

Application of the Taguchi Method in Reducing the Number of Experiments and Optimizing the Factors in an Artificial Neural Network Related to the Phenomenon of Design of the Stable Size of Riprap Around Bridge Piers

Sara Esfandmaz¹, Atabak Feizi^{2*}, Mojtaba Karimaei Tabarestani³

1- Graduated M.Sc. in Civil Engineering-Water Resource Management and Engineering, Dept. of Civil Engineering, University of Mohaghegh Ardabili, Ardabil, Iran.

2- Associate Professor, Dept. of Civil Engineering, Faculty of Engineering, University of Mohaghegh Ardabili, Ardabil, Iran, (Corresponding Author).

3- Assistant Professor, Dept. of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran.

* a_feizi@uma.ac.ir

Received: 10 June 2021, Accepted: 21 August 2021 J. Hydraul. Homepage: www.jhyd.iha.ir

Abstract

Introduction: Hydraulic phenomena are typically studied in the laboratory; thus, it appears necessary to employ a method that minimizes the number of experiments, saves time and money, and maintains reasonable accuracy; one such method is the Taguchi method. To this end, the Taguchi method and response level were used to evaluate the efficiency of trapping and sedimentation in the pond of the laboratory model and introduce the effective parameters (Dalir et al., 2021). Ranjbar-Zahedi et al. (2021) used the 27 proposed Taguchi experiments to determine the optimal structure's size and location and minimize local scouring around the bridge piers and the number of experiments. Atarodi et al. (2020) designed geometric decompositions using the Taguchi and Taguchi-GRA methods. In the present study, in addition to utilizing the Taguchi property for reducing the number of studies examining a stable RipRap size around the bridge piers (number of experiments in the experimental part and number of responses in the neural network), Taguchi optimization and prediction (a less studied property) was used. Then, the Taguchi prediction results were compared to the artificial neural network (ANN) results for validation.

Methodology: The Taguchi method was examined to reduce the number of experiments and propose different, but limited compounds for study. Additionally, the results were analyzed using the mean graph and the signal-to-noise ratio (S/N), and the optimal parameter combination was introduced. Furthermore, the ANOVA table was used to determine the effects of each parameter level and, finally, the effective parameters. To evaluate the results, the predictive property was used to compare the results of Taguchi method to the results of the ANN. It should be noted that the Taguchi method was used to adjust adjustable parameters of the neural network for the stone crushing failure phenomenon. To determine the stable size of the RipRap around the bridge piers for scouring protection, 145 research laboratory data were analyzed (Karimaei Tabarestani and Zarrati, 2013). Four parameters were determined using these data: flow rate in six levels, rock size, and ratio. The length of bridge pier to width ratio and pitch angle relative to the flow direction were examined at three levels. Moreover, the adjustable components of neural network were examined at three levels,

including the four components of the number of neurons in the first and second hidden layers, the training function, and the transmission function in each layer. Finally, the neural network results were compared to the Taguchi prediction results.

Results and Discussion: Compared to the results of Karimaie Tabarestani and Zarrati (2013) and the complete factorial method, the Taguchi method eliminates 87 and 89% of tests, respectively, while saving time and money. To this end, a stable RipRap size was designed around bridge piers to prevent scouring through the Taguchi method. The results of the Taguchi analysis revealed that the maximum flow depth required for crimping stability occurs when the flow rate is $0.06 \text{ m}^3 / \text{s}$, d_{50} is 0.00205 m , L is 35 m , and $\theta = 20$ is 20 degrees, and the most effective parameter Q was introduced in this regard. Additionally, the best ANN based on Taguchi's optimal combination based on S/N diagram analysis will have three layers and a correlation coefficient (R) of 0.971 when the first and second hidden layers contain seven neurons each. The neuron is a training function for tranlm, and each layer has a transmission function of tansig. Moreover, ANOVA analysis indicated that the transfer function was the most effective factor, with a participation rate of 95.07%. Finally, the Taguchi-assisted neural network (detection coefficient of 0.94) was superior to the Taguchi method (detection coefficient of 0.79) in predicting the results of designing a stable RipRap size around bridge piers to prevent scouring.

Conclusion: This study demonstrates that by utilizing the Taguchi orthogonal array table and analyzing its results in the experimental section, the optimal parameter combination can be determined with a limited number of experiments, and the optimal solution can be predicted. Furthermore, the Taguchi method is a suitable alternative to the trial and error method for adjusting neural network parameters. Also, the Taguchi method produces sufficiently accurate results when designing neural network parameters.

Keywords: Taguchi Method, Artificial Neural Network Bridge Piers, RipRap, Scour.



© 2021 Iranian Hydraulic Association, Tehran, Iran.
This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license)
(<http://creativecommons.org/licenses/by/4.0/>)

کاربرد روش تاگوچی در کاهش شمار آزمایش‌ها و بهینه‌سازی فراسنجه‌های شبکه عصبی مصنوعی (بررسی موردی: پایداری سنگ‌چین در پیرامون پایه پل)

سارا اسفندمز^۱، اتابک فیضی^{۲*}، مجتبی کریمائی طبرستانی^۳

۱- فارغ التحصیل کارشناسی ارشد رشته مهندسی عمران- مهندسی و مدیریت منابع آب، دانشکده فنی و مهندسی، دانشگاه محقق اردبیلی، اردبیل، ایران
 ۲- دانشیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه محقق اردبیلی، اردبیل، ایران
 ۳- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران

* a_feizi@uma.ac.ir

دریافت: ۱۴۰۰/۰۳/۲۰، پذیرش: ۱۴۰۰/۰۵/۳۰ و وب‌گاه نشریه هیدرولیک: www.jhyd.iha.ir

چکیده: در این تحقیق از روش تاگوچی، که یکی از روش‌های طراحی آزمایش‌هاست، برای کاهش شمار آزمایش‌های تجربی و همچنین تنظیم فراسنجه‌های ورودی در طراحی شبکه عصبی مصنوعی استفاده می‌شود. برای این منظور از نتایج بررسی آزمایشگاهی پیشین که مربوط به پدیده پایداری سنگ‌چین در پیرامون پایه پل است به عنوان بررسی موردی استفاده شد. همچنین قابلیت پیش‌بینی تاگوچی در مقایسه با نتایج به‌دست آمده از شبکه عصبی مصنوعی نیز مورد بررسی قرار گرفت. نتایج نشان داد که با استفاده از روش تاگوچی می‌توان شمار آزمایش‌ها را به ترتیب به میزان ۸۹ و ۸۷ درصد نسبت به بررسی محققان پیشین و روش فاکتوریل کامل کاهش داد. همچنین تحلیل حساسیت فراسنجه‌های مؤثر نشان داد که دبی جریان به عنوان مؤثرترین فراسنجه بر پایداری سنگ‌چین در پیرامون پایه پل است. در نهایت برای تعیین شرایط هیدرولیکی پایداری سنگ‌چین، اقدام به تنظیم فراسنجه‌های شبکه عصبی مصنوعی با استفاده از روش تاگوچی شد که نتایج به‌دست آمده نشان‌دهنده دقت بالای این روش در برآورد نتایج آزمایشات با ضریب همبستگی ۰/۹۷ بود. نتایج تحلیل حساسیت فراسنجه‌های ورودی شبکه عصبی نیز نشان داد که تابع انتقال بیشترین تأثیر را بر روی نتایج شبکه عصبی مصنوعی دارد.

کلیدواژگان: روش تاگوچی- شبکه عصبی مصنوعی- پایه پل- سنگ‌چین- آب‌شستگی.

۱- مقدمه

برشی در پیرامون و پائین‌دست پایه پل تحت زاویه با راستای جریان رخ می‌دهد.

تاکنون بررسی‌های زیادی در مورد پایداری سنگ‌چین در پیرامون پایه پل انجام شده است که دو مورد اخیر آن شامل Rashno et al. (2020) و Karimaei (2020) می‌باشند.

