

Accurate estimation of shear strength of deep reinforced concrete beams using meta-heuristic methods

Hamid Reza Rabieifar*¹, Alireza Shahbazian², Babak Aminnejad³

1- Associate Professor, Department. of Civil Engineering, Kish International Branch, Islamic Azad University, Kish Island, Iran

2- PhD student Department. of Civil Engineering, Kish International Branch, Islamic Azad University, Kish Island, Iran

3- Associate Professor, Department. of Civil Engineering, Kish International Branch, Islamic Azad University, Kish Island, Iran

ABSTRACT

Shear force is one of the most important influencing forces of structural beams and especially unreinforced deep concrete beams that cause sudden failure and sudden collapse of the structure and for this reason, it is of interest to designers and implementers of structures. The study of the conducted research shows that the proposed methods including the use of artificial neural network cannot predict Provide an accurate description of the behavior of deep reinforced concrete beams against shear force. This research, while specifying the cause of the error of the artificial neural network in estimating the shear strength of deep reinforced concrete beams, presents a solution to achieve accurate results by optimizing the artificial neural network by the meta-heuristic algorithm of particle swarm. For this purpose, 309 laboratory samples of deep concrete beams were collected from the research literature and the particle swarm algorithm was used to optimize the weights in the artificial neural network using MATLAB software. The comparison of the results of this method with the results of these letters and other existing methods that were examined in this research showed that the use of the combination of particle swarm algorithm and optimized artificial neural network to estimate the shear strength of unreinforced deep reinforced concrete beams provides more accurate answers.

ARTICLE INFO

Receive Date: 13 March 2023

Revise Date: 13 May 2023

Accept Date: 08 July 2023

Keywords:

Shear strength
Deep beam
particle swarm
Artificial neural network
Meta heuristic method

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://doi.org/10.22065/jsce.2023.386744.3047>

*Corresponding author: Hamid Reza Rabieifar

Email address: h_rabieifar@azad.ac.ir

تخمین دقیق مقاومت برشی تیرهای بتنی مسلح عمیق با استفاده از ترکیب روش های فرا ابتکاری

علیرضا شهبازیان^۱، حمید رضا ربیعی فر^{۲*}، بابک امین نژاد^۳

۱- دانشجوی دکترا، دانشکده مهندسی عمران، دانشگاه آزاد اسلامی بین المللی کیش، جزیره کیش، ایران

۲- استادیار، دانشکده مهندسی عمران، دانشگاه آزاد اسلامی بین المللی کیش، جزیره کیش، ایران

۳- استادیار، دانشکده مهندسی عمران، دانشگاه آزاد اسلامی بین المللی کیش، جزیره کیش، ایران

چکیده

از مهمترین نیروهای تاثیرگذار برالمانهای سازه ای و بویژه تیرهای بتنی مسلح عمیق مقاوم سازی نشده که موجب شکست آنی و ریزش ناگهانی سازه می شود، نیروی برشی است و به همین جهت مورد دغدغه طراحان و مجریان سازه ها می باشد. مطالعه تحقیقات انجام شده نشان داد، روش های ارائه شده، منجمله استفاده از شبکه عصبی مصنوعی، نمی توانند پیش بینی دقیقی را از رفتار تیرهای عمیق بتنی مسلح در برابر نیروی برشی، ارائه نمایند. این تحقیق، ضمن مشخص نمودن علت خطای شبکه عصبی مصنوعی در تخمین مقاومت برشی تیرهای بتن مسلح عمیق، راهکار دستیابی به نتایج دقیق تر را، با بهینه سازی شبکه عصبی مصنوعی بوسیله الگوریتم فراابتکاری ازدحام ذرات ارائه می دهد. بدین منظور ۳۰۹ نمونه آزمایشگاهی تیرهای بتنی عمیق از ادبیات تحقیق جمع اوری شد و الگوریتم ازدحام ذرات برای بهینه سازی وزن ها در شبکه عصبی مصنوعی با استفاده از نرم افزار متلب مورد استفاده قرار گرفت. مقایسه نتایج حاصل از این روش با نتایج حاصل از این نامه ها و سایر روش های موجود که در این تحقیق مورد بررسی قرار گرفتند نشان داد، استفاده از ترکیب الگوریتم ازدحام ذرات و شبکه عصبی مصنوعی بهینه شده، جهت تخمین مقاومت برشی تیرهای بتنی مسلح عمیق مقاوم سازی نشده، پاسخ های دقیق تری را ارائه میدهد.

کلمات کلیدی: مقاومت برشی، تیر عمیق، ازدحام ذرات، شبکه عصبی مصنوعی، روش های فرا ابتکاری.

شناسه دیجیتال:		سابقه مقاله:				
doi:	https://doi.org/10.22065/jsce.2023.386744.3047	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت
	10.22065/jsce.2023.386744.3047	۱۴۰۳/۰۱/۳۱	۱۴۰۲/۰۴/۱۷	۱۴۰۲/۰۴/۱۷	۱۴۰۲/۰۲/۲۳	۱۴۰۱/۱۲/۲۲
حمیدرضا ربیعی فر h_rabieifar@azad.ac.ir				*نویسنده مسئول: پست الکترونیکی:		

۱- مقدمه

گسست و فروریزش سازه ها در اثر نیروی برشی، یکی از دغدغه های طراحان و مجریان سازه ها است. اهمیت نیروی برشی و لزوم کنترل مقاومت المان های سازه ای در برابر آن از آن جا ناشی میشود که این نیرو برخلاف غالب نیروهای مؤثر بر سازه (همچون نیروی خمشی)، بدون هرگونه هشدار دهی و علامت، منجر به فروریزش آنی سازه میشود.

تیرهای عمیق بتنی مسلح، بدلیل هندسه ی خاص خود، از حساس ترین اعضای سازه ای در برابر این نیرو هستند و این موضوع، لزوم دستیابی به یک روش قابل اعتماد و ارزان برای تخمین مقاومت اینگونه اعضای سازه در برابر نیروی مذکور را نمایان می سازد. روش مرسوم استفاده از آزمایشگاه، بدلیل زمان بر و پرهزینه بودن و دسترسی محدود به آزمایشگاههای معتبر، نمی تواند راهکار مناسبی باشد و از این رو، محققین، استفاده از روش های ابتکاری و فرا ابتکاری همچون شبکه های عصبی مصنوعی و الگوریتم های بهینه سازی را بدلیل پتانسیل و قابلیت های خوب آن توصیه کردند که تاریخچه برخی از موارد نحوه بکار گیری آنها در حل مسایل مهندسی عمران، ذیلا آمده است.

در اواخر سال ۱۹۶۱، به منظور تخمین مقامت برشی تیرهای عمیق بتنی، یک برنامه ی گسترده ی بلند مدت توسط کنگ^۱ آغاز شد و هنوز هم در دانشگاه نیوکاسل ادامه دارد. آزمون ها، تا کنون روی بیش از ۴۹۱ تیر عمیق، که بزرگترین نمونه شامل وزن ۵.۴ تن و نمونه ی لاغر، با نسبت B/H (ارتفاع / ضخامت) تا ۶۷، انجام شده است. کنگ و شارپ^۲ در سال ۱۹۷۳ روی مودهای شکست و مقاومت تیرهای عمیق گزارشی را تهیه و بار نهائی را پیش بینی کردند. ایشان، ظرفیت برشی یک تیر عمیق بتنی مسلح را با حداکثر نیروی برشی که می تواند توسط مقطع بحرانی تحمل شود تعریف نمودند و ارماتور برشی را برای آن بخش از نیروی برشی که نمی تواند به تنهایی توسط بتن تحمل شود در نظر گرفتند [۱]. آدیکاری^۳ و همکاران به پیش بینی مقاومت برشی نهایی تیرهای عمیق بتن مسلح با مقطع متغیر توسط شبکه های عصبی مصنوعی پرداختند. آنها در این مقاله انواع مختلفی از این تیرها را توسط نرم افزار های انسیس و آباکوس طراحی و تحلیل نمودند و شبکه عصبی مصنوعی با توجه به نتایج حاصل از تحلیل تیرها در این دو نرم افزار و همچنین داده های موجود از آزمایشهای محققین دیگر آموزش داده شد و در نهایت مقاومت برشی نهایی این نمونه از تیرها را توسط شبکه عصبی مصنوعی پیش بینی کردند [۲]. علی و همکاران، به ارایه مدل شبکه عصبی برای تخمین سهم الیاف پلیمری مقاوم سازی شده (FRP^۴) در افزایش ظرفیت برشی تیر بتنی مقاوم سازی شده با FRP پرداختند [۳]. امانی و همکاران به تخمین مقاومت برشی نهایی تیرهای بتن آرمه مسلح به الیاف پلیمری با استفاده از شبکه عصبی پرداختند. مقایسه روابط آیین نامه بتن ایران و امریکا با مدل ارایه شده، نشان می دهد که در مجموع، استفاده از این مدل، از قدرت پیش بینی به مراتب بهتری نسبت به آیین نامه های تجربی برخوردار است [۴]. ارمغانی و همکاران به پیش بینی ظرفیت برشی تیرهای بتن آرمه تقویت شده توسط FRP به روش شبکه های عصبی مصنوعی پرداختند. شبکه عصبی مصنوعی (ANN)^۵ با پرسپترون چندلایه و الگوریتم پس انتشارخطا برای پیش بینی مقاومت برشی مورد استفاده قرار گرفت. نتایج نشان داد در مجموع ANN از قدرت پیش بینی به مراتب بهتر و قویتری نسبت به معادلات و آیین نامه های تجربی موجود برخوردار است [۵]. آتشیپاز، توانست با استفاده از الگوریتم جستجوی ارگانیسم های همزیست، به طراحی بهینه قابهای بتن آرمه با در نظر گرفتن تغییر شکل غیرخطی مواد دست یابد [۶]. بنچیک^۶ و همکاران به طراحی بهینه ی دالهای بتنی یکطرفه با استفاده از الگوریتم جستجوی همزیستی جانداران پرداختند. ایشان از الگوریتم همزیستی، که یکی از جدیدترین روش ها برای حل مسائل بهینه سازی است، استفاده کردند [۷]. کلادرا^۷ و همکاران روش طراحی برشی برای تیرهای بتونی نرمال و با استحکام بالا با استفاده از شبکه های عصبی مصنوعی را پیشنهاد کردند. آنها یک شبکه عصبی مصنوعی برای پیش بینی مقاومت برشی تیرهای تقویت شده ایجاد نمودند و بر اساس نتایج آن، یک مطالعه پارامتری برای تعیین تأثیر هر پارامتر مؤثر بر مقاومت برشی تیرهای بدون تقویت انجام دادند. سرانجام، روش جدیدی برای طراحی تیرهای بتونی مسلح با استحکام بالا و

