۱۷
Fr	۰/۲۵۸	۰/۱۱۶	۰/۱۸۶	۰/۰۴۰	۰/۰۰۲

شده به وسیله مدل‌های عددی،  $\bar{O}$  میانگین مقادیر مشاهداتی و  $n$  برابر تعداد مقادیر مشاهداتی است. در ادامه به بررسی دقت مدل‌های GMDH تعریف شده در وضعیت‌های آموزش و آزمون پرداخته می‌شود. لازم به ذکر است که ۷۰ درصد مقادیر مشاهداتی برای آموزش مدل‌های نرو- فازی استفاده و در مقابل ۳۰ درصد باقیمانده مقادیر آزمایشگاهی جهت آزمون این مدل‌ها به کار گرفته می‌شوند. در ادامه، با تجزیه و تحلیل نتایج شبیه‌سازی‌ها، مدل برتر و موثرترین پارامترهای موردی شناسایی خواهند شد.



شکل ۳- نحوه ترکیب پارامترهای ورودی برای توسعه مدل‌های GMDH

## نتایج و بحث

### تحلیل حساسیت

با توجه به شکل (۳)، با استفاده از پارامترهای بدون بعد تعریف شده در معادله (۱۲)، چهار مدل GMDH متمایز برای اجرای تحلیل حساسیت این مدل‌ها توسعه داده شد. مدل شماره یک یا همان GMDH 1 مقادیر آبشستگی‌ها را بر حسب کلیه پارامترهای ورودی یا  $(D/h, d/h, Fr)$  شبیه‌سازی کرد. بر اساس نتایج شبیه‌سازی‌ها، مقادیر شاخص‌های آماری SI، R و VAF برای وضعیت آزمون مدل GMDH 1 به ترتیب برابر با ۰/۲۱۲، ۰/۹۴۹ و ۹۰/۱۲۹ تخمین زده شدند. در مقابل مقادیر MAE و RMSE برای وضعیت آموزش مدل GMDH 1 به ترتیب برابر با ۰/۳۷ و ۰/۴۸ بودند.

این در حالی است که سه مدل GMDH 2 تا GMDH 4 مقادیر تابع هدف (عمق حفره آبشستگی) را بر حسب ترکیبی از دو پارامتر بدون بعد تخمین زدند. هدف از توسعه این سه مدل GMDH شناسایی تاثیرگذارترین پارامترهای ورودی و تاثیرگذار بر روی توانایی مدل GMDH برای شبیه‌سازی عمق حفره آبشستگی است.

مدل GMDH 2 تابعی از پارامترهای بدون بعد  $D/h$  و  $d/h$  بود. به بیان دیگر برای پیش‌بینی تابع هدف تأثیر عدد فرود نادیده

### معیارهای ارزیابی دقت مدل‌های GMDH

در مطالعه حاضر به منظور ارزیابی دقت مدل‌های عددی معرفی شده از شاخص‌های آماری ضریب همبستگی ( $R$ )، شاخص عملکرد ( $VAF$ )، خطای مربعات میانگین ریشه ( $RMSE$ )، شاخص پراکندگی ( $SI$ )، خطای مطلق میانگین ( $MAE$ ) و ضریب بهره‌وری نش ساتکلیف ( $NSC$ ) به صورت زیر استفاده می‌گردد:

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (\text{رابطه ۱۳})$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)}\right) \times 100 \quad (\text{رابطه ۱۴})$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (\text{رابطه ۱۵})$$

$$SI = \frac{RMSE}{O} \quad (\text{رابطه ۱۶})$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (\text{رابطه ۱۷})$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (\text{رابطه ۱۸})$$