یکی از روش‌های طراحی آزمایش‌ها (DOE) که در سال‌های اخیر در مهندسی صنایع، نفت و شیمی، مکانیک، محیط زیست و به‌تازگی در مهندسی عمران استفاده شده روش تاگوچی است. در این روش با تعیین تابع هدف و سطح‌های تاثیر فراسنجه‌های اصلی، می‌توان آزمایش‌ها را طراحی، سپس اجرا و تحلیل نمود. بررسی‌های محدودی در زمینه

آب‌شستگی پایه پل‌ها یکی از مهم‌ترین پدیده‌هایی است که باعث تخریب پل‌ها می‌شود. به همین دلیل روش‌های مختلفی برای حفاظت از بستر در پیرامون پایه پل معرفی شده است (Karimaei and Zarrati., 2019). در این میان، استفاده از سنگ‌چین در پیرامون پایه پل به عنوان راهکاری برای افزایش مقاومت بستر است. فراسنجه‌های زیادی بر روی پایداری سنگ‌چین مؤثر هستند. بنا بر نظر Karimaei and Zarrati (2013) شکست لایه سنگ‌چین به دلیل نیروی برشی جریان در بالادست پایه پل مستقیم با راستای جریان و یا ناشی از ترکیب نیروهای مکش جریان و نیروی

باهم (توام) بازده تله‌اندازی و رسوب‌گیری کرده و ضمن مشخص کردن حالت بهینه، فراسنجه‌های موثر بر آن را معرفی کردند.

شبکه‌های عصبی مصنوعی به دلیل پیچیدگی مدل‌سازی فرآیند آب‌شستگی به عنوان شناخته‌شده‌ترین روش داده‌کاوی، برای برآورد عمق آب‌شستگی پایه پل‌ها مطرح می‌باشند (Kant, 2017). بررسی منابع‌های مختلف نشان می‌دهد که می‌توان از روش تاگوچی برای تنظیم فراسنجه‌های ورودی شبکه عصبی مصنوعی برای دستیابی به نتایج بهتر نیز استفاده نمود. همچنین با وجود استفاده از این موضوع در رشته‌های مختلف مهندسی، تاکنون از آن در ارزیابی پدیده‌های هیدرولیکی کمتر استفاده شده است. (Razavizadeh and Dargahian, 2018) برای دستیابی به بهترین ساختار شبکه عصبی مصنوعی ANN در پیش‌بینی بار رسوبی رودخانه نکا از روش بهینه‌سازی تاگوچی استفاده کردند. و توانستند دبی رسوب نکارود را با دقت بالا برآورد کنند.

(Beeravelli et al., 2018) در بهینه‌سازی کار و انتشار موتور دیزل تزریقی با استفاده از شبکه عصبی مصنوعی ANN از تاگوچی استفاده کردند. مقایسه نتایج با شبکه عصبی مصنوعی تنها نشان‌دهنده کارکرد بهتر پشتیبانی شبکه عصبی با تاگوچی بود.

در این پژوهش سعی شد افزون بر قابلیت تاگوچی در کاهش شمار آزمایش‌های بررسی اندازه پایدار سنگ‌چین در پیرامون پایه‌های پل (در بخش تجربی شمار آزمایش‌ها و در بخش شبکه عصبی شمار پاسخ‌ها)، از ویژگی بهینه‌سازی و پیش‌بینی تاگوچی با استفاده از تجزیه و تحلیل خروجی و نمودارهای آن در این زمینه استفاده شود (خاصیتی که کمتر مورد ارزیابی قرار گرفته است). در ادامه نیز برای صحت‌سنجی، نتایج به‌دست آمده از پیش‌بینی تاگوچی، با نتایج به‌دست آمده از شبکه عصبی مصنوعی مقایسه شده است.

۲- مواد و روش‌ها

۲-۱- روش تاگوچی در طراحی آزمایش‌ها

روش تاگوچی در طراحی آزمایش‌ها شامل تعیین بهترین

استفاده از این روش در مهندسی هیدرولیک موجود می‌باشد.

(Rostamabadi, 2017) در تعیین میزان بهینه ارتفاع و موقعیت بلوک‌های آرام‌کننده در شرایط هیدرولیکی مختلف به منظور کنترل آب‌شستگی پایین‌دست حوضچه آرامش از روش تاگوچی استفاده کرد. در این تحقیق، نتایج به‌دست آمده از تجزیه و تحلیل تاگوچی با میزان‌های آزمایشگاهی و نتایج روش اجرای طرح فاکتوریل کامل از جنبه‌های مختلف مقایسه شد و سطح‌های بهینه متغیرها مشخص شد. نتایج بیانگر این بود که استفاده از روش تاگوچی افزون بر کاهش شمار آزمایش‌ها، منجر به صرفه‌جویی در زمان کل انجام آزمایش‌ها شده است.

(Soukhtanlu et al., 2018) با استفاده از روش طراحی آزمایش‌ها به کمک تحلیل تاگوچی به بررسی آزمایشگاهی گذاره‌های دبی حجمی سیال، قطر جت و ارتفاع بازدارنده در پایین‌دست پرش بر شمار اضلاع پرش‌های هیدرولیکی چندضلعی پرداختند و با استفاده از روش تاگوچی میزان تأثیر هریک از فراسنجه‌های مؤثر را مشخص کردند. مقایسه نتایج رابطه‌های خطی و غیرخطی ارائه شده با نتایج آزمایش‌ها انجام گرفته در این تحقیق و نیز نتایج دیگر محققان نشان داد که رابطه‌های به‌دست آمده از تاگوچی دارای دقت شایان پذیرش می‌باشند.

(Atarodi et al., 2020) برای طراحی فراسنجه‌های هندسی آب‌شکن با هدف بهترین کار در کاهش آب‌شستگی، از روش‌های تاگوچی و GRA استفاده کردند. نتایج به‌دست آمده از پژوهش بیانگر کارکرد مناسب هر دو روش در بهینه‌سازی بود.

(Ranjbar-Zahedi et al., 2021) برای کاهش آب‌شستگی محلی در پیرامون پایه‌های پل و همچنین برای به کمترین رساندن شمار آزمایش‌ها، از ۲۷ آزمایش پیشنهادی تاگوچی برای تعیین اندازه و محل بهینه سازه استفاده کردند. بر مبنای تحقیق ارائه شده آن‌ها، ساختار انحراف جریان یک روش ساده و آسان برای کاهش آب‌شستگی در پل‌های جدید و موجود است.

(Dalir et al., 2021) با استفاده از روش تاگوچی و سطح پاسخ در یک مدل آزمایشگاهی حوضچه، اقدام به بررسی

است. بر این مبنا، میزان بزرگتر نسبت S/N برای یک فراسنجه همواره گویای اهمیت و تأثیر بیشتر آن بر نتایج خروجی است. از این رو می‌توان گفت هدف مورد نظر، پیدا کردن بالاترین نسبت سیگنال به نویز برای هر آزمایش می‌باشد (Yao and Chi., 2004). رابطه ۲ هنگامی که تابع هدف به صورت بیشینه (max) یا "هرچه بیشتر بهتر است"، استفاده می‌شود.

$$\frac{S}{N} = -10 \log\left(\frac{1}{n} \sum_{i=1}^m y_i^2\right) \quad (2)$$

که در آن n شمار آزمایش‌ها و y_i ، i امین شمار مشاهده شده و m شمار معینی است.

برای پیدا کردن اهمیت نسبی فراسنجه‌ها بر روی هر کدام از خروجی‌ها از یک روش آماری به نام آنوآ^۱ (تجزیه و تحلیل واریانس) استفاده می‌شود. در این تحلیل سهم هر عامل در میزان پراکندگی کل پاسخ‌ها از تقسیم میزان تغییرپذیری ناشی از آن عامل بر کل تغییرپذیری به دست می‌آید. که برای به دست آوردن آن، فراسنجه‌های درجه آزادی، مجموع مربعات کل، میانگین مجموع مربعات، نسبت واریانس و در نهایت درصد توزیع برابر رابطه‌های آماری به دست می‌آیند (Taguchi et al., 2005).