1 Kong

2 Kong and Sharp

3 Adhikary

4 Fiber Reinforced Polymer

5 Artificial neural network

6 Ben chik


7 Cladera

بدون آرماتور برشی پیشنهاد دادند [۸]. دیاس^۸ و همکاران به کاربرد شبکه های عصبی مصنوعی برای پیش بینی مقاومت برشی نهایی تیرهای بتنی ساده با آرماتورهای عرضی پرداختند. آنها از داده های تست ۱۷۶ نمونه تیر بتنی که از مقالات دیگر جمع آوری شده است استفاده نمودند. داده های به کار رفته شامل نه پارامتر ورودی بود. نتایج نشان داد که شبکه های عصبی، پتانسیل قوی به عنوان ابزاری برای پیش بینی مقاومت برشی نهایی تیرهای بتن مسلح^۹ (RC) با تقویت عرضی در محدوده پارامترهای ورودی دارد [۹]. فروش^{۱۰} و همکاران به پیش بینی "مقاومت برشی نهایی تیرهای عمیق بتن مسلح با مقطع متغیر توسط شبکه های عصبی مصنوعی" پرداختند. آنها در این مقاله انواع مختلفی از این تیرها را توسط نرم افزارهای انسیس و آباکوس طراحی و تحلیل نمودند و شبکه عصبی مصنوعی با توجه به نتایج حاصل از تحلیل تیرها در این دو نرم افزار و همچنین داده های موجود از آزمایشهای محققین دیگر، آموزش داده شد و در نهایت مقاومت برشی نهایی این نمونه از تیرها را توسط شبکه عصبی مصنوعی پیش بینی کردند [۱۰]. یو^{۱۱} و همکاران، به ارایه "مدل شبکه عصبی برای تخمین سهم FRP در افزایش ظرفیت برشی تیر بتنی مقاومسازی شده با FRP" پرداختند. آنها در این مقاله با بررسی مطالعات و استانداردهای موجود در زمینه مقاوم سازی سازه ها با استفاده از FRP، پارامترهای موثر بر سهم برشی FRP را استخراج نمودند و با استناد به این پارامترها و داده های موجود در مطالعات پیشین، مدلی با استفاده از شبکه های عصبی مصنوعی ارایه کردند که خروجی این مدل، سهم برشی FRP در تیرهای بتنی می باشد [۱۱]. پاسوس^{۱۲} و همکاران به "تخمین مقاومت برشی نهایی تیرهای بتن آرمه مسلح به الیاف پلیمری با استفاده از شبکه عصبی" پرداختند. آنها در این تحقیق، یک پایگاه داده متشکل از ۱۰۳ تیر بتن آرمه از نتایج تجزیه و تحلیل مقالات، بمنظور ارزیابی رفتار برشی تیر بتنی ایجاد نمودند. متغیرهای ورودی شبکه عصبی شامل ۹ متغیر دربرگیرنده مشخصات هندسی مقطع، میزان آرماتور، میزان الیاف پلیمری، مشخصات مصالح بتن و فولاد و الیاف پلیمری است و متغیر خروجی، مقاومت برشی تیر است. مقایسه روابط آیین نامه بتن ایران و امریکا با مدل ارایه شده، نشان می دهد که در مجموع، استفاده از این مدل، از قدرت پیش بینی به مراتب بهتری نسبت به آیین نامه های تجربی برخوردار است [۱۲]. پال و همکاران، به "طراحی بهینه قابهای بتن آرمه با در نظر گرفتن تغییر شکل غیرخطی مواد با استفاده از الگوریتم جستجوی ارگانیکس های همزیست" پرداختند. آنها در این تحقیق مجموعه ای از پارامترهای طراحی شامل اندازه مقطع عرضی میلگرد ها، تعداد و قطر میلگردها و پایه های بتن و تقویت کننده تهیه نمودند. برای بهینه سازی، از الگوریتم جستجوی ارگانیکس های همزیست استفاده شده است. این الگوریتم به هیچ پارامتر تنظیمی خاص نیاز ندارد، که میتواند مهمترین مزیت نسبت به دیگر الگوریتم ها باشد. [۱۳]. پاستور و همکاران، "مدل سازی مقاومت برشی مبتنی بر رگرسیون بردار پشتیبانی از تیرهای عمیق" را ارایه نمودند. آنها در این تحقیق برای تیرهای عمیق پیش ساخته از یک رابطه تجربی جهت مقایسه استفاده نمودند. نتایج حاکی از عملکرد بهتر SVR از نظر قابلیت پیش بینی در مقایسه با روابط تجربی و شبکه عصبی پس انتشار است. مطالعات پارامتری با SVR اهمیت مقاومت استوانه بتونی و نسبت دهانه برشی به عمق موثر تیر بر پیش بینی مقاومت تیرهای عمیق را نشان داد [۱۴]. محمد و همکاران به "پیش بینی مقاومت برشی تیر بتن مسلح با فیبر فولادی با استفاده از مدل های هوش هیبریدی" بعنوان یک رویکرد جدید پرداختند. [۱۵].


خلا تحقیقات قبلی در خصوص کاربرد هوش مصنوعی والگوریتمها در مهندسی عمران، را میتوان چنین عنوان نمود که اگرچه استفاده از الگوریتم ها و روش های فرا ابتکاری، برای تخمین مقاومت المانهای سازه ای و نیز طراحی و بهینه سازی اجزا و ساختار سازه، تا حد زیادی توانسته جایگزین روش های قدیمی تر مانند استفاده از روش های آزمایشگاهی و محاسباتی گردد در برخی موارد، پاسخ های قابل قبولی ارایه نماید ولی عدم ارایه یک روش و راهکار ویژه برای تخمین دقیق مقاومت برشی تیرهای عمیق بتن مسلح مقاوم سازی نشده که از حساسترین اجزای سازه ای بشمار می روند، این تحقیقات را ناتمام گذارده است. گرچه در برخی مطالعات، مانند آنچه که ارمغانی^{۱۳} و همکاران (۲۰۱۹) و امانی و همکاران (۲۰۱۲) و کلادرا و همکاران (۲۰۰۴) و برخی دیگر از محققین انجام دادند، روش های ساده ای مانند

8 Dias
9 Reinforced concrete
10 Frosh
11 YUO
12 passos
13 Armaghani

استفاده از محاسبات نرم و نیز استفاده از شبکه عصبی مصنوعی ارایه گردید، لکن علیرغم خوب بودن نتایج در مورد تیرهای معمولی بتن مسلح، این موضوع در خصوص تیرهای عمیق بتن مسلح صادق نبوده و پاسخ روش های مذکور دارای خطای قابل توجهی بودند. برای اثبات این موضوع، یک شبکه ANN با استفاده از ۳۰۹ نمونه ی جمع آوری شده از ۱۷ مقاله معتبر [۳۲-۱۶]، و انتخاب بهترین ساختار از میان ۱۰۹ ساختار مختلف (براساس کمترین میزان خطا و بیشترین مقدار ضریب تعیین) شامل ۹ ورودی در لایه اول و ۱۷ گره در یک لایه پنهان، با استفاده از نرم افزار متلب^{۱۴}، مورد آموزش و آزمون قرار گرفت. مقادیر بدست آمده برای مقاومت برشی نمونه های مورد استفاده در این روش، در مقایسه با نتایج واقعی آزمایشگاهی در شکل (۱) و (۲)، نشان داده شده است. نرم افزار متلب، ضریب تعیین (R^2) در ساختار برگزیده ی ANN را در مرحله آموزش ۰/۸۵٪ و در مرحله آزمون ۰/۸۱٪ نشان داد که دقت قابل قبولی نیست. در این تحقیق به یافتن علت خطای ANN و ارایه یک روش برای تخمین دقیق مقاومت برشی تیر بتن مسلح عمیق پرداخته شد. و این موضوعی است که علیرغم اهمیت زیاد، انچنانکه باید، بدان پرداخته نشده است.



شکل ۱: مقایسه نتایج آزمایشگاهی مقاومت برشی تیر عمیق بتنی مسلح با نتایج ANN در مرحله آموزش (خروجی نرم افزار متلب).



شکل ۲: مقایسه نتایج آزمایشگاهی مقاومت برشی تیر عمیق بتنی مسلح با نتایج ANN در مرحله آزمون (خروجی نرم افزار متلب).

با توجه به وجود عوامل (پارامترهای) مختلف که بر ظرفیت برشی یک تیر بتنی عمیق تاثیر می گذارند، یک فرضیه برای علت خطای ANN، عدم توانایی آن در تعیین میزان دقیق اثر گذاری هر یک از عوامل اثر گذار بود. اما این که میزان اثر گذاری عوامل موثر بر ظرفیت برشی تیر بتنی، تا چه حد بایکدیگر متفاوتند و اصولاً آیا تفاوت معناداری در میزان اثر گذاری آنها با یکدیگر هست یا خیر، نیازمند

تحلیل حساسیت بود. جهت تحلیل حساسیت پارامترها با استفاده از الگوریتم GST و تخمین مقاومت برشی تیرهای بتنی عمیق مسلح با استفاده از الگوریتم های ذکر شده در بخش ۳، از داده های تجربی ۳۰۹ تیر بتن مسلح که دارای آرماتور برشی بودند و همچنانکه ذکر گردید از ۱۷ مقاله معتبر استخراج شدند، بهره گرفته شد.

