

# تعیین مشخصات سازه با استفاده از پارامترهای مودال سازه و به‌کارگیری الگوریتم‌های بهینه‌سازی: ژنتیک، اجتماع ذرات و آموزش و یادگیری

شهاب امانت (کارشناس ارشد)

دانشکده‌ی مهندسی عمران، دانشکده‌گان فنی دانشگاه تهران، تهران

حامد خرازی (دانشجوی دکتری)

دانشکده‌ی مهندسی عمران، دانشگاه صنعتی شریف

مریم بیطرف\* (استادیار)

دانشکده‌ی مهندسی عمران، دانشکده‌گان فنی دانشگاه تهران، تهران

مهندسی عمران شریف، تابستان ۱۴۰۳ (۱۴۰۳)  
دوری، ۴۰، شماره ۲، صص. ۱۷-۲۸، (ژوئیه)

در پژوهش حاضر، به مقایسه‌ی دقت و سرعت همگرایی روش‌های فراابتکاری مختلف در تعیین سختی المان‌های سازه با استفاده از پارامترهای مودال سازه و تعریف یک تابع هدف مناسب پرداخته شده است. بدین منظور، دو قاب یک‌بندی ۳ طبقه و ۶ طبقه و یک خرپای دُبعدهی بررسی شده‌اند. روش‌های فراابتکاری، شامل: بهینه‌سازی ژنتیک، اجتماع ذرات، و آموزش و یادگیری است. تابع هدف، حاصل‌جمع دو عبارت توان دوم اختلاف بسامد اول سازه‌ی بررسی شده با بسامد اول سازه‌ی حاصل از ماتریس سختی فرضی در هر نسل و اندازه‌ی بردار اختلاف شکل مودی اول سازه‌ی مذکور و سازه‌ی حاصل از ماتریس سختی فرضی در هر نسل است. در الگوریتم‌های فراابتکاری استفاده شده، با کمینه‌سازی مقدار تابع هدف، مقدار سختی المان‌های سازه‌ها به دست آمده است، که کارایی بالای روش‌های فراابتکاری را در تعیین مشخصات مجهول سازه‌ها نشان می‌دهد. نتایج نشان می‌دهند که الگوریتم آموزش و یادگیری، بیشترین سرعت همگرایی و کمترین خطا را نسبت به سایر الگوریتم‌ها داشته است. الگوریتم اجتماع ذرات، سرعت و خطای قابل قبولی را نشان داده است. میزان خطای الگوریتم ژنتیک در مقایسه با دو الگوریتم دیگر قابل توجه بوده است.

واژگان کلیدی: پایش سلامت سازه‌ها، الگوریتم ژنتیک، الگوریتم اجتماع ذرات، الگوریتم آموزش و یادگیری.

## ۱. مقدمه

گسترش جمعیت و توسعه‌ی روزافزون فناوری، بشر را به سمت احداث زیرساخت‌های عمرانی متعددی، نظیر ساختمان‌های بلندمرتبه، پل‌ها، سد‌ها و غیره سوق داده است. زیرساخت‌های عمرانی ممکن است به مرور زمان در اثر بلاهای طبیعی و غیرطبیعی، مانند زلزله، باد، بار ترافیکی، و غیره دچار آسیب شوند. همچنین وجود عدم قطعیت‌ها و وقوع برخی از خطاها در طراحی و یا در حین اجرا اجتناب‌ناپذیر است. در نتیجه، به‌منظور کاهش خسارت‌های جانی و هزینه‌های نگهداری و همچنین افزایش عمر بهره‌برداری سازه، اهمیت کنترل و تحلیل آسیب

\* نویسنده مسئول

تاریخ: دریافت ۱۴۰۲/۳/۷، اصلاحیه ۱۴۰۲/۵/۸، پذیرش ۱۴۰۲/۵/۲۸.