لازم به یادآوری است که تاگوچی در جدول آرایه‌های متعامد خود تنها بخشی از شمار کل حالت‌های آزمایش را ارائه می‌دهد، یعنی ممکن است حالت بهینه در بین آزمایش‌های انجام شده نباشد. زیرا آرایه متعامد شامل تنها کسری کوچک از تمامی حالت‌های ممکن است. در واقع ویژگی اصلی تاگوچی رفع این مسئله است. تاگوچی قادر است تنها با انجام آزمایش‌هایی محدود، حالت بهینه را در بین همه حالت‌های ممکن مشخص کند. برای به دست آوردن نتیجه آزمایش در شرایط بهینه، با به دست آمدن ترکیب بهینه در مرحله‌های پیش، از رابطه‌های ۳ و ۴ استفاده می‌شود (Rostamabadi et al, 2013).

$$\bar{F} = \frac{\sum(F_i)}{n} \quad (3)$$

$$F_{opt} = \bar{F} + \sum(F_{opt} x_i - \bar{F}) \quad (4)$$

که در آن F_{opt} میزان بهینه، \bar{F} میانگین کل پاسخ‌ها، F_i

ترکیب از ورودی‌ها برای تولید یک محصول یا پاسخ یک آزمایش است. از این روش برای ترکیب سطح‌ها یا حالت‌های مختلف فراسنجه‌ها استفاده می‌شود زیرا به جای استفاده از ترکیب‌های فاکتوریلی کامل، از ترکیب‌های فاکتوریلی جزئی استفاده کرده که در آن برای طراحی ترکیب‌های سطح متغیرها از جدول‌های خاصی با عنوان آرایه‌های متعامد (Orthogonal Array) استفاده می‌شود. آرایه متعامد یک ماتریس فاکتوریلی جزئی است که همه متغیرها یا اثرهای متقابل آن‌ها را به صورت موزون مقایسه می‌کند، (Roy., 1990). تاگوچی ۱۸ آرایه متعامد را در جدولی ارائه کرده که آرایه متعامد استاندارد نام دارد. استفاده از این جدول‌ها باعث آسانگری در طراحی آزمایش‌ها می‌شود. نتایج آزمایش‌ها در روش تاگوچی، برای رسیدن به هدف‌هایی همچون تعیین شرایط بهینه، تعیین تأثیر مجزای هر عامل و برآورد کارکرد در شرایط بهینه، تجزیه و تحلیل می‌شوند. تاگوچی برای تحلیل داده‌ها، از روش‌های استاندارد با استفاده از تحلیل میانگین و نسبت سیگنال به نویز یا آشفستگی‌ها (S/N) استفاده می‌کند (Zanjirchi et al., 2015).

در روش استاندارد یا روش انحراف از میانگین، بهینه‌سازی نتایج با استفاده از تحلیل میانگین و تنها به دست آمده از یک بار انجام آزمایش‌هاست. با استفاده از رابطه ۱ میزان‌های میانگین هر عامل در هر سطح محاسبه شده، سپس سطح بهینه هر عامل و ترکیب بهینه مورد نظر با استفاده از جدول‌ها و نمودارهای پاسخ به دست می‌آید، (Roy, 1990).

$$(M)_{Factor=m}^{Level=L} = \frac{1}{n_{Lm}} \sum_{j=1}^{n_{Lm}} [(f_x)_{Factor=m}^{Level=L}]_j \quad (1)$$

که در آن n_{Lm} شمار بارهای ظهور عامل m در سطح L و f_x داده‌های مشاهده‌ای آزمایشگاهی بر مبنای الگوی پیشنهادی تاگوچی است.

کاربرد دیگر تاگوچی، تحلیل نسبت سیگنال (تأثیر فراسنجه‌های قابل کنترل - Signal) به نویز (تأثیر عامل‌های آشفستگی - Noise) (S/N)، برای بررسی میزان تأثیر فراسنجه‌های مختلف ورودی در بهینه‌سازی خروجی‌ها

¹ Analysis Of Variance (ANOVA)

می‌شود. برای تنظیم وزن شبکه عصبی مصنوعی با الگوریتم پس انتشار، داده‌ها از لایه خروجی به لایه پنهان باز می‌گردند و دوباره پردازش می‌شوند، (Braddock et al., 1998). در شبکه عصبی مصنوعی، نرون‌ها داده‌های ورودی شبکه را با استفاده از تابع انتقال که بیشتر غیرخطی است پردازش می‌کنند. تابع انتقال اغلب از نوع محرکه خطی، لگاریتمی و تانژانتی است.

۲-۳- شاخص ارزیابی مدل‌ها

در این تحقیق از دو شاخص R و R^2 برای بررسی و ارزیابی دقت پیش‌بینی مدل‌ها استفاده شده است.

۲-۳-۱- ضریب همبستگی R

برای ارزیابی کارکرد مدل‌های شبکه عصبی در این پژوهش از ضریب همبستگی R (رابطه ۵) استفاده شده است. این ضریب رابطه بین دو متغیر را تعیین می‌کند و هر چه میزان آن به (+۱) نزدیک‌تر باشد بهتر است و نشان‌دهنده رابطه همبستگی قوی‌تر بین متغیرهای مورد بررسی است.

$$R = \frac{\sum_{i=1}^n (x_i^0 - \bar{x}^0)(x_i^p - \bar{x}^p)}{\sqrt{\sum_{i=1}^n (x_i^0 - \bar{x}^0)^2 \sum_{i=1}^n (x_i^p - \bar{x}^p)^2}} \quad (5)$$

که در آن، x_i^0 فراسنجه مشاهده شده، x_i^p فراسنجه پیش‌بینی شده و n شمار داده‌ها است.

۲-۳-۲- ضریب تعیین R^2

R^2 اندازه‌گیری آماری نزدیک داده‌ها به خط رگرسیون برازش شده می‌باشد که به آن ضریب تشخیص یا تعیین نیز گفته می‌شود و نشان‌دهنده این است که چه میزان از تغییرپذیری متغیر وابسته تحت تاثیر متغیر مستقل مربوطه بوده و مابقی تغییرپذیری متغیر وابسته مربوط به دیگر عامل می‌باشد.

این ضریب همیشه بین صفر و ۱۰۰٪ است و صفر درصد نشان می‌دهد که مدل هیچ یک از تغییرپذیری داده‌های پاسخ در پیرامون میانگین آن را تبیین نمی‌کند و ۱۰۰٪ نشان می‌دهد که مدل همه تغییرپذیری داده‌های پاسخ در

پاسخ مربوط به هر آزمایش، n شمار آزمایش‌ها و $F_{opt} x_i$ پاسخ مربوط به ترکیب‌های بهینه به‌دست آمده از مرحله‌های قبل است.

۲-۲- شبکه عصبی مصنوعی (ANN^1)

شبکه‌های عصبی مصنوعی یکی از مدل‌های پیش‌بینی بر پایه هوش مصنوعی است که به صورت ساختار شبکه‌های متشکل از عنصرهای مرتبط به هم به نام نرون می‌باشند. نرون‌ها کارکرد ساده‌ای دارند و هر کدام شامل یک خروجی و ورودی هستند. آن‌ها وظیفه دریافت اطلاعات از لایه ورودی و انتقال آن به لایه پنهان برای پردازش را به عهده دارند. داده‌های پردازش شده نیز در نهایت به لایه خروجی انتقال داده می‌شود. شبکه‌های عصبی مصنوعی را می‌توان به دو نوع تک لایه و چندلایه تقسیم نمود. شبکه‌های عصبی تک لایه که توانایی پیاده‌سازی تابع‌های غیر خطی را ندارند شامل چند نرون هستند که در یک لایه تشکیل شبکه داده‌اند. شبکه عصبی چندلایه نیز شامل لایه ورودی^۲، لایه پنهان^۳ و لایه خروجی^۴ است، (Kia, 2010). شبکه‌های پرسپترون چند لایه (MLP) که یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی هستند اغلب شامل سه لایه ورودی، پنهان و خروجی هستند که سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه لایه منتشر می‌شوند (Menhaj, 2018). در شبکه‌های عصبی، میزان‌های اولیه وزن‌ها اهمیت ویژه‌ای دارا بوده و پیش از آغاز آموزش، همه میزان‌های وزن‌ها به‌طور تصادفی و کوچک انتخاب می‌شوند، (Demuth and Beale., 1992). الگوریتم آموزش در میزان خطا و دقت آن در پیش‌بینی نقش دارد. از رایج‌ترین الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی الگوریتم انتشار خطا به عقب (BP) است. این الگوریتم اغلب در شبکه‌های عصبی مصنوعی مربوط به پدیده‌های هیدرولیکی به‌کار می‌روند. در این الگوریتم، به منظور به کمترین رساندن اختلاف بین داده‌های خروجی هدف و داده‌های خروجی واقعی (خطای آموزش)، وزن ارتباط درونی شبکه عصبی در طی فرایند آموزش تنظیم

³ Hidden layer

⁴ Output layer

¹ Artificial Neural Networks- ANN

² Input layer

به طراحی سنگ‌چین کاربرد زیادی دارد و به صورت رابطه ۶ تعریف می‌شود (Karimaei and Zarrati., 2013).