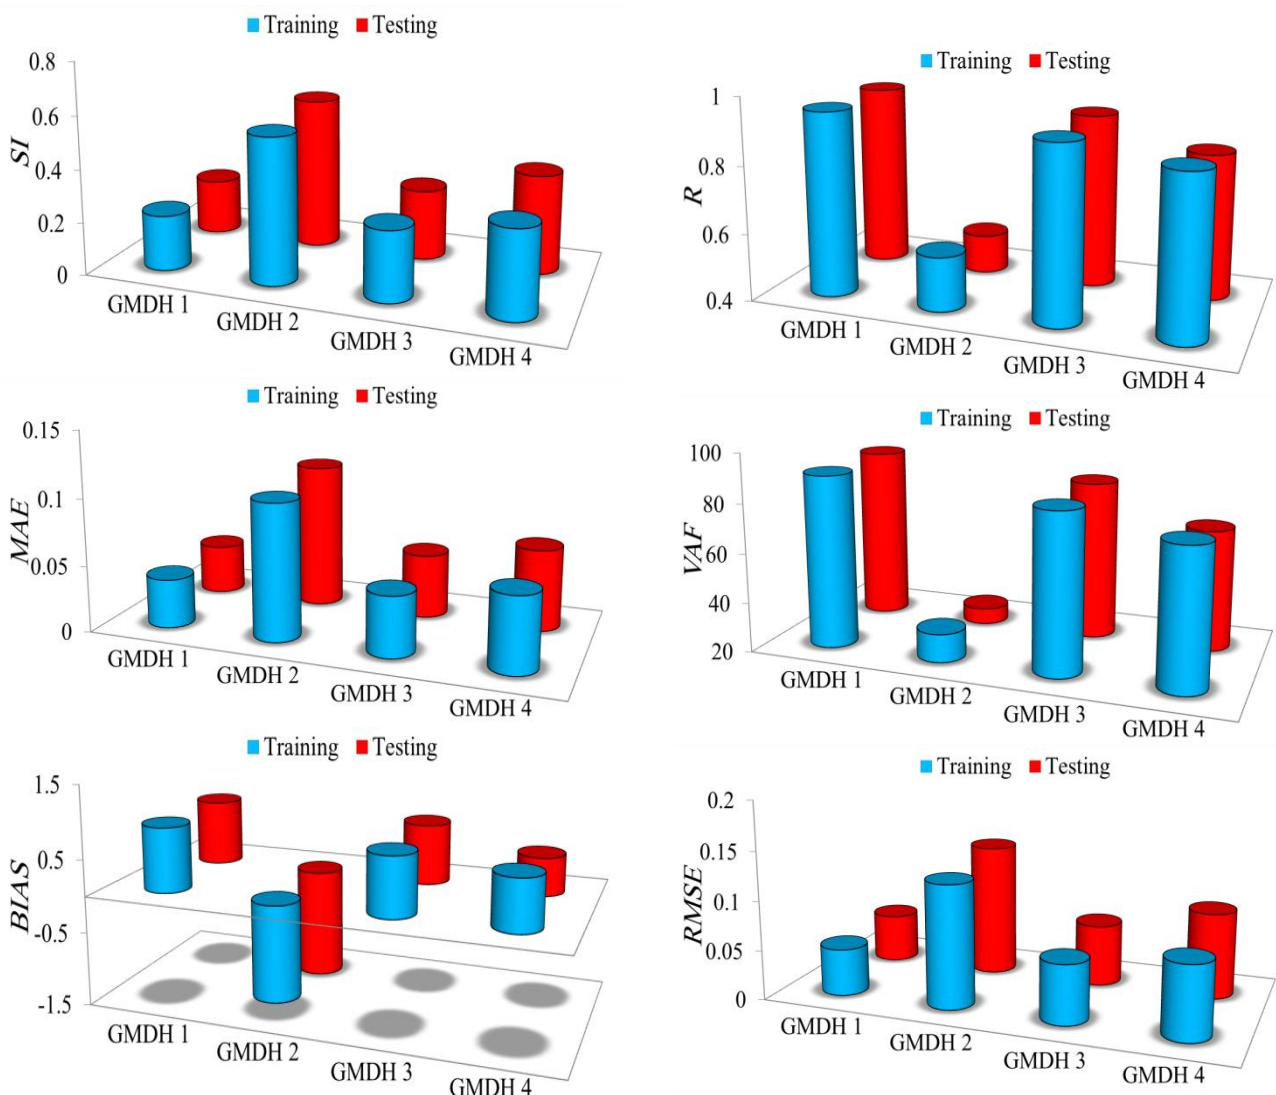
در اینجا  $O_i$  مقادیر مشاهداتی،  $F_i$  مقادیر تراز پیش‌بینی

لازم به ذکر است که تاثیر پارامتر  $D/h$  برای شبیه‌سازی عمق حفره آبستگي توسط مدل GMDH 4 حذف گردید و این مدل مقادير تابع هدف را بر حسب  $d/h$  و  $Fr$  پیش‌بینی کرد. علاوه بر این، مقادير  $SI$ ،  $R$  و  $MAE$  برای شرایط آزمون مدل GMDH 4 به ترتیب برابر با ۰/۳۷۵، ۰/۸۳۱ و ۰/۹۵۷ بودند. در وضعیت آموزش مدل GMDH 4، مقادير شاخص‌های  $MAE$  و  $RMSE$  به ترتیب برابر با ۰/۰۵۶ و ۰/۰۷۴ بودند.

نتایج شاخص‌های آماری محاسبه شده برای مدل‌های GMDH برای هر دو وضعیت آموزش و آزمون در شکل (۴) قابل مشاهده است. علاوه بر این، مقایسه مقادير آبستگي‌های شبیه‌سازی شده توسط مدل‌های GMDH با مقادير آزمایشگاهی در شرایط آموزش و آزمون در شکل (۵) نشان داده شده است.