بررسی مقالات متعددد و آیین نامه های معتبر، نشان داد که ۹ پارامتر، تعیین کننده ی اصلی میزان مقاومت برشی در یک تیر عمیق بتن مسلح می باشند که در شکل ۳ نشان داده شده است. پارامترها عبارتند از: دهانه برش (a)، طول مؤثر تیر (L)، عمق مؤثر (d)، عرض مقطع (bw)، مقاومت فشاری ۲۸ روزه بتن سیلندری نمونه ۳۰٪ * ۵ ۱ آمریکایی (f_c)، تنش تسلیم آرماتورهای طولی (f_{yt}) تنش تسلیم آرماتورهای عرضی (f_{yt})، درصد آرماتور طولی (ρ_l) و درصد آرماتورهای برشی (ρ_t) ۹ پارامتر ذکر شده، به عنوان ورودی در هر یک از الگوریتم های تشریح شده در بخش سوم استفاده شدند و مقدار ظرفیت برشی تیرهای بتن مسلح عمیق نیز به عنوان خروجی این سیستم ها بودند. در جدول ۱، محدوده پارامترهای ورودی داده های مذکور، نشان داده شده است. به منظور عملکرد بهتر در تحلیل حساسیت و پیش بینی ظرفیت برشی تیرهای بتن مسلح با استفاده از الگوریتم های ازدحام ذرات - رقابت امپریالیستی و رگرسیون خطی چند گانه، مقادیر پارامترهای مؤثر پس از نرمال سازی مورد استفاده قرار گرفتند. برای این منظور با استفاده از رابطه (۱)، مقادیر داده های ورودی در بازه (+۱ و -۱) قرار گرفتند.

$$U = [2(x-x_i)/(x_u-x_i)] - 1 \quad (1)$$

در این رابطه X مقدار واقعی پارامترها، x_u و x_i به ترتیب مقادیر کمینه و بیشینه هر پارامتر می باشند. تحلیل حساسیت فرآیندی است که به تجزیه و تحلیل روابط و یا مدلی خاص می پردازد و همچنین تأثیر تغییرات هر یک از پارامترها را به تنهایی و نیز در ارتباط با هم، در خروجی مدل بررسی میکند و همچنین پارامترهایی که حساستر هستند و نیاز به توجه بیشتری دارند را مشخص مینماید. در این الگوریتم فرض میشود برآوردها در روش تجربی مذکور، صحیح میباشد و تنها حساسیت فاکتورها در قالب کلی مدل سنجیده میشود. در این بخش یک مدل عددی از تئوری GST [37]، جهت تعیین حساسیت پارامتری متغیرهای مورد بررسی بر روی ظرفیت برشی تیرهای بتن مسلح به کار گرفته شد. در GST یک ماتریس مرجع شامل متغیرهای وابسته و یک ماتریس مقایسه ای که در برگزیده ی متغیرهای مستقل می باشند، در اختیار می باشد. در این مطالعه، ظرفیت برشی به عنوان ماتریس مرجع و ۹ پارامتر معرفی شده در بخش ۲ در ماتریس مقایسه ای گنجانده شدند. مقادیر هر یک از ماتریس ها مطابق با رابطه (۲) می باشد:

$$X_0 = X_0(1) * X_0(2) * X_0(3) * \dots * X_0(n)$$

$$X_1 = X_1(1) * X_2(2) * X_3(3) * \dots * X_1(n) \quad (2)$$

$$X_m(1) = X_m(1) * X_m(2) * X_m(3) * \dots * X_m(n)$$

در رابطه فوق، X₀ ماتریس مرجع و X₁ تا X_m ماتریس مقایسه ای می باشند. m تعداد متغیرهای بکار رفته و n تعداد مقادیر مربوط به هر یک از متغیرها میباشد. در اینجا m برابر با ۹ و n برابر با تعداد آزمایش های صورت گرفته است که برابر با ۳۰۹ می باشد. به منظور کاهش نوسانات عددی از رابطه ی (۳) جهت نرمال سازی استفاده می شود.

$$Xi(J) = \frac{\square((Xi(J)) / (1/n \sum_{i=1}^n \square \llbracket * i(J) \rrbracket))}{\square} \quad (3)$$

پس از نرمال سازی، ضرایب وابستگی از رابطه (۴) محاسبه شدند:

$$\mathcal{Y}_i [X_0(j), X_i(J)] = | (\min_{i=n} * \min_{j=m} * \Delta_i(j) + p \max_{i=m} \Delta_i(j)) / \Delta_i + p \max_{i=m} \max_{i=m} \Delta_i(j) | \quad (4)$$

مقادیر رابطه فوق از روابط (۵-۷) بدست می آیند:

$$\Delta_i(J) = |X_n(i) - X_i(j)| \quad (5)$$

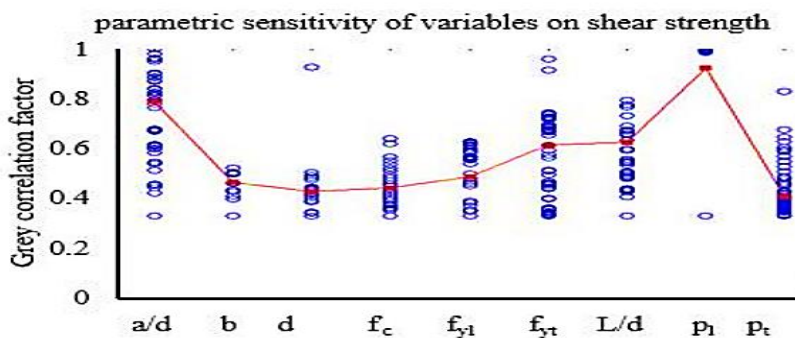
$$\min_{i=n} * \min_{j=m} * \Delta_i(j) = \max_i (\max_j |X_0(j) - X_i(j)|) \quad (6)$$

$$p \max_{i=m} \max_{i=m} \Delta_i(J) = \min_i (\max_j |X_0(j) - X_i(j)|) \quad (7)$$

و p عددی بین ۰ و ۱ می باشد که غالباً برابر ۰/۵ گرفته می شود. به کمک ضرایب وابستگی GST می توان میزان همبستگی ماتریس مرجع و ماتریس های مقایسه ای را مطابق با رابطه (۸) بدست آورد.


$$e = \frac{1}{n} \sum_{i=1}^n \gamma_i [x_0(i), x_i(j)] \quad (8)$$

λ که مقدار آن بین ۰ و ۱ است به عنوان شاخص ارتباط بین متغیرهای مستقل و وابسته استفاده می شود. هر چقدر مقدار λ به ۱ نزدیک تر باشد، همبستگی بین دو متغیر قوی تر است و در طرف مقابل هرچه این مقدار نزدیک به ۰ باشد، همبستگی بین دو متغیر ناچیز است. با توجه به توضیحات گفته شده، در شکل ۳، خروجی تحلیل حساسیت انجام شده توسط نرم افزار مینی تب به صورت نمودار مربوط به میزان همبستگی هر یک از پارامترهای مستقل بر ظرفیت برشی نشان داده شده است. نقاط قرمز در شکل، مقدار میانگین λ برای هر یک از متغیرها را نشان می دهد. مشاهده می شود که بیش ترین مقدار مربوط به درصد آرماتورهای طولی (ρ_l) می باشد.



شکل ۳: تحلیل حساسیت پارامترهای موثر بر مقاومت برشی تیربتنی عمیق (خروجی نرم افزار MINITAB)

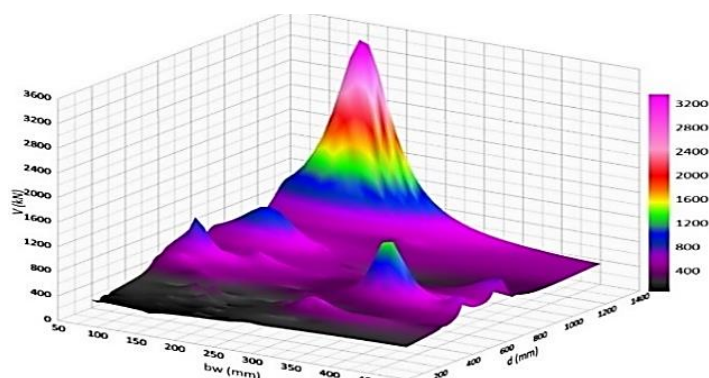
با توجه به تفاوت میزان اثر گذاری هر پارامتر (در تعیین مقاومت برشی تیر عمیق)، این فرضیه قوت گرفت که در مسائل چندمتغیره ی غیر خطی که تعداد متغیرهای معلوم شبکه عصبی مصنوعی (پارامترهای لایه ورودی)، متعدد و دارای وزن های متفاوت باشند، این شبکه نمی تواند به تنهایی، وزن ها و بایاس ها^{۱۵} را به طور دقیق محاسبه نماید و به همین دلیل، پاسخ های حاصله، با نتایج آزمایشگاهی تفاوت دارد. لذا چنانچه بتوان سیستم محاسباتی شبکه عصبی مصنوعی را بگونه ای تعریف کرد که وزن (میزان اثر گذاری) هر پارامتر بصورت دقیق محاسبه شود، میتوان انتظار پاسخ دقیق را در خروجی شبکه عصبی داشت. میزان اثر گذاری هر یک از پارامترها بر مقاومت برشی تیر عمیق بتنی، که از نرم افزار مینی تب^{۱۶} بدست آمد، در نمودارهای سه بعدی شکل های (۴ تا ۶) نشان داده شده است.