$$N_c = \frac{\rho \cdot V^2}{(\rho_s - \rho) \cdot g \cdot d_{50}} \quad (6)$$

که در آن V سرعت میانگین جریان، d_{50} اندازه میانگین دانه‌های بستر (دانه‌های سنگ‌چین)، ρ چگالی جریان و ρ_s چگالی دانه‌های رسوب می‌باشد. جذر این فراسنجه به صورت عدد فرود دانه‌ها معرفی شده که به عنوان یک فراسنجه مهم در پدیده آب‌شستگی در پیرامون پایه پل مطرح می‌باشد. در بسیاری از رابطه‌ها برآورد اندازه دانه‌های سنگ‌چین را می‌توان به صورت مقداری ثابت از این فراسنجه یا به صورت تابعی از یک فراسنجه دیگر مانند d_{50} / y نشان داد. با توجه به رابطه معکوس بین فراسنجه N_c و فراسنجه اندازه دانه‌های سنگ‌چین (d_{50})، هر چه میزان N_c در یک شرایط ثابت، کوچک‌تر به دست آید اندازه به دست آمده برای سنگ‌ها بزرگ‌تر خواهد بود. بیشتر رابطه‌های تجربی ارائه شده پیشین به علت در نظر نگرفتن فراسنجه‌های مختلف مؤثر بر پایداری سنگ‌چین، دقت مناسبی نداشته و اغلب دست بالا می‌باشند. بنابراین برای بررسی دقیق‌تر این پدیده نیاز به مدل‌سازی فیزیکی در آزمایشگاه می‌باشد.

(Karimaei and Zarrati. (2013) پس از انجام تحقیقات آزمایشگاهی، معادله‌ای تجربی γ را برای طراحی اندازه دانه‌های سنگ‌چین در پیرامون پایه‌های پل با مقطع دایره‌ای و یا مستطیلی با قرارگیری مستقیم و یا تحت زاویه نسبت به مسیر جریان ارائه کردند. این معادله عبارت از:

$$N_c = 2.85 \times K_y \times K_d \times K_b \quad (7)$$

که در آن N_c فراسنجه بی‌بعد پایداری سنگ‌چین و سایر فراسنجه‌ها شامل ضریب تصحیح عمق جریان $k_y = (d_{50} / y)^{0.25}$ ، ضریب تصحیح اندازه سنگ‌چین $k_d = \sqrt{d_{50} / y}$ و ضریب اصلاح زاویه برخورد جریان به پایه پل $k_b = (B / B_{eff})^{1.5}$ است که در آن B عرض پایه پل می‌باشد همچنین B_{eff} عرض مؤثر پایه پل بوده و به صورت رابطه ۸ تعریف می‌شود.

$$B_{eff} = B \times (1 - \sin\theta) + L \times \sin\theta \quad (8)$$

پیرامون میانگین آن را تبیین می‌کند. R^2 توان دوم ضریب همبستگی (R) است.

۲-۴- ترکیب تاگوچی و الگوریتم شبکه عصبی مصنوعی

برای بالا بردن کار و دقت شبکه عصبی مصنوعی لازم است طراحی مناسب ساختار شبکه یا بهینه‌سازی فراسنجه‌های شبکه عصبی مصنوعی (شمار لایه‌های مخفی، شمار نرون در لایه‌های پنهان، الگوریتم آموزش و نرخ یادگیری، تابع انتقال و تابع آموزش و غیره)، صورت گیرد. یکی از رایج‌ترین روش‌های تعیین این ساختار روش آزمون و خطا است. لزوم استفاده از جایگزین این روش با توجه به زمان‌بر بودن و نبود زمینه تضمین یافتن ساختار مناسب، به چشم می‌خورد.

روش طراحی آزمایش‌های تاگوچی را می‌توان در یافتن بهترین ساختار شبکه عصبی و در نتیجه یافتن بهترین پاسخ با کمترین خطا، استفاده کرد. در این روش فراسنجه معنی‌داری برای هر عامل و درصد تأثیر عوامل در پاسخ ارائه می‌شود (Razavizadeh et al., و Zanjirchi et al., 2015). بر این مبنای، در مرحله اول با استفاده از جدول آرایه‌های متعامد، ترکیب‌های پیشنهادی خود برای تنظیم فراسنجه‌های شبکه عصبی برای کاهش شمار اجراها و در نتیجه صرفه‌جویی در زمان ارائه می‌شود، سپس با استفاده از نمودارهای تحلیلی (تحلیل میانگین و تحلیل S/N)، بهترین شبکه عصبی مصنوعی به دست می‌آید. در نهایت با استفاده از این نمودارهای تحلیل، تأثیر هر یک از فراسنجه‌های شبکه عصبی بر خروجی مشخص می‌شود.

۲-۵- طراحی اندازه پایدار سنگ‌چین پیرامون پایه‌های پل برای حفاظت از آب‌شستگی

بیشترین بررسی و ارزیابی‌هایی که در مورد سنگ‌چین پیرامون پایه پل انجام گرفته، به منظور ارائه رابطه‌های تجربی برای محاسبه اندازه لازم برای دانه‌های سنگ‌چین می‌باشد. بعضی از رابطه‌ها شبیه به هم هستند و تنها در ضریب‌های آن‌ها اختلاف جزئی وجود دارد. فراسنجه N_c عدد پایداری سنگ‌چین نام دارد که در بررسی‌های مربوط

پل (L/B) و زاویه قرارگیری پایه نسبت به راستای جریان (θ) به عنوان فراسنجه اصلی گزینش شد. همچنین فراسنجه وابسته در این آزمایش‌ها عمق جریان (Y) در لحظه شکست سنگ چین است. از آن جایی که فراسنجه عرض پایه پل (B) میزان ثابتی دارد، می‌توان به جای فراسنجه (L/B) تنها از فراسنجه (L) استفاده کرد. بنا بر نتایج داده‌های آزمایشگاهی (Karimaei and Zarrati, 2013) می‌توان برای فراسنجه Q ، شش سطح و برای هر یک از فراسنجه‌های d_{50} ، L و θ ، سه سطح در نظر گرفت. این فراسنجه‌ها و سطح‌های مربوط به آن‌ها در جدول ۱ نشان داده شده است.

در این معادله L طول پایه پل مستطیلی و θ زاویه برخورد جریان به پایه پل می‌باشند. در شرایطی که پایه دایره‌ای باشد، $B_{eff} = B$ است.

۳- نتایج و بحث

۳-۱-گردآوری داده‌های آزمایشگاهی

در بررسی (Karimaei and Zarrati, 2013) از ۱۴۵ داده آزمایشگاهی تحقیق استفاده شد. با توجه به این داده‌ها، چهار فراسنجه مستقل شامل دبی جریان (Q)، اندازه سنگ (d_{50})، نسبت طول (بعد در راستای جریان) به عرض پایه

جدول ۱ فراسنجه‌های اصلی و سطح‌های مربوط به آن‌ها

Table 1 Main parameters and its related levels

Parameter	Number of Levels	Level 1	Level 2	Level 3	Level 4	Level 5	Level 6
Q (m ³ /s)	6	0.01	0.02	0.03	0.035	0.05	0.06
d_{50} (m)	3	0.00205	0.00385	0.007	-	-	-
L (m)	3	15	25	35	-	-	-
θ (degree)	3	0	10	20	-	-	-

نسبت به شمار آزمایش‌های پژوهشگران و ۸۹ درصدی نسبت به روش فاکتوریل کامل، در کاهش شمار آزمایش‌ها و صرفه‌جویی در زمان و هزینه موفق بوده است.