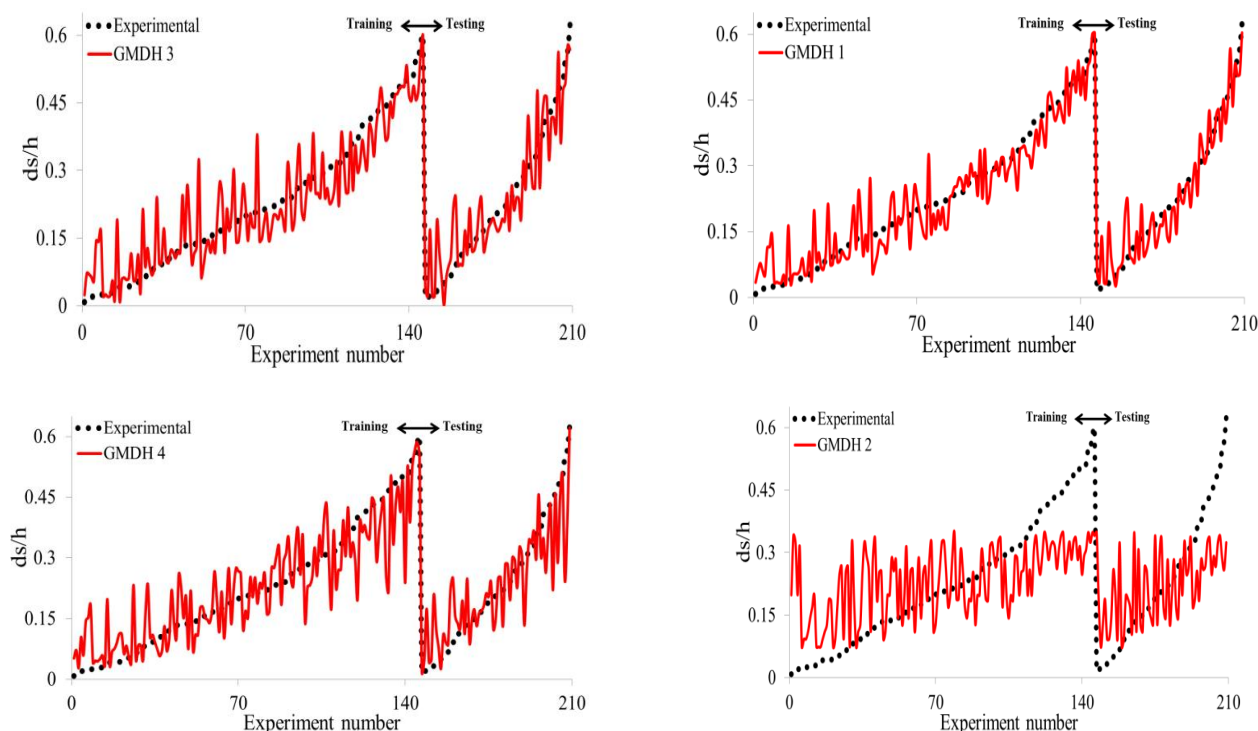
گرفته شد. مقادير شاخص‌های  $SI$ ،  $R$  و  $MAE$  برای مدل GMDH 2 در شرایط آزمون به ترتیب برابر با ۰/۵۸۰، ۰/۵۱۵ و ۰/۴۷۸- بدست آمدند. در وضعیت آموزش مدل GMDH 2 نیز مقادير  $RMSE$  و  $MAE$  به ترتیب مساوی با ۰/۱۲۵ و ۰/۱۰۲ محاسبه شدند.

علاوه بر این، برای مدل GMDH 3 تاثیر پارامتر  $d/h$  نادیده گرفته شده است. به بیان دیگر مدل مذکور مقادير تابع هدف را بر حسب پارامترهای بدون  $D/h$  و  $Fr$  شبیه‌سازی کرد. این در حالی است که برای شرایط آزمون مدل GMDH 3 مقادير  $SI$ ،  $R$  و  $MAE$  به ترتیب مساوی ۰/۲۶۹، ۰/۹۱۷ و ۰/۱۲۰ محاسبه شدند. لازم به ذکر است که مقادير  $MAE$  و  $RMSE$  مدل GMDH 3 در شرایط آموزش به ترتیب مساوی با ۰/۰۴۵ و ۰/۰۶۰ بدست آمدند.