شکل ۴: میزان اثر گذاری f_c و a/d بر روی ظرفیت برشی تیر عمیق بتن مسلح. (خروجی نرم افزار MINITAB)

¹⁵ Bias

¹⁶ Minitab



شکل ۵: میزان اثر گذاری d و b_w بر روی ظرفیت برشی تیر عمیق بتن مسلح. (خروجی نرم افزار MINITAB)



شکل ۶: میزان اثر گذاری K_f و P_{sl} بر روی ظرفیت برشی تیر عمیق بتن مسلح. (خروجی نرم افزار MINITAB)


بررسی نتایج حاصل از تحلیل حساسیت، صحت این فرضیه را تقویت نمود. لذا سوگیری این تحقیق در جهت رفع ضعف ANN با بکارگیری الگوریتمهای بهینه سازی و ترکیب آن با ANN گردید. بدین منظور یک الگوریتم بهینه سازی قدرتمند (مانند ازدحام ذرات)، وزن و بایاس دقیق هر یک از پارامترهای موثر بر مقاومت برشی تیر عمیق بتنی را محاسبه نموده و سپس شبکه عصبی مصنوعی، وزن های تدقیق شده را جهت محاسبه مقاومت برشی مورد استفاده قرارداد. بدین ترتیب با تدقیق تر شدن وزن پارامترهای ورودی، انتظار می رفت پاسخ های دقیق تری حاصل گردد. برای اطمینان از دقت بهینه سازی الگوریتم ازدحام ذرات، نتایج آن با نتایج بدست آمده از ترکیب شبکه عصبی مصنوعی و سایر الگوریتم های پر کاربرد در مهندسی و نیز با نتایج بدست آمده از آیین نامه بتن آمریکا، مقایسه گردید و ویژگی این تحقیق، ترکیب الگوریتمهای فرا ابتکاری بمنظور هم افزایی توان محاسباتی و افزایش قدرت بهینه سازی آنها به منظور ارائه پاسخ دقیق تر است که در خصوص تخمین مقاومت برشی تیرهای بتنی عمیق، مسبوق به سابقه نبوده است. توصیف مختصر الگوریتم های مورد اشاره ذیلا آمده است.

۳- شرح مختصر الگوریتمهای مورد استفاده در این تحقیق

۳-۱- شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی یک روش محاسبات نرم است که می تواند الگوهای موجود بین مجموعه ای از اعداد معین را تشخیص دهد و مدلی را برای آن اعداد فراهم نماید. این الگوریتم؛ یک ساختار ریاضی است که توانایی نشان دادن فرایندها و ترکیبات دلخواه غیر خطی جهت ارتباط بین ورودی ها و خروجی های هر سیستمی را دارا می باشد [۳۳]. شکل (۷) لایه های یک شبکه عصبی مصنوعی را نشان می دهد. مراحل ونحوه بکار گیری شبکه ANN شامل موارد ذیل است:

➤ تعیین ورودی و خروجی و زوج های آموزشی، استاندارد و نرمالیزه کردن داده ها، دسته بندی داده ها، آموزش، اعتباریابی همزمان با آموزش، آزمون




شکل ۷: لایه های شبکه عصبی مصنوعی [۳۴].

در شبکه های عصبی مصنوعی، لایه اول (بیرونی) پارامترهای ورودی هستند و لایه میانی (پنهان)، عمل پردازش داده ها را با توجه به وزن هر داده (خطوط ارتباطی) انجام میدهد. برای مشخص شدن بهترین نحوه تقسیم گره در لایه های میانی، هیچ فرمول مشخصی وجود ندارد. لذا باید تمامی حالات ممکن را بررسی نمود و توپولوژی که کمترین میزان خطا و بیشترین ضریب تعیین را داراست، بعنوان توپولوژی برتر ملاک عمل قرارداد [۳۴]. در مرحله آموزش با توجه به نوع الگوریتم یادگیری، وزن های اتصالات شبکه تغییر می یابند. با تغییر توابع انتقال و تعداد لایه ها و تعداد نرون های لایه پنهان و عوامل موثر در تغییر وزن ها بصورت سعی و خطا، مناسبترین مدل شبکه عصبی برای مسئله مورد نظر بدست می آید [۳۵]. شبکه عصبی مورد استفاده در این تحقیق از نوع پیشخور^{۱۷} است. شبکه های پرسپترون چند لایه، جزء این شبکه ها می باشند. شبکه های عصبی چند لایه پیشخور دارای توانایی بیشتری نسبت به شبکه های عصبی تک لایه اند [۳۶].


۳-۲- الگوریتم ازدحام ذرات (PSO)^{۱۸}

الگوریتم بهینه سازی ازدحام ذرات یک الگوریتم فرا ابتکاری است که برای بهینه سازی توابع پیوسته غیر خطی، مناسب محسوب می شود. دسته پرندگانی (ازدحام پرندگان) که بر فراز یک منطقه در حال حرکت هستند، باید یک نقطه را برای فرود پیدا کنند. در این حالت، تعریف اینکه همه پرندگان در کدام نقطه باید فرود بیابند، مسئله پیچیده ای است. مسئله پیدا کردن بهترین نقطه برای فرود، یک مسئله بهینه سازی محسوب می شود. این الگوریتم با گروهی از ذرات (راه حل های) تصادفی آغاز می شود و سپس با به روز رسانی پاسخ ها، جستجو را ادامه می دهد. در هر تکرار، هر ذره با دو ارزش "بهترین" به روز رسانی می شود. [۳۷]. در شکل های (۹و۸) به روز رسانی هایی در سرعت ذرات و موقعیت آن در تکرار t با در نظر داشتن مسئله دوبعدی با متغیرهای x_1 و x_2 انجام شده است.

شکل ۸: بردار سرعت در تکرار t [۳۷].

¹⁷ Feed Forward

¹⁸ Particle swarm optimization



شکل ۹: بردار بروز رسانی شده مکانی در تکرار t [۳۷].

۳-۳- الگوریتم رقابت استعماری (ICA) ^{۱۹}

بطور خلاصه، این الگوریتم، از چندین کشور در حالت اولیه شروع می‌شود. کشورها در حقیقت جوابهای ممکن مساله هستند و معادل ذره، در بهینه‌سازی ازدحام ذرات هستند. رقابت امپریالیستی در کنار سیاست همگون‌سازی، هسته‌ی اصلی این الگوریتم را تشکیل می‌دهد و باعث می‌شود که کشورها به سمت مینیمم مطلق تابع حرکت کنند با داشتن تابع $f(\mathbf{x})$ ، در بهینه‌سازی می‌باید آرگومان \mathbf{X} را به گونه‌ای تعیین کرد که هزینه متناظر آن، بهینه باشد [۳۸]. در بهینه‌سازی، هدف، یافتن یک جواب بهینه بر حسب متغیرهای مسئله است. در حقیقت در حل یک مسئله بهینه‌سازی، الگوریتم، به دنبال بهترین کشور (با بهترین ویژگی‌های اجتماعی-سیاسی) است. یافتن این کشور در حقیقت معادل یافتن بهترین پارامترهای مسئله است که کمترین مقدار تابع هزینه را تولید می‌کنند. الگوریتم مورد نظر تا برآورده شدن یک شرط همگرایی یا تا اتمام تعداد کل تکرارها، ادامه می‌یابد. [۳۹].

۳-۴- رگرسیون خطی چندگانه (MLR) ^{۲۰}

یک تکنیک آماری است که از چندین متغیر توضیحی برای پیش بینی نتیجه یک متغیر پاسخ استفاده می‌کند. هدف رگرسیون خطی چندگانه مدل سازی رابطه خطی بین متغیرهای توضیحی (مستقل) و متغیرهای پاسخ (وابسته) است. رگرسیون خطی چندگانه، برای تعیین یک رابطه ریاضی بین چندین متغیر تصادفی استفاده می‌شود. به عبارت دیگر، بررسی می‌کند که چگونه چندین متغیر مستقل با یک متغیر وابسته مرتبط هستند. هنگامی که هر یک از عوامل مستقل برای پیش‌بینی متغیر وابسته تعیین شد، می‌توان از اطلاعات مربوط به متغیرهای متعدد برای ایجاد پیش‌بینی دقیق در سطح تأییری که بر متغیر نتیجه می‌گذارند استفاده کرد. مدل رگرسیون چندگانه به تحلیلگر اجازه می‌دهد تا بر اساس اطلاعات ارائه شده بر روی متغیرهای توضیحی چندگانه، یک نتیجه را پیش بینی کند [۴۱-۴۳]. برای مدل کردن رگرسیون خطی از برنامه SPSS ^{۲۱} استفاده می‌گردد.

۴- فرضیات و روش تحقیق:

فرضیه تحقیق بر مبنای ضعف شبکه عصبی در تخمین دقیق ظرفیت برشی تیرهای بتن مسلح عمیق بدلیل دقیق نبودن اوزان و بایاس ^{۲۲} های محاسبه شده برای متغیرهای معلوم ورودی (در زمانی که متغیرهای معلوم، متعدد و دارای تفاوت وزنی زیاد باشند) شکل گرفت و راهکار رفع این نقص، بهره گیری از توان بهینه سازی یک الگوریتم قدرتمند مانند ازدحام ذرات بمنظور تدقیق وزن پارامترهای ورودی منظور گردید. شبکه عصبی مورد استفاده، از نوع پرسپترون پیش‌خور (Feed Forward) با یک لایه ورودی (دارای ۹ متغیر معلوم) و یک لایه خروجی (با یک متغیر نامعلوم) و ۱۹ گره (Node) بود که در حالت یک لایه و دولایه پنهان با استفاده از نرم افزار متلب مدل سازی و توپولوژی برتر بر اساس کمترین میزان خطا و بیشترین ضریب تعیین انتخاب و مورد آموزش و آزمون قرار گرفت. تعداد گره ها از رابطه تجربی (۹) حاصل گردید [۴۶].

$$N_H \leq 2N_1 + 1$$

(۹)

¹⁹ Imperialist Competitive Algorithm

²⁰ Multiple Linear Regression

²¹ Statistical Package for the Social Sciences

²² Bias

در این فرمول، N_H تعداد گره‌های لایه‌های پنهان و N_I تعداد ورودی‌ها است. با توجه به اینکه تعداد ورودی‌های موثر، ۹ عدد است، حداکثر تعداد گره‌های لایه (لایه‌های) پنهان، برابر با ۱۹ عدد گردید. بعبارت دیگر $N_H \leq 19$. جهت حصول نتیجه، فرایند ذیل طی گردید:

۱- تهیه پایگاه داده با ۳۰۹ نمونه تجربی از تیرهای بتنی عمیق مسلح منتج از ادبیات تحقیق و ۱۷ مقاله معتبر [۵۰]