جدول ۲ کاهش شمار آزمایش‌ها با استفاده از روش تاگوچی
Table 2 Reduction of the number of experiments by the Taguchi method

	Karimaei and Zarrati (2013)	Full factorial	Taguchi method
Number of experiments	145	162	18
Percentage reduction of experiments compared to the results of researchers			87%
Percentage reduction of experiments compared to full factorial method			89%

۳-۳-ارزیابی روش تاگوچی در تعیین اندازه پایدار سنگ چین

پس از کاهش شمار آزمایش‌ها، پاسخ ترکیب‌های پیشنهادی تاگوچی برای تحلیل نتایج، وارد نرم‌افزار Minitab شد. سپس برابر با هدف مسئله که افزایش عمق جریان (Y) برای پایداری سنگ چین (کمتر شدن فراسنجه

۳-۲- کاهش شمار آزمایش‌ها

با توجه به شمار سطح‌های برگزیده برای هر فراسنجه (جدول ۱)، در صورت استفاده از روش فاکتوریل کامل نیاز به انجام صد و شصت و دو ($6 \times 3 \times 3 \times 3 = 162$) آزمایش خواهد بود. در حالی که با استفاده از روش تاگوچی این میزان کاهش می‌یابد. با توجه به اصول روش تاگوچی، میانگین کل دارای یک درجه آزادی و همچنین فراسنجه‌های سه سطحی (θ ، L ، d_{50})، دارای دو ($3 - 1 = 2$) درجه آزادی و فراسنجه شش سطحی (Q) دارای پنج ($6 - 1 = 5$) درجه آزادی است. در نتیجه شمار درجه‌های آزادی کل برابر با دوازده ($1 + 1 \times 5 + 3 \times 2 = 12$) است که با توجه به جدول استاندارد تاگوچی آرایه‌های L_{16} ، L_{18} و L_{25} مناسب هستند. برای دستیابی به نتیجه بهتر آرایه L_{18} گزینش می‌شود. یعنی به جای ۱۶۲ آزمایش، ۱۸ ترکیب مختلف فراسنجه‌ها بررسی می‌شود. جدول ۲ نشان‌دهنده کاهش شمار آزمایش‌ها نسبت به روش فاکتوریلی کامل و آزمایش‌های (Karimaei and Zarrati, 2013) است. این جدول نشان می‌دهد که استفاد از روش تاگوچی با کاهش ۸۷ درصدی

فراسنجه‌های طول و زاویه قرارگیری پایه نسبت به راستای جریان نیز صادق است. یعنی هرچه طول پایه پل و زاویه آن نسبت به راستای جریان بیشتر باشد، عمق جریان شکست سنگ‌چین افزایش می‌یابد. در حالی‌که برای فراسنجه اندازه سنگ با افزایش اندازه سنگ این میزان کاهش می‌یابد. در شکل ۱ (b)، با تکیه بر بالابودن نسبت S/N ترکیب بهینه در سطح آخر فراسنجه‌های اول و سوم و چهارم و در سطح اول فراسنجه دوم رخ داده است. تحلیل این نمودار نیز به کلی سازگار با نمودار میانگین میانگین‌هاست. نتایج ترکیب بهینه خروجی هر تحلیل در جدول ۳ ارائه شده است.

در نظر گرفته شد، از نمودارهای میانگین میانگین‌ها و نسبت سیگنال به نویز (S/N) برای ارزیابی نتایج استفاده می‌شود. شکل ۱ (a,b)، نتایج خروجی نرم‌افزار Minitab برای انجام این ارزیابی را نشان می‌دهد. در این شکل واحد فراسنجه‌های محور افقی در جدول (۱) ارائه شده است. با توجه به شکل ۱ (a) نتایج نشان می‌دهد که فراسنجه اول (Q) در سطح ششم و فراسنجه دوم (d_{50}) در سطح اول و فراسنجه‌های سوم (L) و چهارم (θ) در سطح سوم، بیشینه عمق جریان را برآورده می‌کنند. به عبارت دیگر نمودار نشان می‌دهد که هر چه دبی بالاتر باشد عمق جریان برای پایداری سنگ‌چین بیشتر خواهد بود. این مسئله در مورد

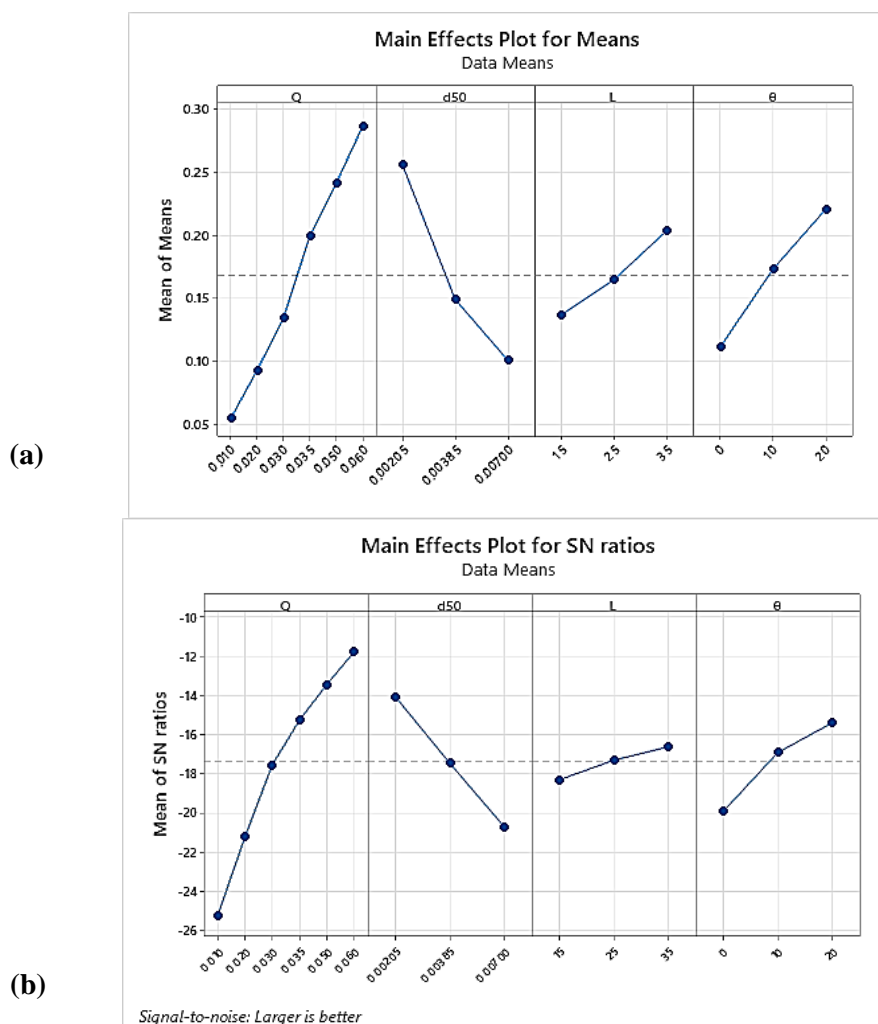


Fig.1 Taguchi's output in Minitab: (a) the mean of means and (b) S/N ratios
 شکل ۱ خروجی روش تاگوچی در نرم‌افزار Minitab: (a) میانگین میانگین‌ها و (b) نسبت S/N

جدول ۳ ترکیب بهینه پیشنهادی تاگوچی

Table 3 The optimal combination proposed by Taguchi

Method	Levels of Parameters				Response
	Q (m ³ /s)	d ₅₀ (m)	L (m)	θ (degree)	Y (m)
By Means & S/N	0.006	0.00205	35	20	0.462

جریان (پاسخ) برای این ترکیب بهینه نیز در جدول ۳ ارائه شده است.

درصد سهم هر فراسنجه با استفاده از جدول ANOVA در جدول ۴ بیان شده است. با توجه به این جدول فراسنجه دبی (Q) با ۶۴/۷۱٪ بیشترین تأثیر و فراسنجه طول پایه پل (L) با ۱/۳۷٪ کمترین تأثیر را دارد.

با توجه به جدول ۳ ترکیب بهینه تاگوچی بر مبنای تجزیه و تحلیل نمودار میانگین پاسخها و S/N برای هر چهار فراسنجه مؤثر یکسان است. به عبارت دیگر بیشترین عمق جریان (کمترین میزان فراسنجه NC) در شرایطی به دست آمده که دبی جریان ۰/۰۶ مترمکعب بر ثانیه، اندازه سنگ ۰/۰۲۰۵ متر، طول پایه پل ۳۵ متر، زاویه پایه پل نسبت به جریان ۲۰ درجه باشد. میزان بیشینه عمق شکست

جدول ۴ نتایج به دست آمده از جدول آنوا و سهم هر فراسنجه

Table 4 The results of the ANOVA table and the participation of each parameter

Parameter	Degree freedom (DF)	Squares sum (SS)	Mean Squares sum (MS)	Variance (V)	Percentage of participation (P)
Q (m ³ /s)	5	383.889	76.778	279.97	64.71%
d ₅₀ (m)	2	133.103	66.552	242.68	22.42%
L (m)	2	8.64	4.320	15/75	1.37%
θ (degree)	2	63.844	31.922	116.4	10.71%

بنا بر جدول آرایه‌های متعامد ارائه شده تاگوچی، ۹ ترکیب شبکه عصبی (به جای استفاده از ۸۱ ترکیب متفاوت از مدل‌های شبکه عصبی) با ساختار پیشنهادی تاگوچی در نرم‌افزار متلب ایجاد شد.