شکل ۴- شاخص‌های آماری محاسبه شده برای مدل‌های GMDH در هر دو شرایط آموزش و آزمون



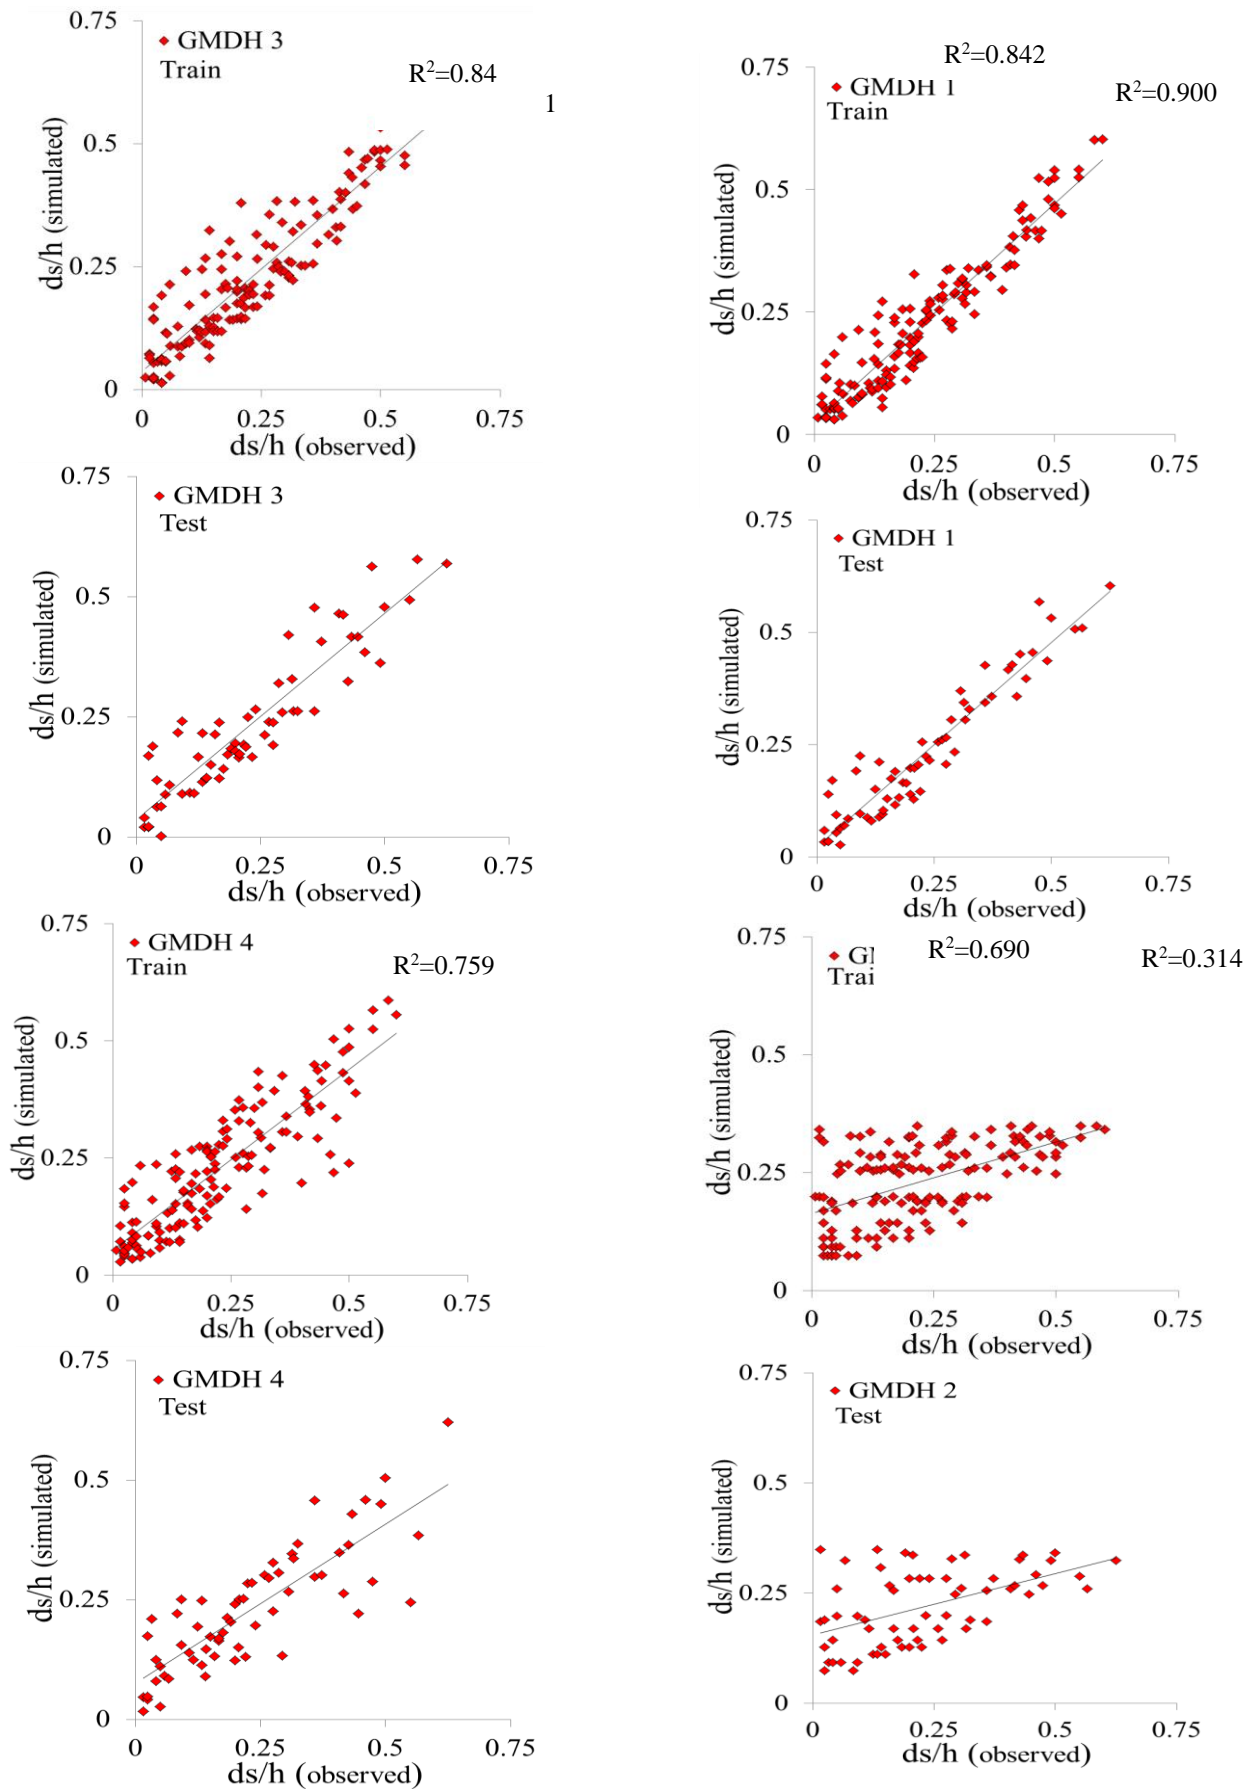


شکل ۵- مقایسه مقادیر آبخستگی شبیه‌سازی شده توسط مدل‌های GMDH با مقادیر آزمایشگاهی در شرایط آموزش و آزمون