۲- استاندارد سازی (نرمالایز) نمونه‌ها جهت آموزش دقیق تر شبکه عصبی مصنوعی

۳-، کدنویسی برای ترکیب الگوریتم بهینه سازی با ANN با استفاده از نرم افزار MATLAB. [۵۰]

۴- ترسیم و بررسی تمام توپولوژیهای ممکن برای شبکه عصبی با ساختار ۹ پارامتر در لایه اول (متغیرهای معلوم) و یک پارامتر خروجی در لایه سوم (مقاومت برشی) و یک و دولایه ی پنهان جهت انتخاب بهترین توپولوژی بر مبنای کمترین خطا و بیشترین ضریب تعیین، انتخاب شود. [۵۰]

۵-مقایسه نتایج

۴-۱- نرمالیزاسیون پایگاه داده و پیشگیری از بیش برآزش^{۲۳}

آموزش دقیق ANN منوط به همگرایی و نرمال بودن داده‌ها است. لذا طی فرایند نرمالیزاسیون، نمونه‌هایی که با ضوابط تیر عمیق بتنی وفق مقررات ملی ساختمان ایران و ایمن نانه بتن امریکا مطابقت نداشت (مقادیرهایی که $\ln/d > 4$ بودند) و نیز داده‌هایی که دارای مشخصاتی با اختلاف زیاد با سایر داده‌ها بودند، حذف شدند و نهایتاً ۱۷۹ مقادیری نرمالایز شده استحصال گردید. در جدول ۱ حداقل و حداکثر ابعاد و اندازه‌ی نمونه‌های مورد استفاده ذکر شده است.

جدول ۱: خصوصیات آماری مقادیرهای نرمالایز شده.


مشخصه	d	b	a	f_c	f_y	β
میانگین	۳۷۰/۹	۹۸/۲	۳۵۴/۷	۰/۰۲	۰/۴۲	۰/۰۱۶
استاندارد	۱۰۱/۴	۱۰/۷	۱۱۶	۰/۰۱	۰/۱۳۱	۰/۰۰۴۵
حداکثر	۲۱۶	۷۶	۱۲۵	۰/۰۱۶	۰	۰/۰۰۵۲
حداقل	۷۲۴	۱۱۰	۱۰۰۰	۰/۰۵۸	۰/۰۴۸	۰/۰۱۹

جهت پیشگیری از بیش برآزش (overfitting)، علاوه بر استاندارد سازی داده‌ها، از روش نگه داری داده‌ها (Holding out Data) استفاده شد. براین اساس، از حداقل تعداد لایه پنهان که دقت بیش از ۹۰ درصد را ارائه نمود (یعنی دولایه پنهان)، در توپوگرافی ANN استفاده شد و بجای استفاده از همه‌ی داده‌ها برای آموزش، فقط ۷۰٪ آنها، یعنی ۱۲۵ نمونه برای آموزش شبکه و ۳۰٪ یعنی ۵۴ نمونه برای آزمون بکار گیری شد. آموزش تا آنجا تکرار شد تا در تست نیز نتایج با دقت بالا بدست آمد. این امر نشان‌دهنده‌ی قابلیت تعمیم خوب مدل بود؛ زیرا مجموعه‌ی تست نشان‌دهنده‌ی داده‌های دیده‌نشده‌ای بود که برای آموزش استفاده نشده بودند؛ البته این رویکرد به مجموعه‌داده‌ای نسبتاً بزرگ نیاز داشت بهمین دلیل از یک پایگاه داده با ۳۰۹ نمونه استفاده گردید.

توزیع نرمال هر پارامتر توسط نمودارهای "طرح احتمالات"^{۲۴} بررسی گردید. این نمودارها نشان دادند که هر پارامتر تا چقدر به توزیع نرمال نزدیک است. البته اگر یک یا چند متغیر نیز از توزیع نرمال پیروی نکنند، در مدل‌های هوش مصنوعی تغییر آنچنانی ایجاد نمی‌گردد ولی نزدیک بودن پارامترها به توزیع نرمال نشان‌دهنده‌ی دقت بالاتر مدل است. توزیعات نرمال پارامتر خروجی با استفاده از نمودارهای مذکور، در شکل (۱۰) نشان داده شده است.

²³ Overfitting

²⁴ Probability Plot



شکل ۱۰: نمودار "طرح احتمالات" برای تعیین نرمال بودن پارامتر ظرفیت برشی تیر.

۲-۴- تعیین بهترین ساختار (توپولوژی)

نرم افزار متلب، ۱۸۰ ساختار ممکن برای ANN، ارایه داد. توپولوژی برتر، براساس کمترین میزان خطا (اعم از خطاهای نسبی و مطلق و مجذور مربعات خطا که با علایم اختصاری ME^{25} , MSE^{26} , MAE^{27} , AAE^{28} نشان داده میشوند) و بیشترین ضریب تعیین (R^2) در دو حالت آموزش و آزمون انتخاب شد. این توپولوژی، تعداد لایه های پنهان و تعداد گره ها در هر لایه را نشان می دهد. نحوه محاسبه میزان خطاها در روابط (۱۰-۱۴) نشان داده شده است.

$$ME = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (11)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \quad (12)$$

$$RMSE = \sqrt{\left[\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \right]} \quad (13)$$

$$AAE = \left| \frac{\sum_{i=1}^n X_i \frac{(O_i - P_i)}{O_i}}{n} \right| \times 100 \quad (14)$$

۱۰ ساختار (توپولوژی) برتر منتج از خروجی نرم افزار متلب، در مراحل آموزش و آزمون، در جداول (۳ و ۲) نشان داده شده است. براساس نتایج حاصله، مدل پرسپترون پیشخور^{۲۹} با دو لایه پنهان و ۶-۷ گره در آن [ساختار (۱-۷-۶-۹) ۲L]، بهترین مدل تشخیص داده شد. در این مدل، تابع تحریک، تنسیگ^{۳۰}، الگوریتم آموزش لونیبرگ-مارکوات^{۳۱}، با تعداد تکرار ۱۵۰ بود. مقدار R^2 در مراحل آموزش و آزمون برای شاخص نیروی برشی در تیر عمیق به ترتیب برابر ۰/۹۳ و ۰/۹۰ بود که بالاترین ضریب تعیین در بین تمامی توپولوژی ها را داشت و بیانگر نزدیکی خروجی های این مدل، به داده های واقعی بود. فلوجارت روش تحقیق در شکل ۱۱ نشان داده شده است.

²⁵ Mean error

²⁶ Mean squared error

²⁷ Mean absolute error

²⁸ Absolut average error

²⁹ Feed Forward

³⁰ tansig

³¹ Levenberg-Marquardt

جدول ۲: ده توپولوژی برتر شبکه عصبی در مرحله آموزش.

ساختار شبکه ³²	MSE	R ²	ME	MAE	RMSE
۲L(۱-۵)	۲۸۳۶/۴	۰/۹۷	۰/۰۱۳	۳۶/۲۵	۵۳/۵۱
۲L(۲-۸)	۵۲۳/۴۸	۰/۹۹	۰/۰۰۳	۱۶/۳۴	۲۲/۸۸
۲L(۳-۷)	۱۹۲۳/۲۹	۰/۹۸	۰	۰۲۹/۲۵	۴۳/۸۵
۲L(۴-۶)	۲۶۰/۷۹	۰/۹۹	۰/۱۴۹	۱۱/۴۷	۱۶/۱۴
۲L(۵-۵)	۲۰۲/۶۸	۰/۹۹	۰	۱۰/۰۸	۱۴/۲۳
۲L(۶-۷)	۵۳۳/۰۸	۰/۹۳	-۰/۰۱	۱۶/۸۹	۲۳/۵۱
۲L(۷-۶)	۶۹/۷۱	۰/۹۹	-۰/۰۱	۵/۴۲	۸/۳۵
۲L(۸-۶)	۵۰/۸۹	۱	۰/۰۰۱	۴/۳۲	۷/۱۳
۲L(۹-۶)	۳۸/۸۵	۰/۹۹	۰/۰۰۶	۳/۹۵	۶/۲۳
۲L(۱۰-۹)	۱۴/۹	۱	-۰/۰۰۲	۱/۷۲۳	۳/۸۶

جدول ۳: ده توپولوژی برتر شبکه عصبی در مرحله آزمون.

ساختار شبکه	MSE	R ²	ME	MAE	RMSE
۲L(۱-۳)	۲۶۱۸۹/۱	۰/۷۵	-۲/۹۳	۹۰/۰۴	۱۶۱/۸۳
۲L(۲-۱)	۷۱۹۳	۰/۹۳	-۴/۹	۴۸/۰۴	۸۴/۸۱
۲L(۳-۶)	۱۸۶۰۰/۱	۰/۹۲	۲۳/۰۷	۵۶/۵۲	۱۳۶/۳۸
۲L(۴-۲)	۳۲۵۱/۸	۰/۹۶	۸/۶۷	۳۰/۳۸	۵۷/۰۲
۲L(۵-۱)	۵۳۶۲/۹	۰/۹۳	۱۰/۱۱	۳۵/۰۲	۷۳/۲۲
۲L(۶-۷)	۱۹۱۰	۰/۹۰	۶/۹۹	۲۵/۲۷	۴۳/۷
۲L(۷-۷)	۷۰۱۷	۰/۹۲	۱۳/۳۱	۲۸/۷۹	۸۳/۷۶
۲L(۸-۳)	۴۹۷۶/۱	۰/۹۳	۳/۳۹	۴۰/۷۳	۷۰/۵
۲L(۹-۳)	۶۸۵۹/۴	۰/۹۳	۱۱/۲	۳۹/۴۱	۸۲/۸۲
۲L(۱۰-۴)	۴۷۴۹۹/۶	۰/۷۶	-۱۸/۸	۸۳/۴۱	۲۱۷/۹۴



شکل ۱۱: فلوجارت روش تحقیق.