جدول ۵ سطح‌های مربوط به فراسنجه‌های مؤثر شبکه عصبی

Table 5 Levels of important parameters for ANN

Parameter	Number of Levels	Level 1	Level 2	Level 3
Number of neurons in first layer	3	7	8	9
Number of neurons in second layer	3	7	8	9
Training function	3	trainlm	trainoss	trainr
Transfer function	3	lagesig	purelin	tansig

۳-۴- کاربرد روش تاگوچی در طراحی بهینه شبکه عصبی برای پیش‌بینی طراحی اندازه پایدار سنگ‌چین

در این پژوهش از شبکه عصبی پرسپترون چند لایه و الگوریتم پیش‌خور پس‌انتشار خطا (FFBP-NN) استفاده شده است. از مجموع داده‌های آزمایشگاهی Karraei and Zarrati (2013) ۸۰٪ برای آموزش و ۲۰٪ برای آزمایش شبکه در نظر گرفته شد. ورودی‌های شبکه عصبی مصنوعی فراسنجه‌های اثرگذار شامل Q، d₅₀، L و θ و خروجی Y است. سه لایه پنهان برای ایجاد این شبکه عصبی انتخاب شده و مولفه‌های قابل تنظیم شبکه عصبی شامل چهار مولفه شمار نرون‌ها در لایه‌های پنهان اول و دوم، تابع آموزش و تابع انتقال در هر لایه است که در جدول ۵ نشان داده شده است. در جدول ۵ فراسنجه‌های اصلی و سطح‌های مربوط به هر فراسنجه نشان داده شده است. شکل ۲ نیز شبکه عصبی مصنوعی ساخته شده با ویژگی‌های بالا را نشان می‌دهد.

برای ارزیابی دقیق تر و دستیابی به اطمینان هر شبکه ایجاد شده، از نتایج ۵ بار اجرا (run) برای هر شبکه استفاده شده و میزان های نتایج ضریب همبستگی (R) به دست آمده است. به جای میانگین گرفتن از R ها برای تحلیل نتایج، از تحلیل نسبت S/N تاگوچی در نرم افزار Minitab استفاده شده است. ویژگی های شبکه های عصبی ایجاد شده و نتایج ضریب همبستگی شبکه عصبی (R) به دست آمده از اجراهای شبکه عصبی برای ۵ بار تکرار در جدول ۶ ارائه شده است. همان طور که مشاهده می شود میزان های S/N به دست آمده در ردیف هشت از جدول ۶، بیشترین میزان در بین نه شبکه عصبی ساخته شده را دارا می باشد.

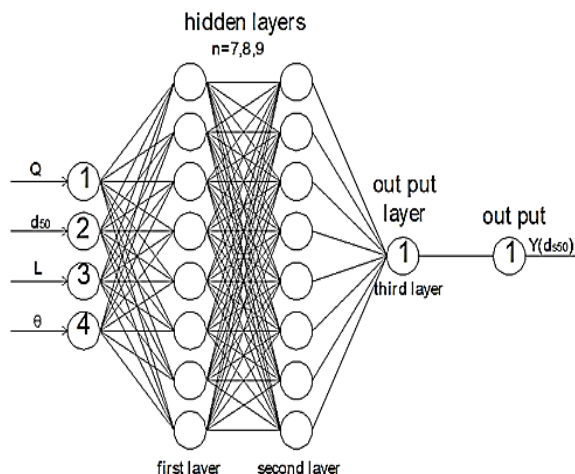


Fig. 2 The structure of ANN in estimating the RipRap
 شکل ۲ ساختار شبکه عصبی مصنوعی در محاسبه پدیده شکست سنگ چین

جدول ۶ نتایج تحلیل مربوط به ۵ تکرار شبکه عصبی مصنوعی

Table 6 Analysis results for five replications in ANN

Number of study	Number of neurons in layer1	Number of neurons in layer2	Training function	Transfer function	R in different iterations					S/N ratio
					Iteration 1	Iteration 2	Iteration 3	Iteration 4	Iteration 5	
1	7	7	trainlm	Logesig	0.740	0.742	0.740	0.742	0.742	-2.606
2	7	8	Trainoss	Purelin	0.862	0.862	0.863	0.862	0.863	-1.283
3	7	9	Trainr	Tansig	0.945	0.945	0.945	0.945	0.945	-0.491
4	8	7	Trainoss	Tansig	0.934	0.934	0.947	0.947	0.947	-0.357
5	8	8	Trainr	Logesig	0.606	0.606	0.665	0.743	0.743	-3.553
6	8	9	Trainlm	Purelin	0.861	0.861	0.861	0.861	0.861	-1.299
7	9	7	trainr	Purelin	0.850	0.850	0.850	0.850	0.850	-1.411
8	9	8	Trainlm	Tansig	0.964	0.964	0.964	0.964	0.964	-0.318
9	9	9	trainoss	logesig	0.724	0.724	0.719	0.721	0.721	-2.831

purelin است و تابع های آموزش trainlm و trainlrp به ترتیب بهترین و بدترین نوع تابع آموزش است. همچنین نتایج مربوط نشان داد که شمار نرون ها در لایه های پنهان اول و دوم در سطح اول و سوم بسیار شبیه به هم عمل می کنند. به عبارت دیگر نمودار نشان می دهد که بهترین شبکه عصبی ما هنگامی به دست می آید که شمار نرون ها در لایه های پنهان اول ۷ و در لایه پنهان دوم ۷، تابع آموزش trainlm و تابع انتقال هر لایه از نوع tansig باشد. به این ترتیب بهترین شبکه عصبی پیشنهادی تاگوچی در آغاز ایجاد و آن گاه آموزش داده شد تا برای تحلیل نتایج آن بررسی و ارزیابی شود. نمودارهای شکل ۴ نیز نمودار رگرسیون داده های بهترین شبکه عصبی مصنوعی ایجاد شده با ترکیب پیشنهادی تاگوچی را با مشخص کردن ضریب همبستگی برای داده های آزمایش، اعتبارسنجی و

از سویی همان طور که پیشتر اشاره شد ممکن است حالت بهینه در بین ترکیب های ارائه شده تاگوچی نباشد. زیرا این نه (۹) آرایه ی متعامد پیشنهادی تنها بخشی از شمار کل شبکه عصبی های قابل ساخته شدن است. بنابراین از نتایج به دست آمده از تحلیل S/N تاگوچی برای بررسی و ارزیابی دقیق تر استفاده می شود. شکل نمودار ۳ نتایج خروجی نرم افزار Minitab برای دستیابی به این نتایج را نشان می دهد.

با توجه به نمودار شکل ۳ فراسنجه های اول و دوم و سوم در سطح اول و فراسنجه چهارم در سطح سوم، هدف مسئله یعنی بهترین شبکه عصبی مصنوعی ایجاد شده برای بیشترین اندازه پایدار سنگ چین در پیرامون پایه پل را برآورده می کنند. با توجه به نمودار بالا می توان گفت تابع انتقال tansig بسیار مناسب تر از تابع های انتقال logesig و

در شاخص S/N از همین نسبت در همه‌ی ۹ مدل شبکه عصبی بیشتر است و این مورد نتایج به دست آمده از تاگوچی را تأیید می‌کند. در جدول ۸ نیز درصد سهم هر فراسنجه در تحلیل تاگوچی ارائه شده است. با توجه به ستون درصد مشارکت در جدول ۸، فراسنجه تابع انتقال بیشترین تأثیر (۰/۹۵/۱) و فراسنجه شمار نرون در لایه پنهان دوم با ۰/۰۷/۱ کمترین تأثیر را بر روی کار شبکه عصبی را داراست. به دلیل تأثیر بالای تابع انتقال، تصمیم‌گیرنده باید در گزینش این فراسنجه با دقت بیشتری عمل کند.