همچنین برای تجزیه و تحلیل بیشتر نتایج مدل‌های GMDH 1 تا GMDH 4 پارامتر ضریب اختلاف<sup>۱</sup> ( $DR$ ) به صورت نسبت مقادیر آبخستگی‌های مدل‌سازی شده به مقدار آزمایشگاهی ( $DR = (ds/h)_{(simulated)} - (ds/h)_{(observed)}$ ) معرفی می‌شود. بنابراین نحوه تغییرات پارامتر  $DR$  در مقابل مقادیر آبخستگی‌های بدون بعد در شکل (۷) نشان داده شده است. لازم به یادآوری است که نزدیک بودن مقدار پارامتر  $DR$  به عدد یک نشان دهنده عملکرد بهتر مدل عدد مورد نظر است. بر اساس نتایج مدل‌سازی عددی، مقدار  $DR$  متوسط برای مدل GMDH 1 برابر ۱/۲۲۸۰۰۵ است. مقادیر ضریب اختلاف حداقل و حداکثر برای مدل GMDH 1 به ترتیب مساوی با ۰/۳۹۲ و ۱/۲۲۸ محاسبه شدند. در مقابل مقدار  $DR$  متوسط برای مدل GMDH 2 برابر ۲/۰۱۸ و برای GMDH 3 مساوی ۱/۲۵۷ محاسبه گردید. این در حالی است که مقدار این پارامتر برای مدل GMDH 4 برابر ۱/۳۴۲ بدست آمد. علاوه بر این، مقدار ضریب اختلاف حداکثر برای مدل‌های GMDH 2، GMDH 3 و GMDH 4 به ترتیب برابر با ۲۳/۸۰۱، ۶/۷۵۵ و ۷/۷۵۳ تخمین زده شدند. بنابراین با توجه به تجزیه و تحلیل پارامتر ضریب اختلاف، مدل GMDH 1 دارای کوچکترین مقدار ضریب اختلاف متوسط بود.

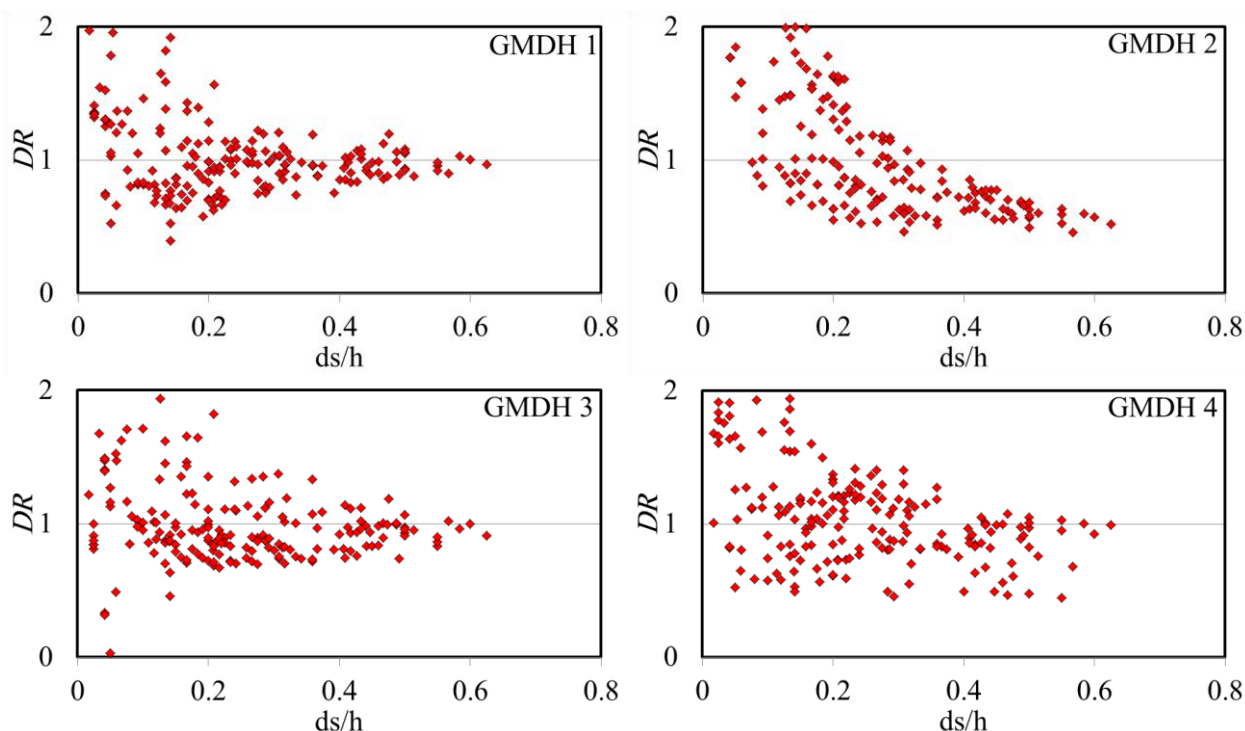
در شکل (۶) نمودارهای پراکندگی برای مدل‌های GMDH مختلف در شرایط آموزش و آزمون به تصویر کشیده شده است. با توجه به نتایج تحلیل حساسیت اجرا شده، مدل GMDH 1 دارای بیشترین دقت و کمترین مقدار خطا است. به عبارت دیگر، مدل GMDH 1 به عنوان مدل برتر شناسایی گردید که مقادیر حفره آبخستگی را بر حسب کلیه پارامترهای ورودی شبیه‌سازی نمود. مدل GMDH 1 در مقایسه با سایر مدل‌های هوش مصنوعی توسعه داده شده در مطالعه حاضر در هر دو وضعیت آموزش و آزمون عملکرد بهتری داشت. بعد از مدل GMDH 1، مدل GMDH 3 دارای بیشترین همبستگی با مقادیر آزمایشگاهی بود (دومین مدل از نظر دقت). لازم به ذکر است که مدل‌های GMDH 2 و GMDH 4 به ترتیب به عنوان سومین و چهارمین مدل از لحاظ دقت در نظر گرفته شدند.

