

Reliability-based design optimization of double layer barrel vault using pattern search algorithm and optimized neural network as an surrogate model

Reza Javanmardi¹, Behrouz Ahmadi-Nedushan^{2*}

1- Ph.D. Candidate, Department of Civil Engineering, Yazd University, Yazd, Iran

2- Associate Professor, Department of Civil Engineering, Yazd University, Yazd, Iran

ABSTRACT

In this research, a method based on the optimal neural network and pattern search optimization algorithm is presented to solve reliability-based design optimization problems. The main idea is to find a surrogate model that does not suffer from the phenomenon of overfitting and therefore has a good generalization accuracy. In the first stage, using the program written using the SM toolbox, a data set of inputs and outputs of the problem is created by running Sap2000. Then an optimization problem is solved to obtain the best performance of the neural network. The design variables in the neural network training stage, are the number of layers, the number of neurons in each layer and the type of transfer. The objective function is the performance ratio, which is defined as the ratio of the number of parameters in the neural network to the number of members of the data set used in the training process. Subsequently, the pattern search algorithm is used to optimize the examples using the developed optimal ANN as a surrogate model. To demonstrate the effectiveness of the presented method, two numerical examples are considered. In the first example, a ten-bar plane truss and in the second example, a two-layered 832-membered barrel vault have been investigated. In the first example, the proposed method has worked about 32 times faster in the case of continuous variables and 25 times faster in the case of discrete variables. (Compared to solving the problem with the original SAP 2000 model and the Latin hypercube sampling method). In both examples, the surrogate model obtained from the proposed method has provided the desired performance in both the validation and test data.

ARTICLE INFO

Receive Date: 04 September 2022

Revise Date: 22 October 2022

Accept Date: 07 December 2022

Keywords:

Reliability-based Design optimization, Optimization, Double layer barrel vault, Neural network, Overfitting, SAP 2000

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://doi.org/10.22065/jsce.2022.359507.2919>

*Corresponding author: Behrouz Ahmadi-Nedushan
Email address: behrooz.ahmadi@yazd.ac.ir

بهینه سازی مبتنی بر قابلیت اعتماد چلیک های دولایه با استفاده از الگوریتم

جستجوی الگو و شبکه عصبی بهینه شده به عنوان مدل جایگزین

رضا جوانمردی^۱، بهروز احمدی ندوشن^{۲*}

۱- دانشجوی دکتری سازه، دانشکده مهندسی عمران، دانشگاه یزد، یزد، ایران

۲- دانشیار، دانشکده مهندسی عمران، دانشگاه یزد، یزد، ایران

چکیده

در این تحقیق، یک روش مبتنی بر مدل جایگزین شبکه عصبی بهینه شده برای حل مسائل بهینه سازی مبتنی بر قابلیت اعتماد سازه ها ارائه شده است. ایده اصلی یافتن مدل جایگزینی است که در فضای متغیرها به اندازه کافی تعمیم یافته باشد و همچنین در فرایند آموزش، دچار پدیده بیش برازش نشده باشد. به این ترتیب، ابتدا با استفاده از جعبه ابزار *SM*، یک پایگاه داده از ورودی ها و خروجی های مساله ایجاد می شود. سپس یک مساله بهینه سازی برای به دست آوردن بهترین عملکرد شبکه عصبی حل می شود. متغیرهای طراحی در مرحله آموزش شبکه عصبی، تعداد لایه های تعریف شده در شبکه عصبی، تعداد نرون های هر لایه و نوع توابع انتقال در نظر گرفته شده اند. تابع هدف برابر با نسبت عملکرد که به صورت نسبت تعداد پارامترهای موجود در شبکه عصبی به تعداد اعضای از پایگاه داده که در فرآیند آموزش به کار می روند، تعریف می شود. در مرحله بعد، از الگوریتم جستجوی الگو برای حل مسائل بهینه سازی بر مبنای قابلیت اعتماد استفاده شده است. برای نشان دادن کارایی روش ارائه شده، دو مثال عددی در نظر گرفته شده اند. در مثال نخست، یک خرپای ۱۰ عضوی دو بعدی و در مثال دوم، یک چلیک دولایه ۱۳۲ عضوی مورد بررسی قرار گرفته اند. مثال اول برای هر دو حالت متغیرهای پیوسته و گسسته حل شده است. در مثال نخست، روش پیشنهادی ۳۲ برابر در حالت پیوسته و ۲۵ برابر در حالت گسسته سریع تر عمل کرده است. (نسبت به حل مساله با مدل اصلی *SAP 2000* و روش ابر مکعب لاتین). در هر دو مثال، مدل جایگزین به دست آمده از روش پیشنهاد شده عملکرد مورد نظر در داده های اعتبار سنجی و آزمون را تامین کرده است.

کلمات کلیدی: بهینه سازی مبتنی بر قابلیت اعتماد، چلیک دولایه، شبکه عصبی، بیش برازش، *SAP2000*

سابقه مقاله:		شناسه دیجیتال:			
دریافت	بازنگری	پذیرش	انتشار آنلاین	چاپ	doi:
۱۴۰۱/۰۶/۱۳	۱۴۰۱/۰۷/۳۰	۱۴۰۱/۰۹/۱۶	۱۴۰۱/۰۹/۱۶	۱۴۰۲/۰۷/۳۰	https://doi.org/10.22065/jsce.2022.359507.2919
*نویسنده مسئول:		بهروز احمدی ندوشن			
پست الکترونیکی:		behrooz.ahmadi@yazd.ac.ir			

۱- مقدمه

قابلیت اطمینان، به عنوان احتمال اینکه عملکرد سیستم با در نظر گرفتن عدم قطعیت ها به مقدار نهایی خود برسد تعریف می شود [۱]. به بیان ریاضی، قابلیت اطمینان یک سازه به عنوان احتمال مکمل احتمال شکست تعریف می شود:

$$P_s = 1 - P_f \quad (1)$$

که در آن، P_f ، احتمال شکست و P_s ، قابلیت اعتماد است. برآورد قابلیت اعتماد یک سیستم، یک فرایند پرهزینه از نظر محاسباتی محسوب می شود و با وجود پیشرفت های فراوان در ظرفیت و سرعت رایانه ها، حصول نتیجه در فرایندهای زمانبر محاسباتی بسیار دشوار و گاهی غیر ممکن است.

هدف از حل یک مساله بهینه سازی، جستجوی متغیر های مساله است که تابع هدف را کمینه و یا بیشینه کند و در عین حال محدودیت های آن مساله را نیز برآورده کند [۲]. از روش های بهینه سازی در رشته مختلف مهندسی استفاده می شود [۱۰-۳]. یک مساله بهینه سازی که عدم قطعیت را در فرایند بهینه سازی در نظر می گیرد یک مساله RBDO^۱ نامیده می شود که آنرا می توان به شکل زیر بیان کرد:

$$\begin{aligned} \min_{d, \mu_x} & f(d, \mu_x, \mu_p) \\ \text{s.t.} & \text{Prob}(g_i(d, X, P) \leq 0) \geq P_{si}, i = 1, \dots, n \end{aligned} \quad (2)$$

$$d^{Lower} \leq d \leq d^{Upper}$$

$$\mu_x^{Lower} \leq \mu_x \leq \mu_x^{Upper}$$

که در آن، $f(\cdot)$ ، تابع هدف، X ، بردار شامل متغیر های طراحی تصادفی، d ، بردار متغیر های طراحی، μ_x ، بردار شامل مقادیر میانگین X ، P ، بردار شامل پارامترهای تصادفی، μ_p ، بردار شامل میانگین P ، $g_i(\cdot)$ ، تابع قید، n ، تعداد قیود، $\text{Prob}(\cdot)$ ، احتمال ارضای قید i ام و P_{si} ، سطح قابلیت اعتماد دلخواه است. معمولاً P_{si} ، به صورت زیر برآورد می شود:

$$P_{si} = \Phi(\beta) \quad (3)$$

که در آن، Φ تابع چگالی تجمعی (CDF^۲) متغیر تصادفی نرمال استاندارد و β ، شاخص قابلیت اعتماد است. یک مساله RBDO، از نظر محاسباتی یک فرایند شدیداً پرهزینه محسوب می شود. روش های مختلفی برای در نظر گرفتن عدم قطعیت در تحلیل های قابلیت اعتماد سازه و بهینه سازی مبتنی بر قابلیت اعتماد در سیستم های مهندسی توسعه داده شده اند [۱۷-۱۱]. این روش ها در دو گروه تقسیم بندی می شوند که شامل روش های تک حلقه ای و روش های دو حلقه ای می شوند. در روش تک حلقه ای یک مساله بهینه سازی مبتنی بر قابلیت اعتماد تبدیل به یک مساله تقریبی بهینه سازی مبتنی بر متغیرهای قطعی می شود [۱۸]. در روش دو حلقه ای بهینه سازی با استفاده از حلقه بیرونی صورت می پذیرد و حلقه داخلی شاخص قابلیت اعتماد را محاسبه می کند [۲۰، ۱۹]. تحلیل قابلیت اعتماد را می توان از روش های مستقیم نظیر اندیس قابلیت اعتماد [۱۹] و یا روش های معکوس [۲۱، ۲۲] انجام داد. یک ایده دیگر برای حل مسائل RBDO، استفاده از رویکرد توالی بهینه سازی و ارزیابی شاخص قابلیت اعتماد (SORA) است. در این رویکرد یک مساله RBDO به

¹ Reliability Based Design Optimization

² Cumulative Distribution Function

توالی حلقه بهینه سازی و حلقه ارزیابی قابلیت اعتماد تبدیل می شود [۲۳]. همچنین یک روش ترکیبی موسوم به SORA-ICDE برای حل مسائل RBDO در خراباها ارائه شده است [۲۴]. این روش ترکیبی از روش SORA و الگوریتم بهبود یافته مقید شده تکامل تفاضلی (ICDE) است.