آموزش و نتیجه کلی نشان می‌دهند. ضریب همبستگی $R=0/971$ نیز مناسب بودن شبکه عصبی ایجاد شده را تأیید می‌کند. نتایج ترکیب بهینه شبکه عصبی و خروجی آن برای ۵ بار تکرار در جدول ۷ آمده است. با توجه به جدول ۷ ترکیب بهینه تاگوچی بر مبنای تجزیه نمودار S/N برای بهترین شبکه عصبی مصنوعی با سه لایه، زمانی روی خواهد داد که ۷ نرون در لایه پنهان اول و ۷ نرون در لایه پنهان دوم و تابع آموزش از جنس tranlm و تابع انتقال هر لایه از نوع tansig باشد. برابر جدول ۷ نسبت S/N در حالت بهینه

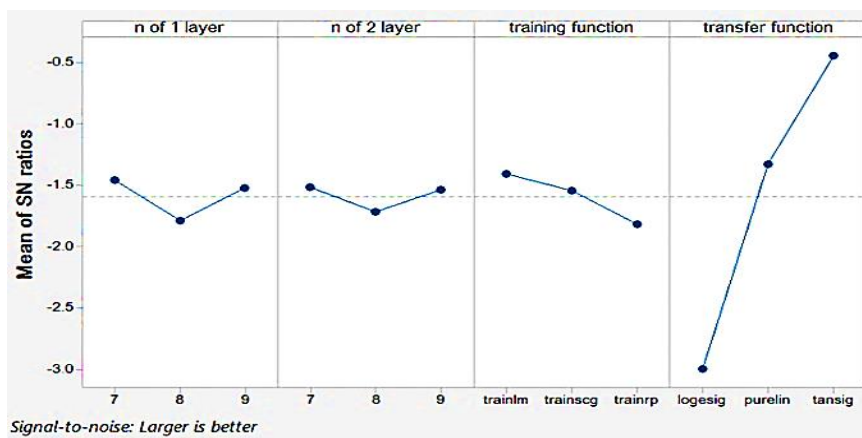


Fig. 3 Taguchi's output in Minitab for the mean S/N in ANN

شکل ۳ خروجی تاگوچی در نرم‌افزار Minitab برای نمودار S/N شبکه عصبی

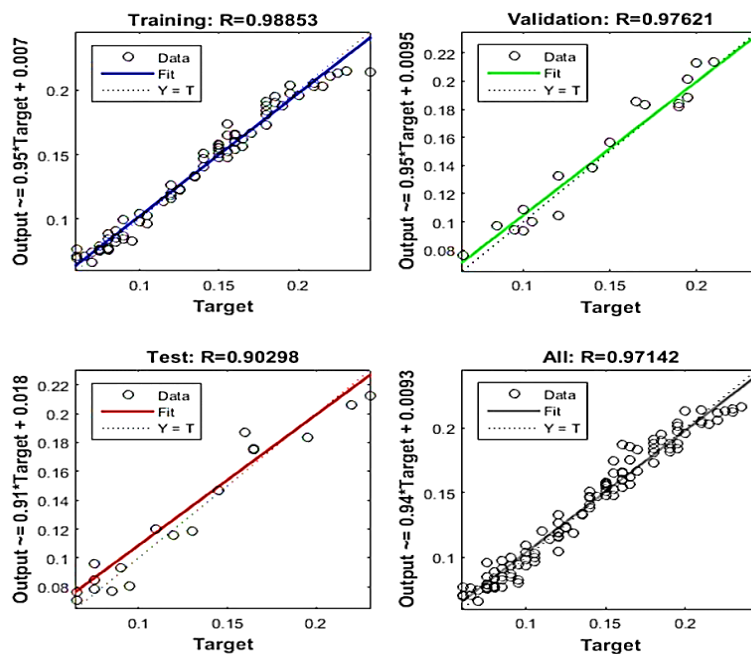


Fig. 4 Regression diagram of the best ANN data by Taguchi

شکل ۴ نمودار رگرسیون داده‌های بهترین شبکه عصبی مصنوعی ساخته شده با کمک تاگوچی

جدول ۷ ترکیب بهینه پیشنهادی تاگوچی برای بهترین شبکه عصبی مصنوعی

Table 7 Taguchi's optimal combination for the best ANN

By S/N	Number of neurons in		Training function	Transfer function	R in different iterations					S/N
	layer1	layer 2			Iteration	Iteration	Iteration	Iteration	Iteration	
					1	2	3	4	5	
	7	7	trainlm	tansig	0.971	0.971	0.970	0.970	0.971	-0.053

جدول ۸ سهم هر عامل برای بهترین شبکه عصبی مصنوعی

Table 8 Participation of each factor in the best ANN

Factors	Degree freedom (DF)	Squares sum (SS)	Mean Squares sum (MS)	Percentage of participation (P)
Number of neurons in layer1	2	0.186	0.093	1.76%
Number of neurons in layer2	2	0.074	0.037	0.70%
Training function	2	0.262	0.131	2.47%
Transfer function	2	10.079	5.039	95.07%

به دست آید. همان گونه که در شکل ۶ مشاهده می شود؛ شبکه عصبی مصنوعی بهینه با ضریب تعیین $R^2=0.95$ در پیش بینی نتایج نسبت به روش تاگوچی با نسبت $R^2=0.8$ کارکرد بهتری داشته است. همچنین پراکندگی پاسخ های روش تاگوچی نسبت به روش ANN در شکل نمودار ۵ نیز قابل رویت است. جدول ۹ نیز به مقایسه ترکیب بهینه و پاسخ بهینه دو روش تاگوچی و ANN می پردازد.

۳-۵- ارزیابی دقت نتایج به دست آمده از شبکه

عصبی مصنوعی بهینه و روش تاگوچی تنها

برای صحت سنجی نتایج تاگوچی تنها و ترکیب تاگوچی و شبکه عصبی، بیست ترکیب متفاوت از فراسنجه های مؤثر گزینش شد تا پاسخ هدف یکبار با استفاده از ویژگی پیش بینی تاگوچی و یکبار با استفاده از بهترین شبکه عصبی مصنوعی (به کمک ترکیب تاگوچی و شبکه عصبی)

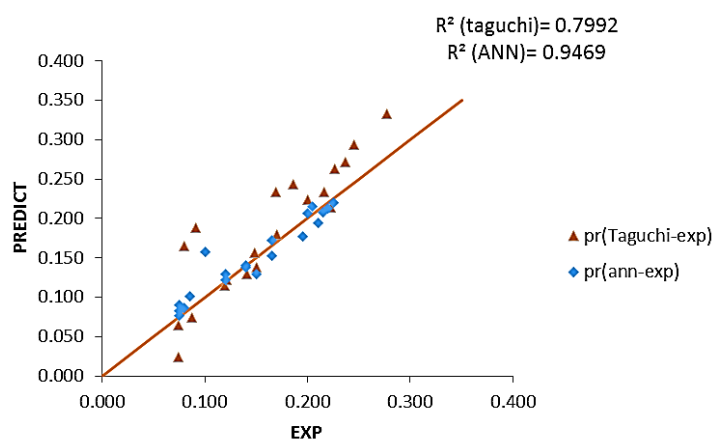


Fig. 5 Evaluation diagram of the validation results using Taguchi and ANN

شکل ۵ نمودار ارزیابی نتایج صحت سنجی روش تاگوچی و شبکه عصبی مصنوعی

جدول ۹ مقایسه ترکیب بهینه و پاسخ های تاگوچی و شبکه عصبی مصنوعی.

Table 9 Comparison of the optimal combination and responses of TM and ANN

Optimization Algorithm	Type of analysis	Levels of parameters				Y (m)
		Q (m ³ /s)	d ₅₀ (m)	L (m)	Θ (degree)	
TAGUCHI	mean of means	0.06	0.00205	35	20	0.586
ANN	mean of S/N	0.05	0.007	25	20	0.216

۴- نتیجه گیری

روش تاگوچی به عنوان یکی از روش‌های طراحی آزمایش‌ها با تکیه بر کاهش شمار آزمایش‌ها و پیشنهاد ترکیب‌های متفاوت اما محدود برای انجام بررسی‌ها به کار برده شد. همچنین تحلیل نتایج نیز با استفاده از نمودار میانگین میانگین‌ها و نسبت سیگنال به نویز (S/N) ارزیابی شد و بهترین ترکیب فراسنجه‌ها معرفی شده است. همچنین با استفاده از جدول آنوا تأثیر سطح‌های هر فراسنجه و در نهایت مؤثرترین فراسنجه نیز مشخص شده است. برای ارزیابی نتایج هم با استفاده از ویژگی پیش‌بینی، نتایج به دست آمده از روش تاگوچی با نتایج به دست آمده از شبکه عصبی مصنوعی ANN ارزیابی شده است. لازم به یادآوری است از روش تاگوچی برای تنظیم فراسنجه‌های قابل تنظیم شبکه عصبی مانند شمار لایه‌های پنهان، شمار نرون‌ها در لایه‌های پنهان، تابع آموزش و تابع انتقال، برای یافتن بهترین شبکه عصبی مصنوعی برای پدیده شکست سنگ‌چین نیز استفاده شده است.