بر اساس نتایج تحلیل حساسیت، با حذف کردن عدد فرود ( $Fr$ ) دقت مدل‌سازی به شکل قابل ملاحظه (بیش از نود درصد) کاهش یافت. بنابراین، عدد فرود جریان به عنوان موثرترین پارامتر بدون بعد شناسایی گردید. بعد از عدد فرود، پارامترهای بدون بعد  $d/h$  و  $D/h$  به ترتیب به عنوان دومین و سومین پارامتر بدون بعد از لحاظ تاثیرگذاری در نظر گرفته شدند.



شکل ۶- نمودارهای پراکنندگی برای مدل‌های GMDH





شکل ۷- نمودارهای نسبت اختلاف برای مدل‌های GMDH

**مدل‌های GMDH**

در این قسمت روابط استخراج شده از مدل‌های GMDH ارائه می‌گردد. مدل شماره یک یا GMDH 1 تابعی از کلیه پارامترهای ورودی یا همان  $Fr$ ،  $D/h$  و  $d/h$  بودند. مدل GMDH 2 تابعی از  $D/h$  و  $d/h$  بود این در حالی است که مدل GMDH 3 مقادیر آبشستگی‌ها را بر حسب  $Fr$  و  $D/h$  شبیه‌سازی کرد. لازم به ذکر است که مدل GMDH 4 با استفاده از  $Fr$  و  $d/h$  مقادیر تابع هدف

**GMDH 1**

(رابطه ۱۹)

$$x4 = 0.268 - 6.269 \times (Fr) - 0.113 \times (d/h) + 1.214 \times (d/h) \times (Fr) + 46.459 \times (Fr)^2 + 0.0003 \times (d/h)^2 - 2.060 \times (d/h) \times (Fr)^2 + 0.003 \times (d/h)^2 \times (Fr) - 88.252 \times (Fr)^3 - 0.0003 \times (d/h)^3$$

$$x5 = -0.644 + 3.933 \times (Fr) + 1.303 \times (D/h) + 23.259 \times (D/h) \times (Fr) - 34.704 \times (Fr)^2 - 5.956 \times (D/h)^2 + 7.846 \times (D/h) \times (Fr)^2 - 22.846 \times (D/h)^2 \times (Fr) + 53.195 \times (Fr)^3 + 5.380 \times (D/h)^3$$

$$ds/h = 0.036 + 0.727 \times x5 - 0.628 \times x4 - 10.223 \times x4 \times x5 + 4.535 \times (x5)^2 + 9.235 \times (x4)^2 - 23.756 \times x4 \times (x5)^2 + 36.854 \times (x4)^2 \times x5 + 3.890 \times (x5)^3 - 20.462 \times (x4)^3$$

**GMDH 2**

(رابطه ۲۰)

$$ds/h = -0.383 + 0.124 \times (d/h) + 1.854 \times (D/h) + 0.035 \times (D/h) \times (d/h) - 0.033 \times (d/h)^2 + 0.082 \times (D/h)^2 + 0.121 \times (D/h) \times (d/h)^2 - 0.882 \times (D/h)^2 \times (d/h) - 0.002 \times (d/h)^3 - 1.951 \times (D/h)^3$$

**GMDH 3**

(رابطه ۲۱)

$$ds/h = -0.644 + 3.933 \times (Fr) + 1.303 \times (D/h) + 23.259 \times (D/h) \times (Fr) - 34.704 \times (Fr)^2 - 5.956 \times (D/h)^2 + 7.846 \times (D/h) \times (Fr)^2 - 22.846 \times (D/h)^2 \times (Fr) + 53.195 \times (Fr)^3 + 5.380 \times (D/h)^3$$