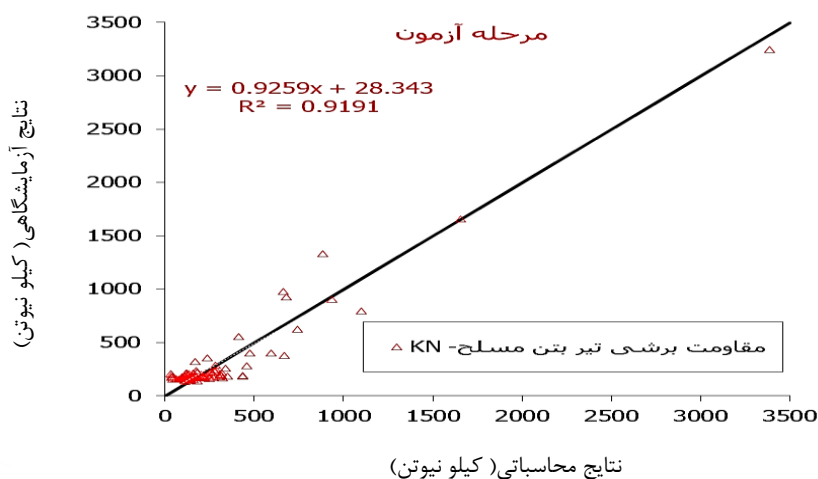
۵- تحلیل نتایج

۵-۱- بهینه سازی (۱-۷-۶-۹) ANN با استفاده از PSO

بر اساس آزمون و خطا، میزان تکرار بهینه برای الگوریتم ازدحام ذرات برابر ۱۵۰ تکرار حاصل شد. مستند به نتایج جدول (۴) و شکل (۱۲)، ضریب همبستگی این روش حدود $R^2 = ۰.۹۲$ و خطای برابر $RMSE = ۱۴۱/۲۴$ بود.

جدول ۴: نتایج ترکیب ANN با PSO جهت تخمین مقاومت برشی تیر عمیق.

سیستم	خطا					R ² %
	ME	MAE	MSE	RMSE	AAE	
شبکه عصبی ترکیبی با ازدحام ذرات (ANN-PSO)	۶/۶	۷۲/۱۹	۱۹۴۷/۸	۱۴/۲۴	۰/۴۴	٪۹۱.۹۱




شکل ۱۲: نتایج سیستم ANN-PSO در مقایسه با نتایج آزمایشگاهی مقاومت برشی (خروجی نرم افزار در آزمون).

۲-۵- بهینه سازی (۱-۷-۶-۹) ANN با استفاده از ICA

براساس آزمون و خطا، تعداد ۱۵۰ بار تکرار برای الگوریتم ICA منظور گردید. مستند به نتایج درج شده در جدول (۵) و شکل (۱۳) ضریب همبستگی این روش حدود ۸۷٪ و خطای RMSE=۱۱۲.۳۲ بود.

جدول ۵: نتایج بهینه سازی شبکه عصبی منتخب با الگوریتم رقابت

سیستم	خطا					R ² %
	ME	MAE	MSE	RMSE	AAE	
شبکه عصبی ترکیبی با رقابت (ANN-ICA)	۱۳/۹	۸۰/۰۴	۱۲۶۱۶/۶۴	۱۱۲/۳۲	۰/۵۴	٪۸۷




شکل ۱۳: مقایسه نتایج سیستم ترکیبی ANN-ICA 2L(9-6-7-1) با نتایج آزمایشگاهی (خروجی نرم افزار)

۵-۳- استفاده از رگرسیون خطی چند گانه (MLR)

مدل سازی MLR با استفاده از نرم افزار SPS، منتج به معادله خطی به شرح معادله ۱۵ گردید که دقت حدود ۷۸.۶٪ را نشان داد. مزیت این معادله، سهولت استفاده آن در کارگاه های ساختمانی برای محاسبه تقریبی ظرفیت برشی تیر بتنی است. عملکرد و میزان دقت MLR در شکل (۱۴)، نمایش داده شده است. براین اساس دقت این روش با جایگزینی داده های نرمال شده در رابطه مذکور برابر $R^2 = 78.5\%$ شد.

$$V = 560 + (1.17b_w) + (0.144d) + (2.27h_f) + (0.0296b) - (26.9 a / d) + \sqrt{(1.35f_c) + (25.9\rho_{sl}) + (78.5\rho_{st}.f_{st},y)} - 763k_{(f)} \quad (15)$$



شکل ۱۴: عملکرد MLR در تخمین مقاومت برشی تیر در مقایسه با نتایج آزمایشگاهی (خروجی نرم افزار)

۵-۴- استفاده از آیین نامه بتن ۱۴-۳۱۸ ACI

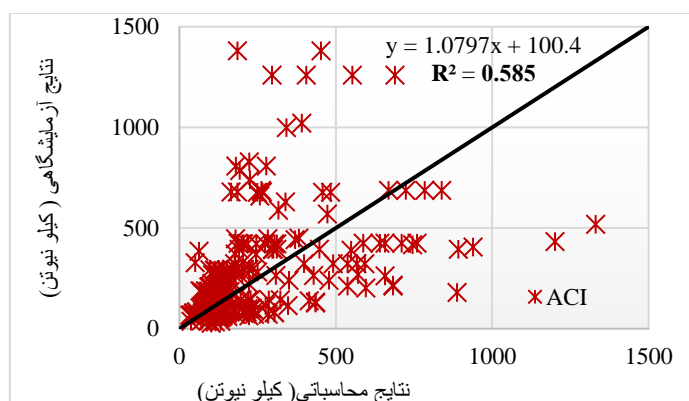
معادله ۱۶ منتج از آیین نامه ۱۴-۳۱۸ ACI و معادله ۱۷ حالت ساده شده ی آن جهت محاسبه ظرفیت برشی تیر بتنی عمیق استفاده شد.

$$V_c = \left[\frac{3}{5} - \frac{2}{5} \frac{M}{V.d} \right] \times \left[1.9\sqrt{f_c} + 2.5\rho \frac{V.d}{M} \right] \times b_w.d \quad (16)$$

$$V_c = 0.7 \times \phi \cdot \sqrt{f_c} \cdot b_w.d \quad (17)$$

در معادله فوق: V_c : مقاومت برشی بتن و f_c : مقاومت مشخصه بتن برحسب مگاپاسکال و d : فاصله مرکز سطح فولاد های کششی تا دورترین تار فشاری برحسب میلیمتر و b_w : عرض مقطع برحسب میلیمتر و ϕ : ضریب کاهش مقاومت که مقدار آن برابر با ۰.۷۵

و V : نیروی متمرکز برشی و M : لنگر خمشی و ρ : درصد فولاد مقطع تیر است. نتایج حاصل از استفاده از ط داده ای نرمال شده در رابطه فوق، خطایی حدود 41.5% و دقتی حدود 58.5% را برای فرمول آیین نامه در شکل ۱۵ نشان داد.



شکل ۱۵: مقایسه نتایج استفاده از ACI 318-14 برای تعیین مقاومت برشی با نتایج آزمایشگاهی (خروجی نرم افزار)

۶-مقایسه مدلها:

جداول (۷ و ۶)، نتایج روشهای مختلف جهت تخمین مقاومت برشی تیر بتن مسلح عمیق را نشان داد. خروجی سیستم در جداول مذکور نشان داد، ترکیب الگوریتم ازدحام ذرات با شبکه عصبی مصنوعی پرسپترون پیشخور با ۹ متغیر معلوم ورودی و ۶ گره در لایه پنهان اول و ۷ گره در لایه پنهان دوم و دارا بودن ضریب تعیین معادل 94% در مرحله آموزش و 91% در مرحله آزمون و خطای معادل $RMSE = 32.68$ ، دارای بیشترین دقت، نسبت به سایر روش ها است. ترکیب ICA-ANN با دارا بودن ضریب تعیین (دقت) $R^2 = 0.87$ و در نهایت فرمول های آیین نامه بتن ACI با دارا بودن دقت برابر $R^2 = 0.58/5$ قرار گرفتند.

جدول ۶: نتایج در مرحله آموزش.


سیستم	خطا در مرحله آموزش					R^2
	ME	MAE	MSE	RMSE	AAE	
PSO_ANN	3/22	19/74	1068/06	32/68	0/12	0/94
ICA_ANN	3/65	68/11	9743/91	98/71	0/47	0/89
ANN	12/32	73/29	11217/3	104/66	0/53	0/85
MLR	-	-	-	-	-	0/78
ACI	-	-	-	-	-	0/585

جدول ۷: نتایج در مرحله آزمون.

سیستم	خطا در مرحله آزمون					R^2
	ME	MAE	MSE	RMSE	AAE	
PSO_ANN	6/6	22/19	1947/8	14/24	0/44	0/9191
ICA_ANN	13/9	80/04	12616/64	112/32	0/54	0/87
ANN	42/75	114/13	21072/46	233/74	1.2	0/81
REG	-	-	-	-	-	0/78
ACI	-	-	-	-	-	0/585

۷- راستی آزمایی - مدل سازی یک تیر عمیق بتنی مسلح مقاوم سازی نشده

یک نمونه تجربی از پایگاه داده ی منتج از ادبیات تحقیق با مشخصات مندرج ذیل، با استفاده از روشهای مختلف ذکر شده در این تحقیق مدل سازی شد و نتایج به شرح جدول ۸ ارایه گردید. شکل ۱۶ نمایش شماتیک یک تیر عمیق و پارامترهای مربوطه را نشان میدهد.