در طراحی اندازه پایدار سنگ‌چین پیرامون پایه‌های پل برای حفاظت از آبشستگی روش تاگوچی با کاهش ۸۷ و ۸۹ درصدی به ترتیب نسبت به نتایج Karimaei and Zarrati (2013) و روش فاکتوریلی کامل، در کاهش شمار آزمایش‌ها و صرفه‌جویی در زمان و هزینه موفق بوده است. در تحلیل نتایج با استفاده از تاگوچی مشخص شد بیشترین عمق جریان برای پایداری سنگ‌چین هنگامی روی خواهد داد که Q برابر با ۰/۰۶ مترمکعب بر ثانیه، d_{50} برابر با ۰/۰۲۰۵ متر، L برابر با ۳۵ متر و θ برابر با ۲۰ درجه باشد و در این زمینه مؤثرترین فراسنجه Q معرفی شد. همچنین بهترین شبکه عصبی مصنوعی ANN مبتنی بر ترکیب بهینه معرفی شده تاگوچی بر مبنای تحلیل نمودار S/N، با سه لایه و ضریب همبستگی برابر با ۰/۹۷۱، هنگامی روی خواهد داد که لایه پنهان اول و دوم هر کدام شامل ۷ نرون، تابع آموزش از جنس tranlm و تابع انتقال هر لایه از نوع tansig باشد. همچنین بر مبنای تحلیل ANOVA، مؤثرترین عامل با میزان بالای ۹۵/۰۷٪ مشارکت، تابع انتقال است و در انتها، شبکه عصبی ایجاد شده با کمک تاگوچی با ضریب تعیین ۰/۹۴ نسبت به روش تاگوچی با

ضریب تعیین ۰/۷۹ در پیش‌بینی نتایج مربوط به طراحی اندازه پایدار سنگ‌چین پیرامون پایه‌های پل برای حفاظت از آبشستگی بهتر عمل کرد.

۵- فهرست نشانه‌ها

n_{Lm}	شمار بارهای ظهور عامل m در سطح L
f_x	داده‌های مشاهده‌ای آزمایشگاهی بر مبنای تاگوچی
n	شمار آزمایش‌ها، شمار داده‌ها
F_i	i امین پاسخ مشاهده شده
F_{opt}	میزان یا پاسخ بهینه
\bar{F}	میانگین کل پاسخ‌ها
$F_{opt_{xi}}$	پاسخ ترکیب‌های بهینه به دست آمده از مرحله‌های پیش
R	ضریب همبستگی شبکه عصبی
R^2	ضریب تشخیص
x_i^0	فراسنجه مشاهده شده
x_i^p	فراسنجه پیش‌بینی شده
N_c	عدد پایداری سنگ‌چین
V	سرعت میانگین جریان (ms^{-1})
d_{50}	اندازه میانگین دانه‌های بستر (m)
k_d	ضریب تصحیح عمق جریان
k_b	ضریب اصلاح زاویه برخورد جریان به پایه پل
Y	عمق شکست جریان (m)
B	عرض پایه پل (m)
B_{eff}	عرض مؤثر پایه پل (m)
L	طول پایه پل (m)
Q	دبی جریان (m^3s^{-1})

نشانه‌های یونانی:

ρ	چگالی جریان (kgm^{-3})
ρ_s	چگالی دانه‌های رسوب (kgm^{-3})
θ	زاویه برخورد جریان به پایه پل (degree)

۶- منبع‌ها

Atarodi, A., Karami, H., Ardeshir, A. and Hosseini, Kh. (2020). Optimization of the Geometric Parameters of the Protective Spur Dike using

- Journal of Hydraulic Research. 59(6), 963-976. <https://doi.org/10.1080/00221686.2020.1862321>.
- Rashno, E., Zarrati A.R. and Karimaei Tabarestani, M. (2020). Design of riprap for bridge pier groups. Canadian Journal of Civil Engineering, 47, 516-522.
- Razavizadeh, S. and Dargahian, F. (2018). Optimization of Artificial Neural Network Structure in Prediction of Sediment Discharge Using Taguchi Method. Iran-Watershed Management Science & Engineering. 43(12), 89-97. (In Persian)
- Rezazadeh, R., Barani, G.A. and Naseri, A. (2019). Application of artificial neural networks in estimation of scour depth around the bridge pier with sticky sediments. (Research Note). Journal of Hydraulics. 14(1), 141-149. (In Persian)
- Rostamabadi, M., Salehi Neyshabouri, A.A and Zarrati, A.R. (2013). Optimization of Geometric Parameters of Submerged Vane in Straight Alluvial Channel with Taguchi Method and GRA. Modares Civil Eng. Journal. 13, 79-93. (In Persian)
- Rostamabadi, M. (2017). Determining the optimal value of height and position of calming blocks using studies designed by Taguchi and complete factorial methods. Journal of Hydraulics. 12(2), 35-44. (In Persian)
- Roy, R. (1990). A primer on the Taguchi method. Society of Manufacturing Engineers, New York.
- Soukhtanlou, E., Teymourtash, A.R and Mahpeykar, M.R. (2018). Proposal of experimental relations for determining the number of sides of polygonal hydraulic jumps. Modares Mechanical Engineering. 18(1), 273-280. (In Persian)
- Taguchi, G., Chowdhury, S. and Wu, Y. (2005). Taguchi's quality engineering handbook. Wiley.
- Yao, A.W. and Chi, S.C. (2004). Analysis and design of a Taguchi-Grey based electricity demand predictor for energy management systems. Energy Conversion and Management, 45(7-8), 1205-17.
- Zanjirchi, S.M., Hatami, M.M., Kadkhodazadeh, H.R and Banifateme, S.A.M. (2015). Improving the efficiency of forecasting productivity, using a Taguchi experiment design approach (case study: food industries in Iran). Productivity Management (Beyond Management). 8(32), 69-87. (In Persian)
- Taguchi Method and GRA. Journal of Water and Soil Science. 1(24), 13-26. (In Persian)
- Beeravelli, V.N., Chanamala, R., Rayavarapu, U.M. R. and Kancherla, P.R. (2018). An Artificial Neural Network and Taguchi Integrated Approach to the Optimization of Performance and Emissions of Direct Injection Diesel Engine. European Journal of Sustainable Development Research, 2(2), 16. <https://doi.org/10.20897/ejosdr/85412>.
- Braddock, R.D., Kremmer, M.L. and Sanzogni, L. (1998). Feed-forward artificial neural network model for forecasting rainfall run-off. Environmetrics: The official journal of the International Environmetrics Society, 9(4), 419-32.
- Dalir, M., Ziaei, A. and Sheikh Rezazadeh Nikou, N. (2021). Investigation of Trapping, Sedimentation and Volumetric Fraction Efficiency of Vortex Settling Basin Using Taguchi Method. Iranian Journal of Soil and Water Research. 52(5), 1337-1350. (In Persian)
- Demuth, H. and Beale, M. (1992). Neural Network Toolbox: User's Guide: for Use with Matlab. MathWorks Incorporated.
- Kant, S. (2017). Application of Taguchi OA array and Artificial Neural Network for Optimizing and Modeling of Drilling Cutting Factors. International Journal of Theoretical and Applied Mechanics, 12(1), 1-2.
- Karimaei Tabarestani, M. and Zarrati, A.R. (2013). Design of stable riprap around aligned and skewed rectangular bridge piers. Journal of Hydraulic Engineering, 139(8), 911-6.
- Karimaei Tabarestani, M. and Zarrati, A.R. (2019). December. Local scour depth at a bridge pier protected by a collar in steady and unsteady flow. Water Management, 172(6), 301-311.
- Karimaei Tabarestani, M. (2020). Effect of correlation between hydraulic parameters on reliability analysis of designed riprap around bridge pier, Journal of Water and Soil Science, 14 (4), 51-68. (In Persian)
- Kia, M. (2010). Neural Network in Matlab. Kian Rayane Sabz Publications. (In Persian)
- Menhaj, M.B. (2018). Fundamentals of Neural Networks. Volume 1: Computational Intelligence. Amirkabir University of Technology. (In Persian)
- Ranjbar-Zahedani, M., Keshavarzi, A., Khabbaz, H., Ball, J.E. (2021). Optimizing flow diversion structure as an effective pier-scour countermeasure.