استناد به این مقاله:

امانت، شهاب، خرازی، حامد، و بیطرف، مریم، ۱۴۰۳. تعیین مشخصات سازه با استفاده از پارامترهای مودال سازه و به‌کارگیری الگوریتم‌های بهینه‌سازی: ژنتیک، اجتماع ذرات، آموزش و یادگیری. مهندسی عمران شریف، ۴۰(۲)، صص. ۱۷-۲۸. DOI:10.24200/J30.2023.62232.3212

هزینه‌های مالی و زمانی، راستی‌آزمایی سیستم پایش سلامت صورت گیرد، تا در صورت نیاز اصلاح شود.

قسمت قابل توجهی از مطالعات در بخش پایش سلامت سازه‌ها، ارائه‌ی رویکرد مناسب به منظور تشخیص خرابی است. داده‌های به‌دست آمده از مدل‌های عددی، آزمایشگاهی و سایت‌های واقعی باید به درستی تحلیل و بررسی شوند تا موقعیت خرابی احتمالی را مشخص کنند. به این منظور، روش‌های متعددی در این زمینه پیشنهاد شده است؛ که بسیاری از آنها براساس تحلیل‌های آماری<sup>[۱۳]</sup>، روش‌های یادگیری ماشین<sup>[۱۴، ۱۵]</sup> و غیره هستند. این تذکر لازم است که در داده‌های برداشت شده از یک سازه، خطاهایی ناشی از عوامل محیطی، بهره‌برداری و غیره وجود دارد. در نتیجه، هر چه یک روش پیشنهادی به خطای موجود در داده‌ها حساسیت کمتری داشته باشد و بتواند خرابی احتمالی را به درستی با خطاهای موجود تشخیص دهد، کاربردی تر خواهد بود.

رویکرد استفاده شده در بسیاری از روش‌های موجود در ادبیات فنی پایش سلامت سازه‌ها، ارائه‌ی شیوه‌ای بوده است که اختلاف میان بسامدها و شکل‌های مودال یک سازه‌ی واقعی و مدل عددی آن را تحت بارگذاری دینامیکی به میزان کمیته برساند. به این منظور، یون<sup>۱</sup> و همکاران (۲۰۰۶)<sup>[۱۶]</sup> روشی برای به‌روزرسانی مدل سازه‌ی بیزی<sup>۲</sup> با استفاده از داده‌های مودال مربوط به بسامدهای طبیعی و شکل‌های مودال ارائه دادند. رویکرد آنها برای یافتن محتمل‌ترین مقادیر پارامترهای مدل ساختاری و مودال سیستم، استفاده از یک طرح تکراری، شامل یک سری مسائل بهینه‌سازی خطی جفت شده بوده است. روش ارائه شده‌ی ایشان نیاز به حل مسئله‌ی مقدار ویژه برای هر مدل ساختاری و تطبیق حالت‌های اندازه‌گیری شده با حالت‌های مرتبط از مدل ساختاری ندارد و برخلاف بسیاری از روش‌های موجود در ادبیات فنی است. با توجه به آنکه مدل اخیر چندان به نویز حساس نیست، به‌نظر می‌رسد مدل پیشنهادی ایشان از نظر قدرت محاسباتی مؤثر و مقاوم است.

پژوهشگران متعددی با استفاده از روش‌های بهینه‌سازی فراابتکاری و هوش مصنوعی سعی بر ارائه‌ی رویکردهایی نوین به‌منظور بررسی خرابی در سازه‌های عمرانی داشته‌اند. تیاچت<sup>۳</sup> و همکاران (۲۰۱۸)<sup>[۱۷]</sup> یک رویکرد کاربردی جدید مبتنی بر الگوریتم ژنتیک<sup>۴</sup> برای تشخیص آسیب در ساختارهای قاب سه‌بُعدی ارائه کردند. لذا یک قاب سه‌بُعدی ۲ طبقه را به‌عنوان یک مثال عددی برای شناسایی آسیب در سازه با استفاده از روش پیشنهادی خود بررسی کرده و نتایج به دست آمده هیچ خطایی در پیش‌بینی مکان آسیب نداشته است؛ با این حال یک خطای جزئی در تشخیص شدت آسیب مشاهده شده است. لذا دریافتند که الگوریتم ژنتیک، ابزاری کارآمد برای تعیین کیفی آسیب‌های منفرد و چندگانه با دقت بالا در ساختارهای قاب سه‌بُعدی است. لی<sup>۵</sup> و همکاران (۲۰۲۱)<sup>[۱۸]</sup> کارایی ۴ تابع هدف بر پایه‌ی بسامدهای طبیعی سازه را با استفاده از الگوریتم اجتماع ذرات (PSO)<sup>۶</sup> و روش اجزاء محدود<sup>۷</sup> در تشخیص آسیب مقایسه کردند. نتایج شبیه‌سازی به‌دست‌آمده، عملکرد و برتری تابع تناسب را برای سناریوی آسیب مفرد و چندگانه نشان داد.