استفاده از الگوریتم های فراکاوشی بهینه سازی در حل مسائل RBDO توسط محققان متعددی بررسی شده است. خدام و همکاران [۲۵] با استفاده از روش شبیه سازی وزنی که یکی از روش های نوین و موثر برای محاسبه شاخص قابلیت اطمینان و احتمال خرابی سازه می باشد و الگوریتم کرم شب تاب این گونه مسائل را مورد بررسی قرار دادند. نتایج مثال عددی و مقایسه آن با نتایج سایر روش های متناظر نشان داد که با استفاده از روش پیشنهاد شده ضمن حفظ سطح قابلیت اعتماد مورد نظر به نسبت سایر روش های مقایسه شده، وزن سازه و میزان مصالح مصرفی نیز کاهش پیدا کرده است. کاوه و قازان [۲۶] برای حل مسائل بهینه سازی مبتنی بر قابلیت اعتماد یک مدل مبتنی بر استفاده از الگوریتم های مختلف را ارائه دادند. آنها برای برآورد شاخص قابلیت اعتماد از الگوریتم های $ECBO^3$ ، $DPSO^4$ ، CBO^5 ، $ECBO^6$ و $CEBO$ ، و روش شبیه سازی مونت-کارلو، مساله RBDO قاب های بتنی با در نظر گرفتن طرح لرزه ای مورد بررسی قرار دادند و اثر بخشی این روش را نشان دادند. در صورتی که فرایند محاسبه قیود مساله یک فرآیند زمانبر باشد استفاده از رویکرد های مطرح شده در بالا عملاً بسیار مشکل و یا غیر ممکن می گردد. پاپادراکاکیس و لاگروس [۲۸]، از مدل های جایگزین شبکه های عصبی مصنوعی برای حل مسائل بهینه سازی مبتنی بر قابلیت اعتماد در سازه های بزرگ مقیاس استفاده کردند آنها برای انجام عملیات بهینه سازی از الگوریتم هلی فراکاوشی استفاده کردند و محاسبه احتمال شکست توسط روش مونت-کارلو پیاده سازی شد. یانگ لیو و همکاران [۲۹] یک روش ترکیبی برای مسائل بهینه سازی مبتنی بر قابلیت اعتماد ارائه کردند. روش ارائه شده ترکیبی از مفاهیم اجزای محدود و شبکه عصبی و الگوریتم ژنتیک بود. در این تحقیق از نرم افزار ANSYS برای انجام تحلیل سازه استفاده شد. در این روش مشخصات شبکه های عصبی مورد استفاده از جمله تعداد لایه ها، تعداد نرون های موجود در هر لایه و نوع توابع انتقال و همچنین اندازه پایگاه داده ثابت در نظر گرفته شده است.

محققان در زمینه بهینه سازی سازه ها با رویکرد قطعی نیز از شبکه های عصبی استفاده کرده اند. به عنوان نمونه در مرجع [۳۰]، کاوه و همکاران از این ایده برای کاهش هزینه های محاسباتی در بهینه سازی شکل و اندازه دکل های انتقال برق استفاده کردند. طاهری و همکاران [۳۱]، از شبکه های عصبی شعاع مینا (RBF) برای بهینه سازی برج ها استفاده کردند. الگوریتم بهینه سازی مورد استفاده، الگوریتم کلونی زنبور بود. نگوین و همکاران [۳۲]، از الگوریتم تکامل دیفرانسیل ترکیبی (CoDE) برای بهینه سازی سازه ها استفاده کردند، که در آن بهینه سازی به وسیله شبکه های عصبی به عنوان مدل جایگزین برای سرعت بخشیدن به فرآیند ارزیابی جمعیت استفاده شد. ابتدا CoDE استفاده شد، در این مرحله مقادیر پاسخ های ممکن در پایگاه داده ذخیره شده و پس از تولید داده های کافی، شبکه عصبی آموزش داده می شود تا تخمین های سریع تری از تابع هدف ارائه دهد. سه سازه خرپایی (خرپا ۱۰ میله، خرپا ۲۵ میله و خرپا ۷۲ میله) برای بررسی توانمندی روش استفاده شده است. آن ها نشان دادند که با استفاده از این روش، در حدود ۶۰٪ صرفه جویی در فراخوانی تابع هدف ایجاد می شود. پاپادراکاکیس و همکاران [۳۳]، از شبکه های عصبی به عنوان مدل جایگزین در مرحله زمانبر تحلیل سازه های بزرگ مقیاس برای بهینه سازی شکل و اندازه سازه استفاده کردند و به مزایای محاسباتی قابل توجهی دست یافتند. لاگروس و پاپادراکاکیس [۳۴]، عملکرد الگوریتم های بهینه سازی تکامل دیفرانسیلی، جستجوی هارمونی و ازدحام ذرات را ارزیابی کردند و توانمندی این الگوریتم ها را برای حل مسائل بهینه سازی در سازه های واقعی با تعداد زیاد درجات آزادی نشان دادند. برای این منظور، از شبکه های عصبی برای پیش بینی پاسخ سازه در طول فرآیند بهینه سازی استفاده کردند.

³ Improved Ray Optimization

⁴ Democratic Particle Swarm Optimization

⁵ Colliding Bodies Optimization

⁶ Enhanced Colliding Bodies Optimization

در این تحقیق یک روش مبتنی بر مدل جایگزین شبکه عصبی برای حل مسائل بهینه سازی مبتنی بر قابلیت اعتماد ارائه شده است. ایده اصلی یافتن مدل جایگزینی است که در فضای متغیرها به اندازه کافی تعمیم یافته باشد و همچنین در فرآیند آموزش دچار پدیده بیش برآزش نشده باشد. در این روش ابتدا با استفاده از برنامه نوشته شده توسط جعبه ابزار SM [۳۵] یک مدل اجزای محدود از مساله در نرم افزار SAP2000 ایجاد می شود و با استفاده از آن یک پایگاه داده از ورودی ها و خروجی های مساله ایجاد می شود. سپس یک مساله بهینه سازی برای به دست آوردن بهترین عملکرد شبکه عصبی حل می شود. متغیرهای طراحی در این مرحله، تعداد لایه های تعریف شده در شبکه عصبی، تعداد نرون های هر لایه و نوع توابع انتقال در نظر گرفته شده اند. تابع هدف برابر با نسبت عملکرد در نظر گرفته شده است که به صورت نسبت تعداد پارامترهای موجود در شبکه عصبی به تعداد اعضای از پایگاه داده که در فرآیند آموزش به کار می روند تعریف می شود. همچنین قیود عملکرد شبکه عصبی نیز در نظر گرفته شده اند. با استفاده از شبکه عصبی بهینه شده مساله بهینه سازی مبتنی بر قابلیت اعتماد حل شده است. در این روش در مرحله آموزش شبکه عصبی متغیرهای طراحی نیز به صورت متغیرهای تصادفی با توزیع یکنواخت در نظر گرفته می شوند و بنابر این عملیات آموزش شبکه عصبی تنها یک بار صورت خواهد پذیرفت. برای نشان دادن اثر بخشی روش ارائه شده، دو مثال عددی در نظر گرفته شده اند. در مثال نخست یک خرپای ۱۰ عضوی دو بعدی و در مثال دوم یک چلیک دو لایه ۸۳۲ عضوی مورد بررسی قرار گرفته اند.

۲- جعبه ابزار SM

امروزه در رشته های مختلف مهندسی از جمله مهندسی سازه و مهندسی زلزله تحقیقات زیادی در زمینه های هوش مصنوعی و بهینه سازی صورت می پذیرد. در اکثر این تحقیقات نیاز به تحلیل سازه مورد تحقیق می باشد. محققان برای حل این مساله از روش های متفاوتی در فرآیند برنامه نویسی استفاده می کنند. یکی از موثرترین این روش ها فراخوانی نرم افزار قدرتمند SAP2000 توسط نرم افزار MATLAB می باشد [۳۶]. در این تحقیق، از جعبه ابزار SM که توسط نویسندگان برای فراخوانی نرم افزار SAP2000 توسط نرم افزار MATLAB توسعه داده شده استفاده شده است [۳۵]. بدین ترتیب می توان از تمام مزایای این نرم افزار از جمله مدل سازی دقیق، استفاده از انواع اجزای سازه ای نظیر جز قاب، جز پوسته، میراگر و ... و انواع تحلیل های تعریف شده در این نرم افزار و آیین نامه های مختلف در فرآیند تحقیق بهره برد.

۳- شبکه های عصبی

در سال های اخیر ایده استفاده از مدل های جایگزین برای حل مسائل مهندسی بسیار مورد توجه قرار گرفته است [۳۷-۴۴]. زیرا این مدل ها با استفاده از اصول بسیار کم هزینه تر نسبت به مدل اصلی و با دقت کافی قادر به محاسبه خروجی های معادل سازی شده هستند. همچنین این مدل ها قابلیت اجرا به صورت موازی شده بر روی سخت افزار های مبتنی بر پردازنده ها (CPU⁷) و کارت های گرافیکی (GPU⁸) را دارند که سرعت محاسبات را بطور قابل توجهی افزایش می دهند. مدل های جایگزین انواع مختلفی از جمله ماشین های بردار پشتیبان، درخت تصمیم، چند جمله ای های آشوب، شبکه های عصبی مصنوعی و غیره دارند. از بین انواع مختلف مدل های جایگزین شبکه های عصبی به دلیل استفاده از اصول یادگیری عمیق که در سال های اخیر پیشرفت های فراوانی را تجربه کرده است بسیار مورد توجه است. شبکه های عصبی یک روش محاسباتی است که بر اساس ساختار سلول های نرونی سیستم عصبی پیاده سازی شده است. با در دسترس بودن داده های آموزشی، یک شبکه عصبی می تواند طرح حاکم بر پایگاه داده را تشخیص دهد. شبکه های عصبی سه مزیت عمده دارند: اول اینکه توانایی یادگیری هرگونه محیط پیچیده و غیر خطی را دارند. دوم اینکه شبکه هیچ پیش فرض اولیه ای در مورد توزیع داده ها در نظر نمی گیرد و سوم اینکه شبکه های عصبی در برابر داده های ناقص و از دست رفته بسیار انعطاف پذیراند. رایج ترین نوع شبکه های عصبی شبکه عصبی چند لایه (MLP⁹) نامیده می شود که شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه

⁷ Central Processing Unit

⁸ Graphics Processing Unit

⁹ Multilayer Perceptron

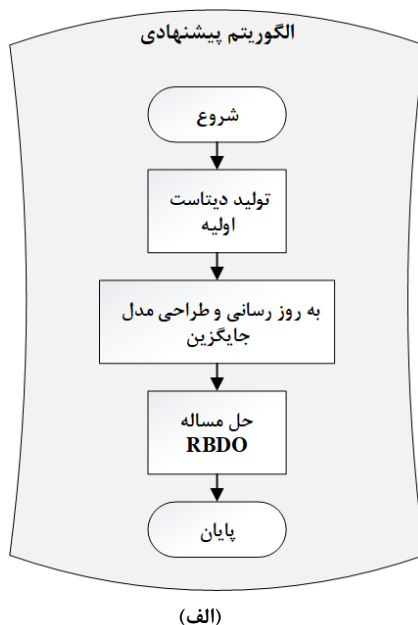
خروجی است. نورون ها در چندین لایه از جمله لایه ورودی، لایه های پنهان و لایه خروجی سازماندهی می شوند. خروجی های نورون های لایه قبلی پس از مقیاس بندی با وزن های مربوطه به ورودی های نورون فعلی تبدیل می شوند. همه ورودی ها در هر لایه جمع می شوند و سپس توسط تابع فعال سازی تبدیل به خروجی لایه فعلی می شوند [۴۵].