شکل ۱۶: نمایش شماتیک یک تیر عمیق

$$d=46.3\text{cm} \quad b_w=10.16\text{cm} \quad a=35.56\text{cm} \quad f_c=382\text{Kg/Cm}^2 \quad f_{yh}=0/4459 \quad F_{yv}=0/4459 \quad \rho=0/0194 \quad \rho_h=0/023 \quad \rho_v=0/018$$

۷: ظرفیت برشی تیر در آزمایشگاه: 311.02 Kg/Cm^2

d: عمق - b_w : عرض - a: دهانه برش - f_c : مقاومت فشاری بتن - f_{yh} و f_{yv} : تنش جاری شدن فولاد طولی و عرضی - ρ : درصد فولاد آرماتور برشی ρ_h و ρ_v : درصد فولاد طولی و عرضی

جدول ۸: نتایج دقت روش های مختلف در تخمین مقاومت برشی (KG/CM^2)

روش	ACI	ANN	ANN-PSO	ANN-ICA	MLR	آزمایشگاه
۷ ظرفیت برشی	417.19	263.31	332.23	353.54	238.86	311.02
RMSE خطا	-	191/13	97/03	107/91	-	0
R^2 (دقت)	٪62	84/66	93/18	86/33	76/8	100

۸- جمع بندی

اهمیت ویژه تیرهای بتنی عمیق در سازه ها و نیاز به راهکاری برای تخمین سریع و دقیق ظرفیت برشی آنها و عدم وجود روشی دقیق و غیرآزمایشگاهی برای این امر از یکسو و فراگیر شدن استفاده از الگوریتمها و هوش مصنوعی در محاسبات سازه ای از سوی دیگر موجب گردید سوگیری تحقیق در جهت رفع نقص و تکمیل روشهای موجود شود. این تحقیق نشان داد ترکیب الگوریتمها میتواند با هم افزایی توان محاسباتی، موجب رفع نواقص موجود در الگوریتم یا به حداقل رساندن آن شود و یک راهکار ابتکاری برای تخمین دقیق تر ظرفیت برشی تیرهای بتنی عمیق، نسبت به سایر روشها ارایه نماید.

۸-۱- نتیجه گیری

- ۱- شبکه عصبی مصنوعی پرسپترون پیشخور با دو لایه پنهان بهینه سازی شده با الگوریتم ازدحام ذرات، با ۱۰۰ تکرار و توپولوژی (۱-۶-۹) L و ورودی و تابع انتقال تنسیگ، با ارایه نتایجی با دقت $R^2=0.94$ در مرحله آزمون و دقت حدود $R^2=0.92$ و جذر مربعات خطای $RMSE=14/24$ در مرحله ی آزمون، توانست مقاومت برشی تیر بتنی عمیق را دقیق تر از سایر روشها محاسبه نماید.
- ۲- تعدد متغیرهای معلوم با بایاسهای متفاوت در لایه اول یک شبکه پرسپترون ANN موجب کاهش دقت اوزان تعیین شده و در نتیجه کاهش دقت پاسخ در لایه خروجی ANN میگردد.
- ۳- توان بهینه سازی الگوریتمهای بهینه سازی، موجب تدقیق بایاسهای متغیرهای معلوم لایه اول شبکه عصبی مصنوعی و دقیق تر شدن پاسخ در لایه خروجی آن گردد.
- ۴- جهت تخمین مقاومت برشی تیرهای عمیق (تحت بارهای متمرکز) بوسیله ANN، الگوریتم ازدحام ذرات توان بهینه سازی بیشتری نسبت به سایر الگوریتمها داشته و در نتیجه مقدار مقاومت برشی حاصله، به نتایج آزمایشگاهی بسیار نزدیکتر است.

- ۵- فرمولهای ایین نامه ای منجمله آیین نامه بتن ACI 318-14، برای تعیین مقاومت برشی تیرهای بتنی عمیق، از دقت مناسبی برخوردار نیستند.
- ۶- ظرفیت برشی تیر عمیق با ۹ پارامتر ارتباط مستقیم دارد. این پارامترها عبارت بودند از: عرض کامل تیر b ، عرض موثر تیر b_e ، عمق کامل تیر h ، ارتفاع موثر تیر h_e ، نسبت عمق تیر به دهانه h/d ، مقاومت فشاری بتن f_c ، درصد و سطح مقطع میلگرد a ، مقاومت کششی فولاد f_y و سختی المان k .
- ۷- با افزایش مقاومت تسلیم فولاد، ظرفیت برشی تیر عمیق بتنی مسلح، افزایش می یابد.
- ۸- عرض تیر عمیق بتنی مسلح، اثر ناچیزی بر مقاومت برشی دارد.
- ۹- تحت اثر بار متمرکز، نمونه هایی که دارای عمق موثر بزرگتر هستند نسبت به مقاطع با عمق موثر کوچکتر دارای عملکرد بهتری می باشند.
- ۱۰- تحت اثر بار متمرکز، نمونه هایی که دارای عرض کمتری هستند نسبت به مقاطع با عرض بیشتر دارای عملکرد بهتری می باشند.
- ۱۱- ظرفیت برشی یک تیر با مقاومت فشاری بتن آن، ارتباط مستقیم دارد.
- ۱۲- تحت اثر بار متمرکز، بزرگتر شدن دهانه ی برش تیر بتنی عمیق، موجب کم شدن مقاومت برشی آن می شود.

۲-۸- پیشنهادات

- ۱- استفاده از مدل ANN-PSO 2L(9-6-7-1) برای تعیین مقاومت خمشی و مقاومت فشاری تیرهای بتنی تحت بار گسترده بعنوان یک تحقیق مستقل
- ۲- استفاده از الگوریتم بهینه سازی متناسب با صورت مسئله برای تدقیق بایاسهای ANN و اخذ خروجی دقیقتر از شبکه
- ۴- کنترل ظرفیت برشی تیرهای عمیق در پروژه های در حال اجرا بوسیله روش پیشنهادی جهت اطمینان از عملکرد و ظرفیت تیرهای عمیق در برابر نیروهای برشی طرح

مراجع:

1. Abuodeh, O. R., Abdalla, J. A., & Hawileh, R. A. (2019). Prediction of shear strength and behavior of RC beams strengthened with externally bonded FRP sheets using machine learning techniques. *Composite Structures*, 111698. <https://doi.org/10.1016/J.COMPSTRUCT.2019.111698>
2. Adhikary, B. B., & Mutsuyoshi, H. (2006). Prediction of shear strength of steel fiber RC beams using neural networks. *Construction and Building Materials*, 20(9), 801–811. <https://doi.org/10.1016/J.CONBUILDMAT.2015.01.047>
3. Ali, M. (2020). Modeling wheat yield with data-intelligent algorithms: artificial neural network versus genetic programming and minimax probability machine regression. *Handbook of Probabilistic Models*, 37–87. <https://doi.org/10.1016/B978-0-12-816514-0.00002-3>
4. Amani, J., & Moeini, R. (2012a). Prediction of shear strength of reinforced concrete beams using adaptive neuro-fuzzy inference system and artificial neural network. *Scientia Iranica*, 19(2), 242–248. <https://doi.org/https://doi.org/10.1016/j.scient.2012.02.009>
5. Armaghani, D. J., Hatzigeorgiou, G. D., Karamani, C., Skentou, A., Zoumpoulaki, I., & Asteris, P. G. (2019). Soft computing-based techniques for concrete beams shear strength. *Procedia Structural Integrity*, 17, 924–933. <https://doi.org/10.1016/J.PROSTR.2019.08.123>
6. Atashpaz-Gargari, E., Hashemzadeh, F., & Lucas, C. (2018). Designing MIMO PIID controller using colonial competitive algorithm: Applied to distillation column process. *2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence)*, 1929–1934. <https://doi.org/10.1109/CEC.2008.4631052>
7. Ben Cheikh-Graiet, S., Dotoli, M., & Hammadi, S. (2019). A Tabu Search Based Metaheuristic for Dynamic Carpooling Optimization. *Computers & Industrial Engineering*, 106217. <https://doi.org/10.1016/J.CIE.2019.106217>