پرز - رامیرز یک<sup>۸</sup> و همکاران (۲۰۱۷)<sup>[۱۹]</sup> با استفاده از یک راهبرد دو مرحله‌ای، شامل تحریک طبیعی سازه و حل یک مسئله‌ی بهینه‌سازی مبتنی بر الگوریتم ژنتیک، پارامترهای مودال را تخمین زدند و دقت و مؤثر بودن روش پیشنهادی خود را در ارزیابی پاسخ شبیه‌سازی شده‌ی یک سازه‌ی مرجع و نتایج حاصل از مطالعه‌ی یک ساختمان ۸ طبقه‌ای نشان دادند. بندرا<sup>۹</sup> و همکاران (۲۰۱۴)<sup>[۲۰]</sup> یک روش تشخیص الگوی خرابی مبتنی بر شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک ارائه

دادند، که می‌توانست با استفاده از توابع پاسخ بسامدی به‌طور مؤثری آسیب‌های غیرخطی را برای سطح معینی از تحریک تشخیص دهد. همچنین، ایشان نشان دادند که شبکه‌ی عصبی آموزش دیده با مجموع توابع پاسخ بسامدی به نتایج مطلوب‌تری در مقایسه با آموزش با توابع پاسخ بسامدی تک دست یافته و مدل مذکور قابلیت شناسایی خرابی غیرخطی در سازه‌ها را داشته است.

الکساندرینو<sup>۱۰</sup> و همکاران (۲۰۲۰)<sup>[۲۱]</sup> یک راهبرد دو مرحله‌ای برای شناسایی سیستمی سازه‌های عمرانی برای پایش سلامت سازه با استفاده از تبدیل موجک و الگوریتم ژنتیک، یک ساختمان واقعی ۸ طبقه را آزمایش کردند و دریافتند که راهبرد پیشنهادی‌شان می‌تواند پارامترهای مودال را دقیقاً تخمین بزند.

قنادی و همکاران (۲۰۲۳)<sup>[۲۲]</sup> از المان قاب با اتصال نیمه‌صلب به جای تیر اویار برنولی برای تشکیل مدل اجزاء محدود تیرآزمایشگاهی و تولید یک مدل عددی با کیفیت استفاده کردند و در آن با تعیین مقدار بهینه‌ی درجه‌ی صلبيت انتهایی اتصال‌ها با به‌کارگیری روش‌های بهینه‌سازی، تطبیق بیشتری میان نتایج آزمایشگاهی و عددی در مدل‌شان مشاهده شد. ایشان از دو تابع هدف، شامل: معیار اطمینان مودال کل اصلاح شده (MTMAC)<sup>۱۱</sup> و تغییرات در بسامدهای طبیعی استفاده کردند و با استفاده از سه روش بهینه‌سازی گرگ خاکستری (GWO)<sup>۱۲</sup>، بهینه‌سازی مبتنی بر گرادیان<sup>۱۳</sup> و روش تقویت شده‌ی گرگ خاکستری، به مقدار بهینه‌ی تابع هدف دست یافتند و روش تقویت شده‌ی گرگ خاکستری با معیار اطمینان مودال کل اصلاح شده در کمترین زمان به مطلوب‌ترین نتایج رسیده بود.