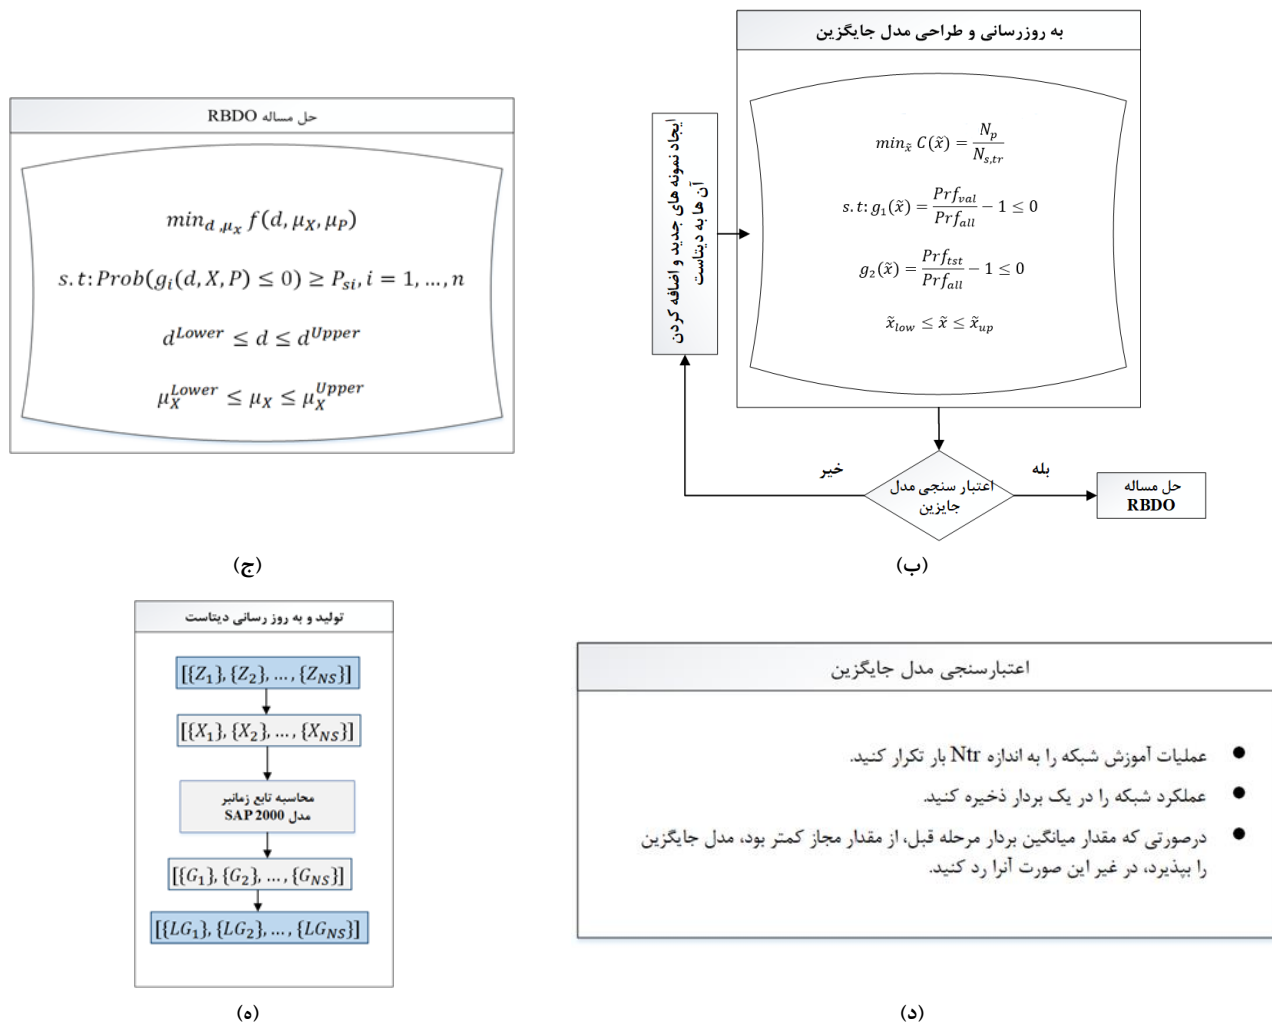
۴- الگوریتم جستجوی الگو

الگوریتم جستجوی الگو یک روش جستجوی مؤثر برای حل مسائل مهندسی با ارزیابی های تابع هدف پرهزینه است [۴۶]. این الگوریتم از روش جستجوی مستقیم برای حل مسائل بهینه سازی استفاده می کند. این روش به اطلاعات گرادینان تابع نیازی ندارد و هدف آن یافتن نتیجه بهتر در اطراف نقطه فعلی است. از جستجوی مستقیم می توان برای حل مسائلی استفاده کرد که تابع هدف برای آنها قابل تمایز یا حتی پیوسته نیست [۴۷]. الگو مجموعه ای از بردارها است $\{v_i\}$ که الگوریتم از آنها برای تعیین نقاط جستجو در هر تکرار استفاده می کند. مجموعه $\{v_i\}$ با تعداد متغیرهای مستقل در تابع هدف، (N) و مجموعه پایه مثبت تعریف می شود. دو مجموعه پایه مثبت که معمولاً در الگوریتم های جستجوی الگو مورد استفاده قرار می گیرند، مبنای حداکثر با بردار به طول $(2N)$ و پایه حداقل با بردار به طول $(N+1)$ هستند. ایده اصلی این است که یک شبکه در اطراف آخرین نقطه بهینه ساخته شود و فرآیند برای به دست آوردن راه حل بهتر با شبکه ادامه یابد. با تغییر اندازه شبکه الگوریتم به نقطه بهینه نزدیک می شود.

۵- الگوریتم پیشنهادی

در شکل ۱ قسمت های اصلی روش پیشنهادی نشان داده شده است. این الگوریتم به دنبال یافتن مدل جایگزینی است که بتواند به جای مدل اصلی در حل مساله به کار گرفته شود و خطای آن قابل چشم پوشی باشد. همچنین اندازه پایگاه داده کمترین مقدار لازم باشد تا زمان دستیابی به مدل مذکور و حل مساله توسط آن کمتر از حل مساله توسط مدل اصلی باشد. بطور کلی روش پیشنهادی شامل دو مرحله است. در مرحله نخست الگوریتم به دنبال بهترین مدل جایگزین و اندازه پایگاه داده لازم برای دستیابی به این مدل جایگزین می گردد. در مرحله دوم الگوریتم حل مساله RBDO دنبال می شود.





شکل ۱: الگوریتم پیشنهاد شده برای حل مساله

در شکل ۱، Ds_0 ، پایگاه داده اولیه، N_s ، تعداد نمونه های لازم برای ساخت مدل جایگزین، بردارهای $\{G\}$ و $\{LG\}$ ، به ترتیب بردارهای شامل قیود اصلی مساله و قیود جایگزین شده هستند (رابطه ۷). پایگاه داده نهایی بین ورودی های نرمال شده $\{Z\}$ و خروجی های مقیاس شده $\{LG\}$ در نظر گرفته می شود. متغیرهای طراحی که از نوع گسسته اند در مرحله تولید پایگاه داده به صورت پیوسته در نظر گرفته شده اند و پس از به دست آمدن مدل جایگزین در مرحله نهایی از مقادیر گسسته استفاده شده است. در شکل ۱-الف، مراحل اصلی الگوریتم نشان داده شده است. در اولین گام یک پایگاه داده اولیه ایجاد می گردد (شکل ۱-ه). در مرحله بعد مدل جایگزین طراحی می گردد و در صورتی که مدل جایگزین شرایط لازم برای حل مساله را داشته باشد پذیرفته می گردد. در غیر این صورت مجدداً اندازه پایگاه داده افزایش داده می شود و مدل جایگزین طراحی می شود. این عمل تا دستیابی به مدل جایگزین مناسب تکرار می گردد (شکل ۱-ب). در آخرین گام، با استفاده از مدل جایگزین به دست آمده مساله RBDO حل می شود. در ادامه نحوه عملکرد قسمت های مختلف الگوریتم پیشنهادی توضیح داده می شود.

۱-۵- ایجاد و به روز رسانی پایگاه داده

در مرحله نخست و در مرحله به روز رسانی پایگاه داده از روش نمونه سازی ابر مکعب لاتین استفاده شده است [۴۸]. بدین ترتیب از توزیع یکنواخت متغیرها در فضای طراحی اطمینان بیشتری حاصل می شود و بنابر این مدل جایگزین به دست آمده عملکرد

مطمئن تری خواهد داشت. از آنجایی که متغیرهای ورودی روش نمونه سازی ابر مکعب لاتین به کار رفته در این تحقیق دارای توزیع نرمال استاندارد هستند، برای تبدیل این متغیرها به متغیرهای اصلی از تبدیل زیر استفاده می شود:

$$x_i = F_x^{-1} \{ \Phi(z_i) \}, i = 1, 2, \dots, n_x \quad (4)$$

که در آن، z_i ، متغیرهای نرمال استاندارد، x_i ، متغیرهای اصلی، n_x ، تعداد کل متغیرها، F_x ، تابع توزیع تجمعی برای متغیر تصادفی X ، Φ تابع توزیع تجمعی برای متغیر نرمال استاندارد است. در این مرحله متغیرهای طراحی نیز به صورت متغیرهای تصادفی با توزیع یکنواخت که بین حد پایین و حد بالای خودشان به صورت تصادفی تغییر می کنند در نظر گرفته می شوند. سپس با استفاده از دستورات جعبه ابزار SM [35]، مدل اجزای محدود مربوط به مساله تشکیل می شود و خروجی های مساله که همان مقادیر قیود هستند محاسبه می شوند. محدودیت های این مساله بر اساس خروجی های نرم افزار SAP2000 به صورت زیر ارائه شده است:

$$g_i(X) = R_i(X) - 1 \leq 0, i = 1, 2, \dots, n_g \quad (5)$$

که در آن n_g ، تعداد قیود تعریف شده در مساله، $R_i(X)$ ، ضرایب کنترلی تنش و یا ظرفیت برای به اعضای تشکیل دهنده سازه است که باید مقادیری کوچکتر و یا برابر با ۱ داشته باشند. قیود مساله ممکن است مقادیری از $-\infty \sim +1$ داشته باشند. این مساله فرآیند آموزش شبکه عصبی را مشکل می کند. در این تحقیق به جای استفاده از قیود تعریف شده در رابطه ۵ از قید جایگزین زیر استفاده می شود:

$$L_{gi} \leq 0, i = 1, 2, \dots, n_g \quad (6)$$

که در آن، تابع L_{gi} از رابطه زیر به دست می آید:

$$L_{gi} = \begin{cases} g_i, & -1 \leq g_i \leq 1 \\ 1 + \ln(g_i), & g_i > 1 \end{cases} \quad (7)$$