**GMDH 4**

(رابطه ۲۲)

$$ds/h = 0.268 - 6.269 \times (Fr) - 0.113 \times (d/h) + 1.214 \times (d/h) \times (Fr) + 46.459 \times (Fr)^2 + 0.0003 \times (d/h)^2 - 2.060 \times (d/h) \times (Fr)^2 + 0.003 \times (d/h)^2 \times (Fr) -$$

را تخمین زد. معادله‌های بدست آمده از مدل GMDH 1 تا GMDH 4 در قالب روابط ۱۹ تا ۲۲ ارائه می‌شود. نتایج شبیه‌سازی‌ها نشان داد که مدل GMDH 1 در مقایسه با سایر مدل‌های GMDH از عملکرد بهتری برخوردار بود. به بیان دیگر این مدل کمترین مقدار خطا و بیشترین همبستگی را با مقادیر مشاهده‌ای داشت.

$$88.252 \times (Fr)^3 - 0.0003 \times (d/h)^3$$

مصنوعی استفاده شده در مطالعه حاضر بود.

### مقایسه با مطالعات گذشته

در این بخش از مطالعه، نتایج مدل برتر یا همان مدل GMDH 1 با نتایج سایر مطالعات از قبیل مطالعه (Azimi et al. (2018) و (Shamshirband et al. (2020) مقایسه می‌شود. (Shamshirband et al. (2018) از یک مدل فرا ابتکاری نو- فازی و (al. (2020) نیز از الگوریتم بهینه‌سازی ازدحام ذرات برای شبیه‌سازی سازی مقادیر آبخستگی‌ها استفاده کردند. در جدول (۲) نتایج این مقایسه نشان داده شده است. همان‌طور که ملاحظه می‌شود، مدل GMDH 1 دارای همبستگی بیشتری در مقایسه با مدل (Shamshirband et al. (2020) بود اما دقت مدل هوش مصنوعی (Azimi et al. (2018) بیشتر بود. این مقایسه نشان داد که مدل GMDH 1 دارای همبستگی بالا و دقت قابل قبول جهت تخمین مقادیر آبخستگی‌ها بود.

همان‌طور که نشان داده شد، مدل GMDH 1 مدل برتر برای شبیه‌سازی مقادیر آبخستگی‌ها شناسایی شد زیرا مدل هوش مصنوعی مذکور از لحاظ دقت و همبستگی در مقایسه با سایر مدل‌ها از عملکرد بهتری برخوردار بود. بعد از مدل GMDH 1، مدل GMDH 3 از عملکرد بهتری برخوردار بود. لازم به ذکر است که مدل‌های GMDH 2 و GMDH 4 در جایگاه سوم و چهارم قرار گرفتند. علاوه بر این، نتایج تحلیل حساسیت نشان داد که عدد فرود جریان موثرترین پارامتر ورودی در نظر گرفته شد زیرا با حذف عدد فرود، عملکرد مدل هوش مصنوعی به شکل قابل ملاحظه‌ای کاهش یافت. همچنین، پارامترهای بدون بعد  $D/h$  از لحاظ اثرگذاری در جایگاه دوم قرار گرفت. این در حالی بود که پارامتر ورودی  $d/h$  کمترین تاثیر را در شبیه‌سازی مقادیر آبخستگی‌ها داشت. به عبارت دیگر با حذف پارامتر بدون بعد  $d/h$  عملکرد مدل GMDH 1 کمترین کاهش را داشت. مدل GMDH 1 دارای کمترین مقدار ضریب اختلاف در میان مدل‌های هوش

جدول ۲- مقایسه نتایج مدل GMDH 1 با مدل‌های هوش مصنوعی (Azimi et al. (2018) و (Shamshirband et al. (2020)

NSC	MAE	SI	RMSE	VAF	R	مدل
۰/۸۹۳	۰/۰۳۷	۰/۲۱۲	۰/۰۴۹	۹۰/۱۲۹	۰/۹۴۹	GMDH 1
-	-	۰/۰۵۸	۰/۰۰۷	-	۰/۹۹۶	Azimi et al. (2018)
-	۰/۰۲۹	-	۰/۰۴۳	-	۰/۹۴۷	Shamshirband et al. (2020)

ورودی تخمین زد. این مدل دارای دقت قابل قبولی بود، به عنوان مثال، مقدار R، NSC و RMSE برای این مدل در شرایط آموزش به ترتیب مساوی با ۰/۹۴۹، ۰/۸۸۸ و ۰/۰۴۸ تخمین زده شدند. همچنین، برای وضعیت آزمون این مدل، مقادیر VAF، SI و MAE به ترتیب برابر با ۹۰/۱۲۹، ۰/۲۱۲ و ۰/۰۳۷ محاسبه شدند. بر اساس نتایج تحلیل حساسیت، پارامتر بدون عدد فرود جریان به عنوان موثرترین پارامتر ورودی شناسایی شد. بعد از عدد فرود جریان، پارامترهای بدون بعد  $D/h$  و  $d/h$  به ترتیب به عنوان دومین و سومین پارامتر بدون از لحاظ تاثیرگذاری معرفی شدند. برای مدل برتر GMDH یک رابطه پیشنهاد گردید. در انتها، نتایج مدل برتر GMDH با نتایج سایر مطالعات نیز مقایسه شد که این مقایسه حاکی از عملکرد قابل قبول مدل هوش مصنوعی GMDH جهت شبیه‌سازی مقادیر آبخستگی در اطراف پایه پل‌ها بود.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