قنادی و کورهللی (۱۹۶۷)<sup>[۲۳]</sup> نیز از الگوریتم بهینه‌سازی کپک مخاطی<sup>۱۴</sup> و بهینه‌سازی شکارچیان دریایی<sup>۱۵</sup> جهت تعیین میزان خرابی در سازه‌هایی با مقیاس بزرگ استفاده و نتایج به دست آمده را با روش‌های بهینه‌سازی شیر مورچه<sup>۱۶</sup>، بهینه‌سازی نهنگ<sup>۱۷</sup> و بهینه‌سازی ملخ<sup>۱۸</sup> مقایسه کردند. آنها از سه تابع هدف، شامل: معیار اطمینان مودال<sup>۱۹</sup>، معیار اطمینان مودال کل اصلاح شده و معیار بردار بسامد طبیعی اطمینان<sup>۲۰</sup> جهت بهینه‌سازی تابع هدف استفاده کردند. سازه‌های بررسی شده‌ی عددی، شامل خرپای دو بُعدی با ۵۳ المان و برج تلویزیونی گوانگژو<sup>۲۱</sup> و نیز یک قاب ۳ طبقه با عنوان مطالعه‌ی آزمایشگاهی بودند و بهترین نتایج با استفاده از معیار اطمینان مودال کل اصلاح شده به‌عنوان تابع هدف و روش بهینه‌سازی تقویت شده‌ی کپک مخاطی به‌دست آمد. در مطالعه‌ی ایشان، روش بهینه‌سازی شکارچیان دریایی، علی‌رغم دستیابی به نتایج مطلوب، زمان اجرایی بیشتری نسبت به سایر روش‌های بهینه‌سازی داشت.

بی‌فی<sup>۲۲</sup> و همکاران (۲۰۲۳)<sup>[۲۴]</sup> روشی جدید برای شناسایی آسیب در سازه‌ها ارائه دادند که در آن از یک مدل‌سازی جایگزین پیشرفته برای تولید یک روش بهینه‌سازی ترکیبی، شامل: بهینه‌سازی خوشه‌بندی K میانگین<sup>۲۳</sup> و الگوریتم ژنتیک استفاده کرده بودند. هسته‌ی اصلی در روش مذکور، استفاده از روش قابل اعتماد و کم‌هزینه‌ی بسط چندجمله‌ای آشوب<sup>۲۴</sup> به‌عنوان جایگزینی برای مدل‌های اجزاء محدودی بود، که کارایی مناسبی در بهینه‌سازی تابع هدف داشت. ایشان کارایی و قابلیت اطمینان روش پیشنهادی‌شان را در برخورد با مشکلات به‌روزرسانی مدل‌های اجزاء محدودی و شناسایی آسیب در یک سد آزمایشگاهی با مقیاس کوچک بررسی کردند و دریافتند که روش پیشنهادی آنها می‌تواند به‌عنوان ابزاری بسیار کارآمد و بالقوه با همگرایی سریع و دقت بالا، برای شناسایی آسیب در سازه‌های بزرگ و پیچیده به‌کار رود.

به‌طورکلی امروزه در مطالعاتی گسترده، الگوریتم‌های بهینه‌سازی فراابتکاری برای حل مسائل مختلفی استفاده می‌شوند.<sup>[۲۵-۲۷]</sup> به‌عنوان مثال، کومار<sup>۲۵</sup> و همکاران (۲۰۲۲)<sup>[۲۸]</sup> یک بهینه‌سازی مبتنی بر آموزش و یادگیری چندهدفه براساس چارچوب

قطر اصلی، مقداری غیرصفر دارند. برخی از پژوهشگران بر این باورند در صورتی که مجموع درایه‌های هر سطر از ماتریس جرم را بر درایه‌ی قطر نظیر سطر مذکور قرار دهند و سایر اعداد آن سطر را برابر صفر قرار دهند، خطای قابل توجهی رخ نمی‌دهد.<sup>[۳۴]</sup> این تذکر لازم است که در سازه‌های ساختمانی معمولاً در بیشتر مواقع، درجه‌های آزادی به‌صورت گسسته است و در نتیجه‌ی آن، ماتریس جرم به‌صورت قطری خواهد بود.<sup>[۳۵]</sup>