این تابع برای مقادیر بین -۱ و +۱ همان مقدار قید را برمی گرداند و برای مقادیر بزرگتر از +۱، مقادیر قیود را مقیاس سازی می کند. در شکل ۱-۵ مراحل مختلف این بخش نشان داده شده است. در ابتدا مجموعه ای از بردارهای نرمال شده $\{Z\}$ که از روش ابرمکعب لاتین تولید شده اند ایجاد می شود. سپس با استفاده از رابطه (۴) و توابع توزیع تجمعی متغیرهای مساله بردارهای اصلی $\{X\}$ ایجاد می شوند. این بردارها به برنامه ای که توسط جعبه ابزار SM در نرم افزار متلب پیاده سازی شده است فرستاده می شوند. و در ازای هر یک از آن ها مدل SAP2000 یک بار اجرا می گردد و خروجی های مساله در بردارهای $\{G\}$ ذخیره سازی می گردند. سپس با استفاده از رابطه (۷) این خروجی ها مقیاس سازی شده و در بردارهای $\{LG\}$ ذخیره می گردند.

۲-۵- ایجاد مدل جایگزین شبکه عصبی بهینه شده و حل مساله RBDO

در این مرحله یک مدل جایگزین مبتنی بر شبکه عصبی چندلایه ایجاد می شود. این مدل جایگزین به جای توابع پرهزینه محاسبه قیود در حل مساله RBDO استفاده می شود. ایده اصلی یافتن مدل جایگزینی است که در فضای متغیرها به اندازه کافی تعمیم یافته باشد و همچنین در فرایند آموزش دچار پدیده بیش برآزش نشده باشد. به این منظور از ایده های ذکر شده در نرم افزار متلب استفاده شده است که در ادامه آورده شده اند [49]:

- در صورتی که پارامترهای یک شبکه عصبی، بسیار کوچکتر از تعداد اعضای از پایگاه داده باشند که برای آموزش شبکه مورد استفاده قرار می گیرند، تقریباً هیچ شانس برای ایجاد پدیده بیش برآزش وجود ندارد.
 - از آنجایی که هر فرآیند آموزش پس انتشار با وزن ها و بایاس های متفاوت اولیه ای و همچنین تقسیم بندی متفاوت داده ها به گروه های آموزش، اعتبارسنجی و آزمایش شروع به کار می کند، فرآیند های چندین باره آموزش می تواند به نتایج متفاوتی برای یک پایگاه داده ثابت منجر شود. بنابراین انجام چندین باره فرآیند آموزش پس انتشار می تواند ایده خوبی برای بررسی تعمیم یافتگی شبکه عصبی جایگزین باشد.
- با توجه به ایده اول، می توان نسبت عملکرد یک شبکه عصبی که برای یک پایگاه داده مشخص آموزش دیده است را به صورت زیر در نظر گرفت:

$$C = \frac{N_p}{N_{s,tr}} \quad (8)$$


که در آن، N_p ، تعداد پارامترهای به کار رفته در شبکه عصبی و $N_{s,tr}$ ، تعداد اعضای پایگاه داده است که برای آموزش شبکه به کار گرفته می شوند. مساله طراحی یک شبکه عصبی به صورت یک مساله بهینه سازی پیاده سازی شده و به صورت زیر قابل بیان است:

$$\begin{aligned} \min_{\tilde{x}} C(\tilde{x}) &= \frac{N_p}{N_{s,tr}} \\ \text{s.t. : } g_1(\tilde{x}) &= \frac{Prf_{val}}{Prf_{all}} - 1 \leq 0 \end{aligned} \quad (9)$$

$$g_2(\tilde{x}) = \frac{Prf_{test}}{Prf_{all}} - 1 \leq 0$$

$$\tilde{x}_{low} \leq \tilde{x} \leq \tilde{x}_{up}$$

که در آن، $\tilde{x} = \{x_{1,ANN}, x_{2,ANN}, x_{3,ANN}\}$ (شکل ۲)، بردار متغیرهای شبکه عصبی ($x_{1,ANN}$)، متغیر طراحی به نمایندگی از تعداد لایه ها، $x_{2,ANN}$ ، متغیر طراحی به نمایندگی از تعداد نرون ها در یک لایه، $x_{3,ANN}$ ، متغیر طراحی به نمایندگی از نوع تابع انتقال (جدول ۱))، $C(\tilde{x})$ ، تابع هدف، Prf_{val} ، عملکرد شبکه عصبی (میانگین مربع خطاها) در داده های اعتبارسنجی، Prf_{test} ، عملکرد شبکه عصبی (میانگین مربع خطاها) در داده های آزمون، Prf_{all} ، مقدار مجاز عملکرد شبکه است.



شکل ۲: متغیرهای مربوط به شبکه عصبی

تعداد پارامترهای به کار رفته در شبکه عصبی برابر با تعداد درایه های موجود در ماتریس های ضرایب و تعداد درایه های موجود در بردارهای بایاس است. هر لایه از یک شبکه عصبی چند لایه دارای یک ماتریس ضرایب به اندازه $S \times R$ و یک بردار بایاس به اندازه $S \times 1$ است. که در آن S ، تعداد پارامترهای خروجی از این لایه و R ، تعداد پارامترهای ورودی آن است. بنابراین این لایه نام از یک شبکه عصبی به تعداد زیر پارامتر خواهد داشت:

$$N_{p,i} = S(1 + R) \quad (10)$$

که در آن، $N_{p,i}$ تعداد پارامترهای لایه نام است. بنابراین تعداد پارامترهای به کار رفته در شبکه عصبی به کار رفته در این تحقیق از رابطه زیر به دست می آید:

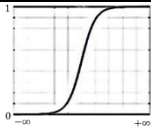
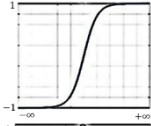
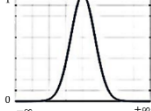
$$N_p = x_{2,ANN} \left((x_{1,ANN} - 1)(x_{2,ANN} + 1) + N_i + N_o + 1 \right) + N_o \quad (11)$$

که در آن، N_i ، تعداد متغیرهای ورودی، N_o ، تعداد متغیرهای خروجی مساله، $x_{1,ANN}$ ، تعداد لایه های مخفی، $x_{2,ANN}$ ، تعداد نرون ها در هر لایه مخفی، و $x_{3,ANN}$ ، نوع تابع انتقال است (جدول ۱). همچنین برای محاسبه Prf ، از رابطه زیر استفاده می شود:

$$Prf = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (12)$$

که در آن، t_i ، مقادیر خروجی در پایگاه داده، a_i ، خروجی های متناظر توسط شبکه عصبی اند. برای حل مساله فوق از الگوریتم بهینه سازی جستجوی گواستفاده شده است.

جدول ۱: انواع توابع انتقال مورد استفاده در شبکه عصبی

ضابطه	شکل
1: $\text{logsig}(n) = \frac{1}{1 + e^{-n}}$	
2: $\text{tansig}(n) = \frac{2}{1 + e^{-2n}} - 1$	
3: $\text{radbas}(n) = e^{-n^2}$	

جهت اعتبار سنجی یک مدل شبکه عصبی از ایده دوم استفاده می شود. بدین ترتیب که با انجام چندین باره عملیات آموزش شبکه (N_r)، چندین شبکه عصبی که داری عملکردهای متفاوتی هستند به دست می آید. در صورتی که میانگین این عملکردها از مقدار مجاز کمتر باشد شبکه و پایگاه داده موجود پذیرفته می شود و در غیر اینصورت اندازه پایگاه داده با یک گام ثابت افزایش داده می شود و عملیات تکرار می گردد. در صورت پذیرش شبکه جایگزین، مساله RBDO با استفاده از مدل جایگزین به دست آمده حل می شود. برای محاسبه احتمال شکست با استفاده از مدل جایگزین به دست آمده و روش مونت-کارلو، یک نمونه تصادفی در هر مرحله از فراخوانی قیود مساله در فرآیند بهینه سازی ایجاد می شود. اندازه این نمونه تصادفی از رابطه زیر محاسبه شده است [۴۸].

$$N_s = \frac{1 - P_f}{V_p^2 P_f}, V_p = 0.05, \beta_t = 3 (P_f = 0.001) \rightarrow N_s = 295,919 \quad (13)$$


که در آن، N_s ، تعداد نمونه های لازم جهت محاسبه احتمال شکست، P_f ، احتمال شکست، و V_p ، واریانس مربوط به احتمال شکست است.

۶- مثال های عددی


در این بخش دو مثال عددی ارائه می شود. مثال اول بهینه سازی مبتنی بر قابلیت اعتماد یک خرپای دو بعدی ۱۰ عضوی و مثال دوم بهینه سازی مبتنی بر قابلیت اعتماد چلیک ها دولایه با ۸۳۲ عضو است. در هر دو مثال، اندازه پایگاه داده با گام ثابت ۵۰ افزایش داده می شود. برای حل هر دو مثال از پردازنده Intel® Core (TM) i5-6200U CPU@2.3GHz، که دارای دو پردازنده فیزیکی و چهار پردازنده منطقی است استفاده شده است. همچنین در هر دو مثال توزیع متغیرهای تصادفی مطابق با توصیه مرجع [۵۰] است.