8. Cladera, A., & Marí, A. R. (2004a). Shear design procedure for reinforced normal and high-strength concrete beams using artificial neural networks. Part II: beams with stirrups. *Engineering Structures*, 26(7), 927–936. <https://doi.org/https://doi.org/10.1016/j.engstruct.2004.02.011>
9. Dias, S. J. E., & Barros, J. A. O. (2013). Shear strengthening of RC beams with NSM CFRP laminates: Experimental research and analytical formulation. *Composite Structures*, 99, 477–490. <https://doi.org/https://doi.org/10.1016/j.compstruct.2012.09.026>
10. R. J. Frosch, “Ultimate shear strength of deep reinforced concrete beams with variable section by artificial neural networks” *ACI Struct. J.*, vol. 97, no. 6, 2001, doi: 10.14359/9626.
11. Yu, Y., Deng, Y., Tan, S.-Y., & Wu, J. (2018). Neural network model to estimate the contribution of FRP in increasing the shear capacity of reinforced concrete beam with FRP A: *Statistical Mechanics and Its Applications*, 507, 435–442. <https://doi.org/https://doi.org/10.1016/j.physa.2018.05.079>
12. Passos, G. C. S., & Barrenechea, M. H. (2019). Estimation of ultimate shear strength of reinforced concrete beams reinforced with polymer fibers using neural network. <https://doi.org/10.1016/J.ECON.2019.09.002>
13. Pal, M., & Deswal, S. (2020). Optimum design of reinforced concrete frames considering the nonlinear deformation of materials using the search algorithm of symbiotic organisms., 89(13–14), 1430–1439. <https://doi.org/10.1016/J.COMPSTRUC.2011.03.005>
14. Pastore, T., Martínez-Gavara, A., Napoletano, A., Festa, P., & Martí, R. (2020). Shear resistance modeling based on support vector regression of deep beams. *Computers & Operations Research*, 114, 104830. <https://doi.org/10.1016/J.COR.2019.10483>
15. Mohammed, A. M., & Duffuaa, S. O. (2020). Prediction of shear strength of reinforced concrete beam with steel fiber using hybrid intelligence models. *Expert Systems with Applications*, 140, 112808. <https://doi.org/10.1016/J.ESWA.2019.07.025>
16. Esmaeil Atashpaz Gargari, Farzad Hashemzadeh, Ramin Rajabioun, & Caro Lucas. (2018). Colonial competitive algorithm: A novel approach for PID controller design in MIMO distillation column process. *INTERNATIONAL JOURNAL OF INTELLIGENT COMPUTING AND CYBERNETICS*, 1(3), 337–355. <https://doi.org/10.1108/17563780810893446>
17. Enayatifar, R., Yousefi, M., Abdullah, A. H., & Darus, A. N. (2013). MOICA: A novel multi-objective approach based on imperialist competitive algorithm. *Applied Mathematics and Computation*, 219(17), 8829–8841. <https://doi.org/10.1016/J.AMC.2013.03.099>
18. Fernandez, M., & Caballero, J. (2016). Genetic Algorithm Optimization of Bayesian-Regularized Artificial Neural Networks in Drug Design. *Artificial Neural Network for Drug Design, Delivery and Disposition*, 83–102. <https://doi.org/10.1016/B978-0-12-801559-9.00004-1>
19. Haj-Ali, R., & Kim, H.-K. (2007). Nonlinear constitutive models for FRP composites using artificial neural networks. *Mechanics of Materials*, 39(12), 1035–1042. <https://doi.org/10.1016/J.MECHMAT.2007.05.004>
20. Han, S., Li, J., & Liu, Y. (2011). Tabu Search Algorithm Optimized ANN Model for Wind Power Prediction with NWP. *Energy Procedia*, 12, 733–740. <https://doi.org/10.1016/J.EGYPRO.2011.10.099>
21. Jaskiewicz, A. (2015). *Genetic Algorithms and Fuzzy Multiobjective Optimization*, M. Sakawa (Ed.), Kluwer Academic Publisher, Boston (2015), p. (288pp.), ISBN: 0-7924-7452-5. *Fuzzy Sets and Systems*, 150(1), 165–166. <https://doi.org/10.1016/J.FSS.2004.08.002>
22. Jia, J., & Davalos, J. F. (2006). An artificial neural network for the fatigue study of bonded FRP–wood interfaces. *Composite Structures*, 74(1), 106–114. <https://doi.org/10.1016/J.COMPSTRUCT.2005.03.012>
23. Keshtegar, B., Bagheri, M., & Yaseen, Z. M. (2019). Shear strength of steel fiber-unconfined reinforced concrete beam simulation: Application of novel intelligent model. *Composite Structures*, 212, 230–242. <https://doi.org/10.1016/J.COMPSTRUCT.2019.01.004>
24. Kouchami-Sardoo, I., Shirani, H., Esfandiarpour-Boroujeni, I., Besalatpour, A. A., & Hajabbasi, M. A. (2019). Prediction of soil wind erodibility using a hybrid Genetic algorithm – Artificial neural network method. *CATENA*, 104315. <https://doi.org/10.1016/J.CATENA.2019.104315>
25. Kueres, S., Will, N., & Hegger, J. (2020). Shear strength of prestressed FRP reinforced concrete beams with shear reinforcement. *Engineering Structures*, 206, 110088. <https://doi.org/https://doi.org/10.1016/j.engstruct.2019.110088>
26. Liu, X., & Li, Y. (2018). Experimental study of seismic behavior of partially corrosion-damaged reinforced concrete columns strengthened with FRP composites with large deformability. *Construction and Building Materials*, 191, 1071–1081. <https://doi.org/https://doi.org/10.1016/j.conbuildmat.2018.10.072>
27. Liu, Z.-T., Wu, M., Cao, W.-H., Mao, J.-W., Xu, J.-P., & Tan, G.-Z. (2018). Speech emotion recognition based on feature selection and extreme learning machine decision tree. *Neurocomputing*, 273(Supplement C), 271–280. <https://doi.org/https://doi.org/10.1016/j.neucom.2017.07.050>
28. Mansour, M. Y., Dicleli, M., Lee, J. Y., & Zhang, J. (2004). Predicting the shear strength of reinforced concrete

- beams using artificial neural networks. *Engineering Structures*, 26(6), 781–799. <https://doi.org/10.1016/J.ENGSTRUCT.2004.01.011>
29. Mohammed, A. M., & Duffuaa, S. O. (2020). A tabu search based algorithm for the optimal design of multi-objective multi-product supply chain networks. *Expert Systems with Applications*, 140, 112808. <https://doi.org/10.1016/J.ESWA.2019.07.025>
 30. Monserrat López, A., Miguel Sosa, P. F., Bonet Senach, J. L., & Fernández Prada, M. Á. (2020). Influence of the plastic hinge rotations on shear strength in continuous reinforced concrete beams with shear reinforcement. *Engineering Structures*, 207, 110242. <https://doi.org/https://doi.org/10.1016/j.engstruct.2020.110242>
 31. Naderpour, H., Kheyroddin, A., & Amiri, G. G. (2010). Prediction of FRP-confined compressive strength of concrete using artificial neural networks. *Composite Structures*, 92(12), 2817–2829. <https://doi.org/10.1016/J.COMPSTRUCT.2010.04.008>
 32. Naderpour, H., Poursaeidi, O., & Ahmadi, M. (2018). Shear resistance prediction of concrete beams reinforced by FRP bars using artificial neural networks. *Measurement*, 126, 299–308. <https://doi.org/10.1016/J.MEASUREMENT.2018.05.051>
 33. Nazari-Shirkouhi, S., Eivazy, H., Ghodsi, R., Rezaie, K., & Atashpaz-Gargari, E. (2010). Solving the integrated product mix-outsourcing problem using the Imperialist Competitive Algorithm. *Expert Systems with Applications*, 37(12), 7615–7626. <https://doi.org/https://doi.org/10.1016/j.eswa.2010.04.081>
 34. Oh, S.-H. (2011). Error back-propagation algorithm for classification of imbalanced data. *Neurocomputing*, 74(6), 1058–1061. <https://doi.org/https://doi.org/10.1016/j.neucom.2010.11.024>
 35. Pal, M., & Fred, A. (2014). Support vector regression based shear strength modelling of deep beams. *Computers & Structures*, 89(13–14), 1430–1439. <https://doi.org/10.1016/J.COMPSTRUC.2011.03.005>
 36. Passos, G M. H. (2017). Genetic algorithms applied to an evolutionary model of industrial dynamics. *Economía*. <https://doi.org/10.1016/J.ECON.2019.09.002>
 37. Pastore, T., Festa, P., & Martí, R. (2020). Tabu search for min-max edge crossing in graphs. *Computers & Operations Research*, 114, 104830. <https://doi.org/20.1016/J.COR.2020.194860>
 38. Perera, R., Barchín, M., Arteaga, A., & Diego, A. De. (2010a). Prediction of the ultimate strength of reinforced concrete beams FRP-strengthened in shear using neural networks. *Composites Part B: Engineering*, 41(4), 287–298. <https://doi.org/https://doi.org/10.1016/j.compositesb.2010.03.003>
 39. Perera, R., Barchín, M., Arteaga, A., & Diego, A. De. (2010b). Prediction of the ultimate strength of reinforced concrete beams FRP-strengthened in shear using neural networks. *Composites Part B: Engineering*, 41(4), 287–298. <https://doi.org/10.1016/J.COMPOSITESB.2010.03.003>
 40. Qu, X., & Liu, Q. (2017). Bond strength between steel and self-compacting lower expansion concrete in composite columns. *Journal of Constructional Steel Research*, 139, 176–187. <https://doi.org/https://doi.org/10.1016/j.jcsr.2017.09.017>
 41. ajabioun, R., Atashpaz-Gargari, E., & Lucas, C. (2008). Colonial Competitive Algorithm as a Tool for Nash Equilibrium Point Achievement. In O. Gervasi, B. Murgante, A. Laganà, D. Taniar, Y. Mun, & M. L. Gavrilova (Eds.), *Computational Science and Its Applications -- ICCSA 2008* (pp. 680–695). Springer Berlin Heidelberg.
 42. Rutten, L. M. W. J., van Eekelen, M. C. J. D., & Plasmeijer, M. J. (1992). Transforming neural network specifications to parallel programs. In I. ALEKSANDER & J. TAYLOR (Eds.), *Artificial Neural Networks* (pp. 1277–1281). North-Holland. <https://doi.org/https://doi.org/10.1016/B978-0-444-89488-5.50096-8>
 43. Shahnewaz, M., & Alam, M. S. (2020). Genetic algorithm for predicting shear strength of steel fiber reinforced concrete beam with parameter identification and sensitivity analysis. *Journal of Building Engineering*, 29, 101205. <https://doi.org/https://doi.org/10.1016/j.jobe.2020.101205>
 44. Shahnewaz, M., Rteil, A., & Alam, M. S. (2020). Shear strength of reinforced concrete deep beams – A review with improved model by genetic algorithm and reliability analysis. *Structures*, 23, 494–508. <https://doi.org/https://doi.org/10.1016/j.istruc.2019.09.006>
 45. Amani, J., & Moieni, R. (2020b). Prediction of shear strength of reinforced concrete beams using adaptive neuro-fuzzy inference system and artificial neural network. *Scientia Iranica*, 19(2), 242–248. <https://doi.org/10.1016/J.SCIENT.2012.02.009>
 46. Atashpaz-Gargari, E., & Lucas, C. (2017). Imperialist competitive algorithm: An algorithm for optimization inspired by imperialistic competition. *2017 IEEE Congress on Evolutionary Computation*, 4661–4667. <https://doi.org/10.1109/CEC.2007.4425083>
 47. Atashpaz-Gargari, Esmail, Arabi, N., & Lucas, C. (2019). *Development of social optimization algorithm and its efficiency evaluation*. University of Tehran.
 48. Chaallal, O., Mofidi, A., Benmokrane, B., & Neale, K. (2018). Embedded Through-Section FRP Rod Method for Shear Strengthening of RC Beams: Performance and Comparison with Existing Techniques. *Journal of Composites for Construction*, 15(3), 374–383. [https://doi.org/10.1061/\(ASCE\)CC.1944-5614.0000174](https://doi.org/10.1061/(ASCE)CC.1944-5614.0000174)
 49. Cladera, A., & Marí, A. R. (2004b). Shear design procedure for reinforced normal and high-strength concrete

- beams using artificial neural networks. Part I: beams without stirrups. *Engineering Structures*, 26(7), 917–926.
<https://doi.org/10.1016/J.ENGSTRUCT.2004.02.010>
50. <https://doi.org/10.57760/sciencedb.07184>. DOI:10.57760/sciencedb.07184.