### نتیجه‌گیری

شناسایی الگوی آبخستگی در اطراف پایه‌های پل یکی از مهمترین معیارهای طراحی این نوع از سازه‌ها محسوب می‌شود. به طور کلی مطالعات فراوانی برای تخمین و اندازه‌گیری عمق حفره آبخستگی در مجاورت پایه‌های پل انجام شده است. در مطالعه حاضر با استفاده از روش دسته‌بندی گروهی داده‌ها (GMDH) عمق آبخستگی در اطراف پایه‌های پل جفت و سه‌تایی تخمین زده شدند. ابتدا با استفاده از پارامترهای موثر بر روی عمق آبخستگی، چهار مدل GMDH توسعه داده شد. لازم به ذکر است که ۷۰ درصد مقادیر مشاهداتی برای آموزش مدل‌های GMDH و ۳۰ درصد نیز برای آزمون آنها استفاده شد. سپس با تجزیه و تحلیل نتایج مدل‌های عددی نشان داده شد که مدل‌های ترکیبی در مقایسه با مدل‌های GMDH مقادیر آبخستگی را با دقت بیشتری تخمین می‌زنند. علاوه بر این مدل برتر معرفی شد. مدل برتر (GMDH 1) مقادیر آبخستگی را بر حسب کلیه پارامترهای

### REFERENCES

Anastasakis, L. and Mort, N. (2001). The development of self-organization techniques in modelling: a review of the group method of data handling (GMDH). Research Report-University of

Sheffield.

Atashkari, K, Nariman-Zadeh, N, Gölcü, M, Khalkhali, A. and Jamali, A. (2007). Modelling and multi-objective optimization of a variable valve-timing

- spark-ignition engine using polynomial neural networks and evolutionary algorithms. *Energy Conversion and Management*, 48(3), 1029-1041.
- Ataie-Ashtiani, B., Baratian-Ghorghi, Z., and Beheshti, A.A. (2010). Experimental investigation of clear-water local scour of compound piers. *Journal of Hydraulic Engineering*, 136(6), 343-351.
- Azamathulla, H.M. (2012). Gene-expression programming to predict scour at a bridge abutment. *Journal of Hydroinformatics*, 14(2), 324-331.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Gharabaghi, B., and Khoshbin, F. (2018). Evolutionary design of generalized group method of data handling-type neural network for estimating the hydraulic jump roller length. *Acta Mechanica*, 229(3), 1197-1214.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Talesh, S. H. A., Michelson, D. G., and Jamali, A. (2017). Evolutionary Pareto optimization of an ANFIS network for modeling scour at pile groups in clear water condition. *Fuzzy Sets and Systems*, 319, 50-69.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Shabanlou, S., Talesh, S. H. A., and Jamali, A. (2019). A pareto design of evolutionary hybrid optimization of ANFIS model in prediction abutment scour depth. *Sādhanā*, 44(7), 169.
- Batani, S. M., and Jeng, D. S. (2007). Estimation of pile group scour using adaptive neuro-fuzzy approach. *Ocean Engineering*, 34(8), 1344-1354.
- Firat, M., and Gungor, M. (2009). Generalized regression neural networks and feed forward neural networks for prediction of scour depth around bridge piers. *Advances in Engineering Software*, 40(8), 731-737.
- Liriano, S. L., and Day, R. A. (2001). Prediction of scour depth at culvert outlets using neural networks. *Journal of Hydroinformatics*, 3(4), 231-238.
- Noori, R., Hoshyaripour, Gh., Ashrafi, Kh., and Nadjar Araabi B. (2010). Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration. *Atmospheric Environment*, 44(4), 476-482.
- Shamshirband, S., Mosavi, A., and Rabczuk, T. (2020). Particle swarm optimization model to predict scour depth around a bridge pier. *Frontiers of Structural and Civil Engineering*, 14(4), 855-866.
- Sharafi, H., Ebtehaj, I., Bonakdari, H., and Zaji, A. H. (2016). Design of a support vector machine with different kernel functions to predict scour depth around bridge piers. *Natural Hazards*, 84(3), 2145-2162.
- Trent, R., Gagarin, N., and Rhodes, J. (1993). Estimating pier scour with artificial neural networks. In *Hydraulic Engineering* (pp. 1043-1048). ASCE.
- Wang, H., Tang, H.W., Xiao, J.F., Wang, Y., and Jiang, S. (2016a). Clear-water local scouring around three piers in a tandem arrangement. *Science China Technological Sciences*, 59(6), 888-896.
- Wang, H., Tang, H., Liu, Q., and Wang, Y. (2016b). Local scouring around twin bridge piers in open-channel flows. *Journal of Hydraulic Engineering*, 142(9), 060160081-8.