۶-۱- خرپای ۱۰ عضوی

در این مثال مساله بهینه سازی مبتنی بر قابلیت اعتماد یک خرپای دوبعدی (شکل ۴) ارائه می شود. این مثال در مراجع [۵۱، ۵۲] ذکر شده است و برای مقاصد این تحقیق ویرایش شده است. مشخصات مربوط به ثوابت و متغیرهای طراحی و تصادفی در جدول ۲ نشان داده شده اند. در مجموع ۱۲ متغیر (۸ متغیر تصادفی و ۴ متغیر طراحی) وجود دارند. اعضای این سازه در دو گروه G_1 و G_2 از مقاطع دایروی ساخته شده اند. ابعاد مقاطع این گروه ها (ضخامت و قطر) به عنوان متغیرهای طراحی در نظر گرفته شده اند (شکل ۳).



شکل ۴: خرابی ۱۰ عضوی



شکل ۳: پارامترهای D, t

محدودیت های این مساله بر اساس خروجی های نرم افزار SAP2000 به صورت زیر در نظر گرفته شده است:

$$g_1(X) = \frac{\Phi(\beta_1)}{\text{Prob}\{R_1(X) - 1 \leq 0\}} - 1 \leq 0 \quad (14)$$

$$g_2(X) = \frac{\Phi(\beta_2)}{\text{Prob}\{R_2(X) - 1 \leq 0\}} - 1 \leq 0 \quad (15)$$

که در آن، $R_1(X)$ و $R_2(X)$ ضرایب کنترلی تنش و یا ظرفیت برای به اعضای تشکیل دهنده سازه هستند که باید مقادیری کوچکتر و یا برابر با ۱ داشته باشند. β_i ، اندیس قابلیت اعتماد هدف است و برابر ۳ در نظر گرفته شده است. این توابع توسط مدل پیشنهاد شده جایگزین می شوند. همچنین از آیین نامه AISC 360-10 برای طراحی اعضای فولادی استفاده شده است. ترکیب بار طراحی به صورت DL+LL در نظر گرفته شده است. همچنین تمامی ضرایب مربوط به کاهش مقاومت برابر با یک در نظر گرفته شده اند. تابع هدف برابر وزن خرپا در نظر گرفته شده است و از رابطه زیر محاسبه می شود:

$$W_t = \mu_\gamma \pi \sum_{i=1}^{N_{el}} D_i t_i L_i \quad (16)$$

که در آن، W_t ، وزن سازه، μ_γ ، میانگین وزن مخصوص فولاد های به کار رفته در سازه، D_i ، قطر مقاطع دایروی به کار رفته در اعضای سازه، t_i ، ضخامت مقاطع دایروی به کار رفته در اعضای سازه، L_i ، طول اعضای سازه، N_{el} ، تعداد کل اعضای سازه است.

جدول ۲: ثوابت، متغیرهای طراحی و تصادفی در حل مساله خرابی ۱۰ عضوی

پارامتر	تعریف	نوع	توزیع	میانگین و واریانس
$X_1(E)$	مدول الاستیسیته فولاد	متغیر تصادفی	لاگ نرمال	$\mu = 210 \times 10^3 \frac{N}{mm^2}$ $\sigma = 31.5 \times 10^3 \frac{N}{mm^2}$
$X_2(F_y)$	تنش تسلیم فولاد	متغیر تصادفی	لاگ نرمال	$\mu = 335 \frac{N}{mm^2}$ $\sigma = 33.5 \frac{N}{mm^2}$
$X_3(F_{1,DL})$	بار مرده اعمال شده بر سازه	متغیر تصادفی	لاگ نرمال	$\mu = 18 KN$ $\sigma = 0.9 KN$

$X_4 (F_{1,LL})$	بار زنده اعمال شده بر سازه	متغیر تصادفی	لاگ نرمال	$\mu = 20 \text{ KN}$ $\sigma = 1 \text{ KN}$
$X_5 (F_{2,DL})$	بار مرده اعمال شده بر سازه	متغیر تصادفی	لاگ نرمال	$\mu = 180 \text{ KN}$ $\sigma = 0.9 \text{ KN}$
$X_6 (F_{2,LL})$	بار زنده اعمال شده بر سازه	متغیر تصادفی	لاگ نرمال	$\mu = 20 \text{ KN}$ $\sigma = 1 \text{ KN}$
$X_7 (F_{3,DL})$	بار مرده اعمال شده بر سازه	متغیر تصادفی	لاگ نرمال	$\mu = 180 \text{ KN}$ $\sigma = 0.9 \text{ KN}$
$X_8 (F_{3,LL})$	بار زنده اعمال شده بر سازه	متغیر تصادفی	لاگ نرمال	$\mu = 20 \text{ KN}$ $\sigma = 1 \text{ KN}$
$d_1 (D_{G1})$	قطر مقطع دایروی، گروه ۱	متغیر طراحی	یکنواخت	گسسه ته 20 : 1 : 150, mm پیوسته 20 ~ 150, mm
$d_2 (t_{G1})$	ضخامت مقطع دایروی، گروه ۱	متغیر طراحی	یکنواخت	گسسه ته 2 : 1 : 10, mm پیوسته 2 ~ 10, mm
$d_3 (D_{G2})$	قطر مقطع دایروی، گروه ۲	متغیر طراحی	یکنواخت	گسسه ته 20 : 1 : 150, mm پیوسته 20 ~ 150, mm
$d_4 (t_{G2})$	ضخامت مقطع دایروی، گروه ۲	متغیر طراحی	یکنواخت	گسسه ته 2 : 1 : 10, mm پیوسته 2 ~ 10, mm
S	پارامتر ابعادی	ثابت	-	3000 mm
H	پارامتر ابعادی	ثابت	-	3000 mm

بازه تغییرات متغیرهای طراحی مربوط به شبکه عصبی به صورت زیر در نظر گرفته شده است:

$$x_{1,ANN} \in \{1, 2, 3\} \quad (17)$$

$$x_{2,ANN} \in \{1, 2, \dots, 20\} \quad (18)$$


$$x_{3,ANN} \in \{1, 2, 3\} \quad (19)$$

عملکرد شبکه عصبی جایگزین برای دستیابی به دقت مطلوب برابر $Prf_{all} = 0.01$ در نظر گرفته شده است. شبکه عصبی بهینه شده، در شکل ۵ نشان داده شده است. نمودار شکل ۶ نشان دهنده رگرسیون شبکه عصبی بهینه شده هستند. همچنین، تعداد اعضای پایگاه داده لازم برای حصول شبکه عصبی بهینه برابر ۶۰۰ به دست آمده است. در جدول ۳ خطاهای مربوط به اعضای به کار رفته در آموزش، اعتبارسنجی و آزمون نمایش داده شده اند.

جدول ۳: خطای مدل جایگزین مربوط به مساله خرپای ۱۰ عضوی


نوع داده ها	میانگین مربعات خطا	میانگین مطلق خطا
داده های آموزش	0.00853	0.0593
داده های اعتبار سنجی	0.00686	0.0613
داده های آزمون	0.00845	0.0657

بر اساس نتایج ذکر شده در جدول ۳، مدل جایگزین پیشنهادی در تخمین قیود مساله توانمندی خوبی دارد.




شکل ۵: شبکه عصبی بهینه شده برای حل مساله خرابی دو بعدی ۱۰ عضوی

در شکل ۷ و شکل ۸، نمودار همگرایی برای الگوریتم جستجوی الگو در حالت گسسته و حالت پیوسته نشان داده شده است.

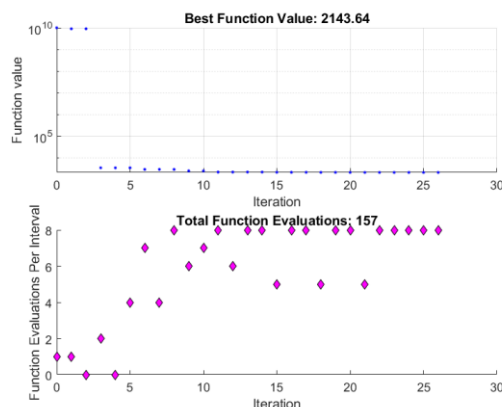


شکل ۶: رگرسیون شبکه عصبی بهینه شده خرابی ۱۰ عضوی

مقدار خطاهای گزارش شده برای مدل جایگزین (جدول ۳) و همچنین ضریب همبستگی نزدیک به ۱ در داده های آموزشی، اعتبار سنجی، آزمایش، و کل داده ها (شکل ۶) نشان دهنده عملکرد خوب روش ارائه شده در حل مساله بهینه سازی تعریف شده برای دستیابی به مدل جایگزین بهینه (رابطه ۹) است. در این مثال در هر دو حالت گسسته و پیوسته الگوریتم ۲۰ بار اجرا شد و بهترین نتیجه گزارش شده است.



شکل ۸: نمودار همگرایی (نیمه لگاریتمی) الگوریتم جستجوی الگو برای مساله خرابی دوبعدی ۱۰ عضوی (حالت پیوسته)



شکل ۷: نمودار همگرایی (نیمه لگاریتمی) الگوریتم جستجوی الگو برای مساله خرابی دوبعدی ۱۰ عضوی (حالت گسسته)

در جدول ۴، متغیرهای بهینه و شاخص قابلیت هر یک از قیود برای حل توسط الگوریتم جستجوی الگو نشان داده شده است.

جدول ۴: متغیرهای طراحی بهینه و شاخص های قابلیت اعتماد مربوط به مساله خرپای ۱۰ عضوی

پارامتر	مقدار	پارامتر	مقدار
$d_1(D_{G1})$	پیوسته	β_1	پیوسته
	گسسته		گسسته
$d_2(t_{G1})$	پیوسته	β_2	پیوسته
	گسسته		گسسته
$d_3(D_{G2})$	پیوسته	$W_{t,opt}$	پیوسته
	گسسته		گسسته
$d_4(t_{G2})$	پیوسته		
	گسسته		

مطابق نتایج جدول ۴، هر دو قید نزدیک به فعال اند. بایستی توجه شود که متغیرهای طراحی در دو حالت گسسته و پیوسته در نظر گرفته شده اند. روش پیشنهادی به خوبی توانسته قیود مساله را به شاخص قابلیت اعتماد هدف نزدیک سازد. از آنجا که مساله در دو حالت متغیرهای پیوسته و گسسته بررسی شده است، شاخص های قابلیت اعتماد دارای مقادیر متفاوتی در هر رویکرد هستند. به جهت نشان دادن توانمندی روش ارائه شده، مقادیر قیود مساله در نمونه هایی که توسط مدل جایگزین نمونه های شکست محسوب شده اند توسط مدل واقعی (SAP 2000) نیز محاسبه شده است. مقدار میانگین مربعات خطا و خطای محاسبه شاخص قابلیت اعتماد توسط مدل جایگزین برای هر دو قید در جدول ۵ نشان داده شده است.

جدول ۵: خطای تشخیص شکست مدل جایگزین مربوط به مساله خرپای ۱۰ عضوی

قید	تعداد نمونه های شکست تشخیص داده شده توسط مدل جایگزین	تعداد نمونه های شکست محاسبه SAP 2000 شده توسط مدل	میانگین مربعات خطا	خطای محاسبه شاخص قابلیت اعتماد توسط مدل جایگزین
$R_1(X) - 1 \leq 0$	پیوسته	$400 \rightarrow \beta_1 = 3$	$400 \rightarrow \beta_1 = 3$	0%
	گسسته	$338 \rightarrow \beta_1 = 3.0505$	$338 \rightarrow \beta_1 = 3.0505$	0%
$R_2(X) - 1 \leq 0$	پیوسته	$370 \rightarrow \beta_2 = 3.0233$	$370 \rightarrow \beta_2 = \beta_2 = 3.0233$	0%
	گسسته	$190 \rightarrow \beta_2 = 3.2195$	$190 \rightarrow \beta_2 = 3.2195$	0%

همانگونه که در جدول ۵ نشان داده شده است، خطای محاسبه شاخص قابلیت اعتماد توسط مدل جایگزین پیشنهادی (نمونه های که توسط SAP 2000 ایمن تشخیص داده شده اند و مدل جایگزین آن ها را نایمن اعلام کرده است) در حالت پیوسته و گسسته برابر با صفر است. زمان مصرف شده به جهت ایجاد مدل جایگزین و پایگاه داده برابر با ۱۸۲۰ ثانیه است.

در حالت پیوسته زمان مصرف شده توسط الگوریتم جستجوی الگو و مدل جایگزین برابر با ۱۱۲ ثانیه و روش پیشنهادی در مجموع (زمان تولید پایگاه داده + مدل جایگزین + حل مساله) ۱۹۳۲ ثانیه (۳۲ دقیقه) زمان مصرف کرده است. حل مساله توسط مدل اصلی SAP 2000 و روش نمونه سازی ابر مکعب لاتین زمانی برابر با ۶۱۵۰۰ ثانیه (۱۷ ساعت) مصرف کرده است. روش پیشنهادی حدوداً ۳۲ برابر سریع تر عمل کرده است.


در حالت گسسته زمان مصرف شده توسط الگوریتم جستجوی الگو و مدل جایگزین برابر با ۹۱ ثانیه و روش پیشنهادی در مجموع (زمان تولید پایگاه داده + مدل جایگزین + حل مساله) ۱۹۱۱ ثانیه (۳۱ دقیقه) زمان مصرف کرده است. حل مساله توسط مدل

اصلی SAP 2000 و روش نمونه سازی ابر مکعب لاتین زمانی برابر با ۴۷۴۰۰ ثانیه (۱۳ ساعت) مصرف کرده است. روش پیشنهادی حدوداً ۲۵ برابر سریع تر عمل کرده است.


در این مثال در هر دو حالت گسسته و پیوسته الگوریتم ۲۰ بار اجرا شد و در بهترین نتیجه گزارش شده، نمودار همگرایی از تکرار ۳ تقریباً به حالت افقی در آمده و تا تکرار ۳۳ در حالت پیوسته و تکرار ۲۶ در حالت گسسته به حالت افقی باقی مانده است. بنا بر این الگوریتم به اندازه کافی فرصت برای یافتن نقطه بهینه داشته است.

۲-۶- چلیک دو لایه ۸۳۲ عضوی

در این مثال با استفاده از جعبه ابزار SM [۳۵] یک برنامه پارامتری برای ایجاد مدل اجزای محدود ایجاد شده است. با تعیین پارامترهای ورودی در این برنامه، مدل اجزای محدود به صورت خودکار تشکیل شده و وزن سازه و محدودیت های در نظر گرفته شده برای مساله محاسبه می شود. پارامترهای اصلی در شکل ۹ و شکل ۱۰ نمایش داده شده اند. جدول ۶ متغیرهای طراحی و متغیرهای تصادفی و همچنین ثوابت این مساله را تشریح کرده است.



شکل ۹: پارامترهای N_{Dx}, N_{Dy}, W_x, W_y




شکل ۱۰: پارامتر H_{Roof}

جدول ۶: ثوابت، متغیرهای طراحی و تصادفی در حل مساله چلیک دولایه

پارامتر	تعریف	نوع	توزیع	میانگین و واریانس
$X_1 (E)$	مدول الاستیسیته	متغیر تصادفی	لاگ نرمال	$\mu = 210 \times 10^3 \frac{N}{mm^2}$ $\sigma = 21 \times 10^3 \frac{N}{mm^2}$
$X_2 (F_y)$	تنش تسلیم	متغیر تصادفی	لاگ نرمال	$\mu = 335 \frac{N}{mm^2}$ $\sigma = 33.5 \frac{N}{mm^2}$
$X_3 (DL)$	بار مرده	متغیر تصادفی	لاگ نرمال	$\mu = 180 KN$ $\sigma = 20 KN$
$X_4 (SL)$	بار برف	متغیر تصادفی	لاگ نرمال	$\mu = 100 KN$ $\sigma = 10 KN$
$d_1 (H_{Roof})$	ضخامت چلیک	متغیر طراحی	یکنواخت گسسته	500 : 1 : 6000, mm
$d_2 (f)$	ارتفاع بالاترین نقطه سهموی	متغیر طراحی	یکنواخت گسسته	5000 : 1 : 6000, mm
$d_3 (D_{UL1})$	قطر مقاطع استفاده شده در لایه فوقانی، گروه ۱	متغیر طراحی	یکنواخت گسسته	50 : 1 : 450, mm
$d_4 (t_{UL1})$	ضخامت مقاطع استفاده شده در لایه فوقانی، گروه ۱	متغیر طراحی	یکنواخت گسسته	3 : 1 : 50, mm
$d_5 (D_{UL2})$	قطر مقاطع استفاده شده در لایه فوقانی، گروه ۲	متغیر طراحی	یکنواخت گسسته	50 : 1 : 450, mm

$d_6 (t_{UL2})$	ضخامت مقاطع استفاده شده در لایه فوقانی، گروه ۲	متغیر طراحی	یکنواخت گسسته	3:1:50, mm
$d_7 (D_{BR1})$	قطر مقاطع استفاده شده در بادبندی ها، گروه ۱	متغیر طراحی	یکنواخت گسسته	50:1:450, mm
$d_8 (t_{BR1})$	ضخامت مقاطع استفاده شده در بادبندی ها، گروه ۱	متغیر طراحی	یکنواخت گسسته	3:1:50, mm
$d_9 (D_{BR2})$	قطر مقاطع استفاده شده در بادبندی ها، گروه ۲	متغیر طراحی	یکنواخت گسسته	50:1:450, mm
$d_{10} (t_{BR2})$	ضخامت مقاطع استفاده شده در بادبندی ها، گروه ۲	متغیر طراحی	یکنواخت گسسته	3:1:50, mm
$d_{11} (D_{LL1})$	قطر مقاطع استفاده شده در لایه تحتانی، گروه ۱	متغیر طراحی	یکنواخت گسسته	50:1:450, mm
$d_{12} (t_{LL1})$	ضخامت مقاطع استفاده شده در لایه تحتانی، گروه ۱	متغیر طراحی	یکنواخت گسسته	3:1:50, mm
$d_{13} (D_{LL2})$	قطر مقاطع استفاده شده در لایه تحتانی، گروه ۲	متغیر طراحی	یکنواخت گسسته	50:1:450, mm
$d_{14} (t_{LL2})$	ضخامت مقاطع استفاده شده در لایه تحتانی، گروه ۲	متغیر طراحی	یکنواخت گسسته	3:1:50, mm
W_x	بعد زمین در جهت X	ثابت	-	70,000 mm
W_y	بعد زمین در جهت Y	ثابت	-	100,000 mm

تابع هدف برابر وزن خرپا در نظر گرفته شده است. برنامه تولید شده توسط جعبه ابزار SM [۳۵] به طور خودکار اعضای لایه های سقف را به اعضای جانبی و اعضای میانی گروه بندی می کند. این گروه بندی به گونه ای انجام می شود که تعداد اعضای گروه های کناری و میانی تقریباً برابر باشد (شکل ۱۱).



شکل ۱۱: گروه بندی اعضا های سازه

بازه تغییرات متغیر های طراحی مربوط به شبکه عصبی به صورت زیر در نظر گرفته شده است:

$$x_{1,ANW} \in \{1, 2, \dots, 4\} \quad (20)$$

$$x_{2,ANW} \in \{1, 2, \dots, 30\} \quad (21)$$

$$x_{3,ANW} \in \{1, 2, 3\} \quad (22)$$

قیود این مساله، بر اساس خروجی های SAP2000 به صورت زیر در نظر گرفته شده اند:

$$g_1(X) = \frac{\Phi(\beta_i)}{\text{Prob}\{R_1(X) - 1 \leq 0\}} - 1 \leq 0 \quad (23)$$

$$g_2(X) = \frac{\Phi(\beta_i)}{\text{Prob}\{R_2(X) - 1 \leq 0\}} - 1 \leq 0 \quad (24)$$


$$g_3(X) = \frac{\Phi(\beta_i)}{\text{Prob}\{R_3(X) - 1 \leq 0\}} - 1 \leq 0 \quad (25)$$

$$g_4(X) = \frac{\Phi(\beta_i)}{\text{Prob}\{R_4(X) - 1 \leq 0\}} - 1 \leq 0 \quad (26)$$

$$g_5(X) = \frac{\Phi(\beta_i)}{\text{Prob}\{R_5(X) - 1 \leq 0\}} - 1 \leq 0 \quad (27)$$

$$g_6(X) = \frac{\Phi(\beta_i)}{\text{Prob}\{R_6(X) - 1 \leq 0\}} - 1 \leq 0 \quad (28)$$

که در آن، $R_1(X)$ و $R_2(X)$ ، به ترتیب نشان دهنده ضرایب کنترل تنش یا ضرایب کنترل ظرفیت برای عناصر سازه در اعضای جانبی و میانی در لایه زیرین چلیک هستند. $R_3(X)$ و $R_4(X)$ ، نشان دهنده ضرایب کنترل تنش یا ظرفیت برای عناصر سازه در اعضای جانبی و میانی در اعضای مهاربندی، $R_5(X)$ و $R_6(X)$ ، به ترتیب نشان دهنده ضرایب کنترل تنش یا کنترل ظرفیت برای عناصر سازه در اعضای جانبی و میانی در لایه فوقانی چلیک هستند. از آیین نامه AISI360-05 تعریف شده در نرم افزار SAP2000 برای طراحی اعضای فولادی استفاده شده است. عملکرد شبکه عصبی جایگزین برای دستیابی به دقت مطلوب برابر $Prf_{all} = 0.01$ در نظر گرفته شده است. شبکه عصبی بهینه شده در شکل ۱۲ نشان داده شده است.




شکل ۱۲: شبکه عصبی بهینه شده برای حل مساله چلیک دولایه

شکل ۱۳ نشان دهنده رگرسیون شبکه عصبی بهینه شده هستند. اندازه پایگاه داده، برابر ۲۳۰۰ حاصل شده است. همچنین در جدول ۷، خطاهای مربوط به اعضای به کار رفته در آموزش، اعتبارسنجی و آزمون نمایش داده شده اند.

جدول ۷: خطای مدل جایگزین مربوط به مساله چلیک دولایه

نوع داده ها	میانگین مربعات خطا	میانگین مطلق خطا
داده های آموزش	0.00312	0.0327
داده های اعتبارسنجی	0.00534	0.0321
داده های آزمون	0.006411	0.066

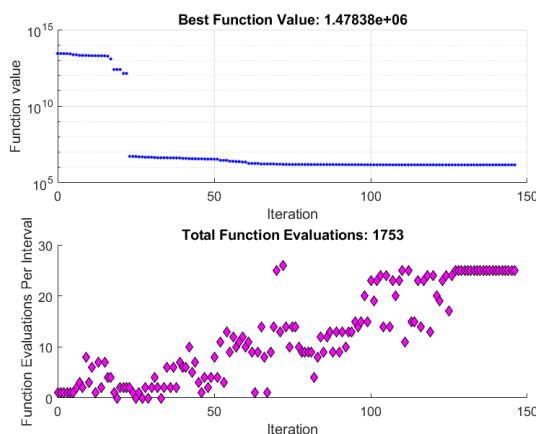
بر اساس نتایج ذکر شده در جدول ۷، مدل جایگزین پیشنهادی در تخمین قیود مساله توانمندی قابل قبولی دارد.



شکل ۱۳: رگرسیون شبکه عصبی بهینه شده چلیک دو لایه

مقدار خطاهای گزارش شده برای مدل جایگزین (جدول ۷) و همچنین ضریب همبستگی نزدیک به ۱ در داده های آموزشی، اعتبار سنجی، آزمایش، و کل داده ها (شکل ۱۳) نشان دهنده عملکرد خوب روش ارائه شده در حل مساله بهینه سازی تعریف شده برای دستیابی به مدل جایگزین بهینه (رابطه ۹) است.

در این مثال الگوریتم ۲۰ بار اجرا شد و بهترین نتیجه گزارش شده است. در شکل ۱۴، نمودار همگرایی مساله نشان داده شده است. همچنین در جدول ۸، متغیرهای بهینه و شاخص قابلیت هر یک از قیود نشان داده شده است.



شکل ۱۴: نمودار همگرایی (نیمه لگاریتمی) الگوریتم جستجوی الگو برای حل مساله چلیک دو لایه ۸۲۲ عضوی

زمان مصرف شده به جهت ایجاد مدل جایگزین و پایگاه داده برابر با ۵۰۶۰۰ ثانیه و تعداد فراخوانی تابع زمانبر برابر با ۲۳۰۰ بار است. زمان حل مساله توسط الگوریتم جستجوی الگو و مدل جایگزین ۱۱۵ ثانیه است. همچنین تعداد فراخوانی تابع هدف ۱۷۵۳ بار است. روش پیشنهادی در مجموع ۵۰۷۱۵ ثانیه (۱۴ ساعت) زمان برای حل مساله مصرف کرده است.

جدول ۸: متغیرهای بهینه، شاخص‌های قابلیت اعتماد برای مساله چلیک دولایه

پارامتر	مقدار	پارامتر	مقدار
$d_{1,opt} (H_{Roof})$	3722 (mm)	$d_{12,opt} (t_{LL1})$	8 (mm)
$d_{2,opt} (f)$	3001 (mm)	$d_{13,opt} (D_{LL2})$	58 (mm)
$d_{3,opt} (D_{UL1})$	171 (mm)	$d_{14,opt} (t_{LL2})$	4 (mm)
$d_{4,opt} (t_{UL1})$	12 (mm)	β_1	3.3584
$d_{5,opt} (D_{UL2})$	155 (mm)	β_2	8.1259
$d_{6,opt} (t_{UL2})$	11 (mm)	β_3	3.5792
$d_{7,opt} (D_{BR1})$	155 (mm)	β_4	4.0685
$d_{8,opt} (t_{BR1})$	12 (mm)	β_5	3.2756
$d_{9,opt} (D_{BR2})$	79 (mm)	β_6	3.4279
$d_{10,opt} (t_{BR2})$	3 (mm)	$W_{t,opt}$	$1.4784 \times 10^6 (N)$
$d_{11,opt} (D_{LL1})$	184 (mm)		

مطابق نتایج جدول ۸، قیود شماره ۱ و ۳ و ۵ و ۶ (روابط ۲۳ الی ۲۸) به مقدار شاخص هدف نزدیک شده‌اند. بایستی توجه شود که، متغیرهای طراحی گسسته‌اند. روش پیشنهادی توانسته ۴ قید از ۶ قید مساله را به شاخص هدف نزدیک سازد.

در این مثال الگوریتم ۲۰ بار اجرا شد و در بهترین نتیجه، نمودار همگرایی از تکرار ۲۳ تقریباً به حالت افقی در آمده و تا تکرار ۱۴۶ حالت افقی باقی مانده است. بنابراین الگوریتم به اندازه کافی فرصت برای یافتن نقطه بهینه داشته است.

نتیجه گیری

در این تحقیق، یک روش مبتنی بر مدل جایگزین شبکه عصبی برای حل مسائل بهینه سازی مبتنی بر قابلیت اعتماد ارائه شده است. ایده اصلی یافتن مدل جایگزینی است که در فضای متغیرها به اندازه کافی تعمیم یافته باشد و همچنین در فرایند آموزش دچار پدیده بیش برازش نشده باشد. برای نشان دادن اثر بخشی روش ارائه شده، دو مثال عددی در نظر گرفته شده‌اند. در مثال نخست، یک خرابی ۱۰ عضوی دو بعدی و در مثال دوم، یک چلیک دو لایه ۸۳۲ عضوی مورد بررسی قرار گرفته‌اند. با توجه به مثال‌های حل شده می‌توان نتایج زیر را در نظر گرفت:

۱. در هر دو مثال، مدل جایگزین به دست آمده از روش پیشنهاد شده عملکرد مورد نظر در داده‌های اعتبار سنجی و آزمون را تامین کرده است.
۲. در هر دو مثال، ضریب همبستگی خطی بین خروجی‌های مدل جایگزین و مقادیر خروجی در پایگاه داده در داده‌های اعتبار سنجی و آزمون نزدیک به ۱ است.
۳. الگوریتم پیشنهادی قیود مساله را به شاخص هدف به خوبی نزدیک کرده است.
۴. در مثال نخست، خطای محاسبه شاخص قابلیت اعتماد توسط مدل جایگزین پیشنهادی (نمونه‌های که توسط SAP 2000 ایمن تشخیص داده شده‌اند و مدل جایگزین آن‌ها را نایمن اعلام کرده است) در حالت پیوسته و گسسته برابر با صفر است.
۵. در مثال نخست، روش پیشنهادی حدوداً ۳۲ برابر در حالت پیوسته و ۲۵ برابر در حالت گسسته سریع‌تر عمل کرده است. (نسبت به حل مساله با مدل اصلی SAP 2000 و روش ابر مکعب لاتین).

مراجع

- [1] Li F, Liu J, Wen G, Rong J. (2019). Extending SORA method for reliability-based design optimization using probability and convex set mixed models. *Struct Multidiscip Optim* ;59:1163–79. <https://doi.org/10.1007/s00158-018-2120-2>.
- [2] Haftka RT, Gurdal Z. (1992). *Elements of Structural Optimization: Third Edition (Google eBook)*. Springer Science & Business Media;
- [3] Shobeiri V, Ahmadi-Nedushan B. (2017). Bi-directional evolutionary structural optimization for strut-and-tie modelling of three-dimensional structural concrete. *Eng Optim* ;49:2055–78. <https://doi.org/10.1080/0305215X.2017.1292382>.
- [4] Fathnejat H, Ahmadi-Nedushan B. (2020). An efficient two-stage approach for structural damage detection using meta-heuristic algorithms and group method of data handling surrogate model. *Front Struct Civ Eng* ;14:907–29. <https://doi.org/10.1007/s11709-020-0628-1>.
- [5] Ahmadi-Nedushan B, Varaee H. (2009). Optimal Design of Reinforced Concrete Retaining Walls using a Swarm Intelligence Technique. Proc First Int Conf Soft Comput Technol Civil, *Struct Environ Eng* ;92. <https://doi.org/10.4203/ccp.92.26>.
- [6] Shakiba M, Ahmadi-Nedushan B. (2009). Engineering Optimization using Opposition Based Differential Evolution. Proc First Int Conf Soft Comput Technol Civil, *Struct Environ Eng* ;92. <https://doi.org/10.4203/ccp.92.23>.
- [7] Ahmadi-Nedushan B, Varaee H. (2011). Minimum cost design of concrete slabs using particle swarm optimization with time varying acceleration coefficients. *World Appl Sci J* ;13:2484–94.
- [8] Mohaddese S, VahidReza K, Pahlavan H. (2022). Optimization of Single-Objective and Multi-Objective Special Truss Moment Frame Using Island Genetic Algorithm. *J Struct Constr Eng* ;8:124–42. <https://doi.org/10.22065/JSCE.2021.257179.2290>.
- [9] Abbas K, Kiani A, Seraji M, Dashti H. (2022). Optimization of structure using hybrid Harris hawks and genetic algorithm. *J Struct Constr Eng* . <https://doi.org/10.22065/JSCE.2022.338161.2788>.
- [10] Arani AS, Ahmadi-Nedushan B, Bondarabadi HA. (2017). Optimal Design of Curved Portal Frame with Consideration of Stressed Skin Action Using the Equivalent Spring Theory. *J Struct Constr Eng*. <https://doi.org/10.22065/JSCE.2017.91588.1261>.
- [11] Chen X, Hasselman TK, Neill DJ. (1997). Reliability based structural design optimization for practical applications. Collect Tech Pap - AIAA/ASME/ASCE/AHS/ASC .In: *Struct Dyn Mater Conf* ;4:2724–32. <https://doi.org/10.2514/6.1997-1403>.
- [12] Du X, Chen W. (2002). Sequential optimization and reliability assessment method for efficient probabilistic design. In: *Proc ASME Des Eng Tech Conf* ;2:871–80. <https://doi.org/10.1115/detc2002/dac-34127>.
- [13] Wang P, Hu C, Youn BD. (2011). A generalized complementary intersection method (GCIM) for system reliability analysis. *J Mech Des Trans ASME*;133. <https://doi.org/10.1115/1.4004198>.
- [14] B.D Y, K.K C, L D. (2005). Adaptive probability analysis using an enhanced hybrid mean value method. *Struct Multidiscip Optim* ;29:134–48.
- [15] Liu J, Wen G, Xie YM. (2016). Layout optimization of continuum structures considering the probabilistic and fuzzy directional uncertainty of applied loads based on the cloud model. *Struct Multidiscip Optim* ;53:81–100. <https://doi.org/10.1007/s00158-015-1334-9>.
- [16] Liu J, Wen G. (2018). Continuum topology optimization considering uncertainties in load locations based on the cloud model. *Eng Optim* ;50:1041–60. <https://doi.org/10.1080/0305215X.2017.1361417>.
- [17] Irani H, Kalatjari VR, Dibaei Bonab M. (2013). Reliability Assessment of Three-dimensional Moment Resisting Frames Designed According to the Iranian National Building Code, Part 10: *Steel Structures*, 2008 and 2013 Editions. *J Struct Constr Eng* 2021;8:173–90. <https://doi.org/10.22065/jsce.2020.185303.1858>.
- [18] Fan L, Teresa W, Adedeji B, Mengqi H, Som S. (2013). A single-loop deterministic method for reliability-based design optimization. *Eng Optim* ;45:435–58.
- [19] Chen Z, Qiu H, Gao L, Su L, Li P. (2013). An adaptive decoupling approach for reliability-based design optimization. *Comput Struct* ;117:58–66. <https://doi.org/10.1016/j.compstruc.2012.12.001>.
- [20] Valdebenito MA, Schuëller GI. (2010). A survey on approaches for reliability-based optimization. *Struct Multidiscip Optim* ;42:645–63. <https://doi.org/10.1007/s00158-010-0518-6>.
- [21] Du X, Sudjianto A, Chen W. (2004). An integrated framework for optimization under uncertainty using inverse reliability strategy. *J Mech Des Trans ASME* ;126:562–70. <https://doi.org/10.1115/1.1759358>.
- [22] Du X, Guo J, Beeram H. (2008). Sequential optimization and reliability assessment for multidisciplinary systems design. *Struct Multidiscip Optim* ;35:117–30. <https://doi.org/10.1007/s00158-007-0121-7>.
- [23] Du X, Chen W. (2004). Sequential optimization and reliability assessment method for efficient probabilistic design. *J Mech Des Trans ASME* ;126:225–33. <https://doi.org/10.1115/1.1649968>.
- [24] Ho-Huu V, Nguyen-Thoi T, Le-Anh L, Nguyen-Trang T. (2016). An effective reliability-based improved

- constrained differential evolution for reliability-based design optimization of truss structures. *Adv Eng Softw* ;92:48–56. <https://doi.org/10.1016/j.advengsoft.2015.11.001>.
- [25] Khodam A, Farajzadeh MS, Shayanfar MA. (2021). Reliability-Based Design Optimization of Structures using Firefly Algorithm. *J Struct Constr Eng* ;8:333–44. <https://doi.org/10.22065/jsce.2020.203929.1962>.
- [26] Kaveh A, Ghazaan MI. (2015). Structural reliability assessment utilizing four metaheuristic algorithms. *Int J Optim Civ Eng* ;5:205–25.
- [27] Gholizadeh S, Aligholizadeh V. (2019). Reliability-based optimum seismic design of RC frames by a metamodel and metaheuristics. *Struct Des Tall Spec Build* ;28. <https://doi.org/10.1002/tal.1552>.
- [28] Papadrakakis M, Lagaros ND. (2002). Reliability-based structural optimization using neural networks and Monte Carlo simulation. *Comput Methods Appl Mech Eng* ;191:3491–507. [https://doi.org/10.1016/S0045-7825\(02\)00287-6](https://doi.org/10.1016/S0045-7825(02)00287-6).
- [29] Liu Y, Lu N, Yin X. (2016). A Hybrid Method for Structural System Reliability-Based Design Optimization and its Application to Trusses. *Qual Reliab Eng Int* ;32:595–608. <https://doi.org/10.1002/qre.1775>.
- [30] Kaveh A, Gholipour Y, Rahami H. (2008). Optimal design of transmission towers using genetic algorithm and neural networks. *Int J Sp Struct*;23:1–19. <https://doi.org/10.1260/026635108785342073>.
- [31] Taheri F, Ghasemi MR, Dizangian B. (2020) Practical optimization of power transmission towers using the RBF-based ABC algorithm. *Struct Eng Mech* ;73:463–79. <https://doi.org/10.12989/sem.2020.73.4.463>.
- [32] Nguyen TH, Vu AT. (2022). Speeding up Composite Differential Evolution for structural optimization using neural networks. *J Inf Telecommun*;6:101–20. <https://doi.org/10.1080/24751839.2021.1946740>.
- [33] Papadrakakis M, Lagaros ND, Tsompanakis Y. (1998). Structural optimization using evolution strategies and neural networks. *Comput Methods Appl Mech Eng*;156:309–33. [https://doi.org/10.1016/S0045-7825\(97\)00215-6](https://doi.org/10.1016/S0045-7825(97)00215-6).
- [34] Lagaros ND, Papadrakakis M. (2012). Applied soft computing for optimum design of structures. *Struct Multidiscip Optim* ;45:787–99. <https://doi.org/10.1007/s00158-011-0741-9>.
- [35] Javanmardi R, Ahmadi-Nedushan B. (2021). Cost Optimization of Steel-Concrete Composite I- Girder Bridges With Skew Angle and Longitudinal Slope , Using the SM Toolbox and the Parallel Pattern Search Algorithm. *Int J Optim Civ Eng*;11:357–82.
- [36] Csi computers & structures.Inc <https://www.csiamerica.com/>.
- [37] Ahmadi Nedushan B, Chouinard LE. (2003). Use of artificial neural networks for real time analysis of dam monitoring data. *Proceedings, Annu Conf - Can Soc Civ Eng*;2003:1987–94.
- [38] Ahmadi-Nedushan B. (2012). Prediction of elastic modulus of normal and high strength concrete using ANFIS and optimal nonlinear regression models. *Constr Build Mater*;36:665–73. <https://doi.org/10.1016/j.conbuildmat.2012.06.002>.
- [39] Deng J, Gu D, Li X, Yue ZQ. (2005). Structural reliability analysis for implicit performance functions using artificial neural network. *Struct Saf* ;27:25–48. <https://doi.org/10.1016/j.strusafe.2004.03.004>.
- [40] Mukhopadhyay A, Iqbal A. (2006). Comparison of ANN and MARS in prediction of property of steel strips. *Adv Soft Comput*;34:329–41. https://doi.org/10.1007/3-540-31662-0_26.
- [41] Shahani AR, Setayeshi S, Nodamaie SA, Asadi MA, Rezaie S. (2009). Prediction of influence parameters on the hot rolling process using finite element method and neural network. *J Mater Process Technol*;209:1920–35. <https://doi.org/10.1016/j.jmatprotec.2008.04.055>.
- [42] Moodi Y, Eslami E, Mousavi SR, Dizangian B, Mirshekar H. (2022). Applying neural networks for estimating the compressive strength of confined circular concrete columns with FRP sheets. *J Struct Constr Eng* ;9. <https://doi.org/10.22065/jsce.2021.178649.1825>.
- [43] Fathi A, Peyman F. (2021). Combining Neural Network Models to Prediction the Bond Strength of Glass FRP to Concrete. *J Struct Constr Eng*;8:313–32. <https://doi.org/10.22065/jsce.2020.216063.2051>.
- [44] Labibzadeh M, Dadak M. (2019). Determining of Load Bearing Capacity of Rectangular Concrete Columns Reinforced with Longitudinal Spirals Using FEM and ANN Methods. *J Struct Constr Eng* ;6:157–76. <https://doi.org/10.22065/jsce.2018.101469.1351>.
- [45] Nguyen TH, Vu AT. (2020). Using Neural Networks as Surrogate Models in Differential Evolution Optimization of Truss Structures. *Lect Notes Comput Sci (Including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)*;12496 LNAI:152–63. https://doi.org/10.1007/978-3-030-63007-2_12.
- [46] Booker AJ, Dennis JE, Frank PD, Serafini DB, Torczon V, Trosset MW. (1999). A rigorous framework for optimization of expensive functions by surrogates. *Struct Optim*;17:1–13. <https://doi.org/10.1007/BF01197708>.
- [47] The Mathworks Inc. (2012). Matlab documentation. Matlab :R2012b.
- [48] Nowak AS, Kevin R C. (2012). *Reliability of Structures*. CRC press;
- [49] The Mathworks Inc. (2019). Matlab documentation. Matlab :R2019b.
- [50] The joint committee on structural safety. vol. 11. 1992. [https://doi.org/10.1016/0167-4730\(92\)90025-i](https://doi.org/10.1016/0167-4730(92)90025-i).
- [51] Hu Z, Du X. (2015). A random field approach to reliability analysis with random and interval variables. *ASCE-*

- ASME J Risk Uncertain Eng Syst Part B Mech Eng*;1. <https://doi.org/10.1115/1.4030437>.
- [52] Wang L, Wang X, Wang R, Chen X. (2016). Reliability-based design optimization under mixture of random, interval and convex uncertainties. *Arch Appl Mech* ;86:1341–67. <https://doi.org/10.1007/s00419-016-1121-0>.