ماتریس سختی برای المان‌های سازه‌ای مختلف به‌راحتی تعیین می‌شود. برای نمونه، ماتریس سختی یک المان محوری یک ماتریس  $2 \times 2$  است. همچنین ماتریس سختی یک المان تیر-ستون، یک ماتریس  $6 \times 6$  است. در این حالت با در دست داشتن مشخصاتی نظیر: سطح مقطع، ممان اینرسی المان، مدول کشسانی و طول المان به‌راحتی می‌توان درایه‌های متناظر با ماتریس سختی را تشکیل داد. شایان ذکر است که در پژوهش حاضر از میرایی در المان‌ها چشم‌پوشی شده است. در صورتی که سازه‌ای تحت اثر یک زلزله‌ی شدید قرار گیرد، به احتمال زیاد دچار آسیب می‌شود. معمولاً پس از زلزله، ماتریس جرم تغییر چندانی نمی‌کند، اما به دلیل ایجاد زوال در سازه، سختی المان‌ها کاهش می‌یابد. منظور از زوال در المان‌ها، وقوع ترک در سازه‌های بتنی و یا تسلیم موضعی در مقاطع فولادی است. در این حالت باید سختی سازه بررسی شود و در صورت نیاز، اقدام‌های لازم به‌منظور بهسازی آن صورت پذیرد. بنابراین مسئله‌ی ذکر شده، تبدیل به تعیین ماتریس سختی پس از آسیب ناشی از زلزله می‌شود.

در صورتی که ماتریس سختی سازه‌ی آسیب دیده مشخص شود، به‌راحتی می‌توان محل خرابی در سازه، مشخصات و رفتار سازه را تعیین کرد. همچنین می‌توان پاسخ سازه را تحت هر بارگذاری دلخواه تعیین کرد. در این حالت، در صورتی که معیارهای طراحی و آیین‌نامه ارضا نشوند، می‌توان از روش‌های متعدد بهسازی برای تقویت سازه استفاده کرد.

## ۲.۱. کاربرد سیستم پایش سلامت سازه‌ها در تعیین مشخصات

### دینامیکی

در صورت استفاده از سیستم پایش سلامت سازه، با تعبیه‌ی حسگر در بخش‌های مختلف سازه می‌توان شتاب را در درجه‌های آزادی مختلف به‌دست آورد. با استفاده از داده‌های اخیر و روش‌های متعدد می‌توان بسامدها و شکل‌های مودی سازه را تعیین کرد.<sup>[۳۶]</sup> یکی از روش‌های رایج به‌منظور تعیین بسامدها و شکل‌های مودی سازه با استفاده از داده‌های به دست آمده از حسگرها، روش تجزیه‌ی دامنه‌ی بسامد یا FDD<sup>۲۸</sup> است. روش FDD، یک شیوه‌ی شناسایی مشخصات مودال سازه براساس رکورد خروجی سازه است و با استفاده از روش تجزیه‌ی مقدار منفرد<sup>۲۹</sup>، از چگالی طیفی توان<sup>۳۰</sup> خروجی سازه، مشخصات مودال آن را محاسبه می‌کند.<sup>[۳۷]</sup> با توجه به آنکه بیشتر داده‌های ثبت شده در اثر بارگذاری محیطی، نظیر ورزش باد هستند، معمولاً با استفاده از روش‌های مذکور فقط امکان تعیین چندین بسامد طبیعی و شکل‌های مودی اول سازه است، که علت آن تحریک نشدن بسامدهای بالاتر در بارگذاری محیطی است. به‌عبارت دیگر، برای تحریک مودهای موردنظر، نیاز به اعمال بارگذاری خارجی است و در نتیجه‌ی آن، ساخت یک سیتاپ<sup>۳۱</sup> آزمایشی اجتناب‌ناپذیر است. تجهیزات موردنیاز هزینه‌بر است، که چندان توجه اقتصادی ندارند. بنابراین با در نظر گرفتن پاسخ‌های ناشی از بارگذاری محیطی می‌توان اطلاعات چندین مود اول سازه را تعیین کرد.

بنابراین توقع می‌رود که با استفاده از سیستم پایش سلامت سازه‌ها بتوان بسامد و

مرتب‌سازی غیرمسلط<sup>۲۶</sup> و ذخیره‌سازی راه‌حل در یک آرشیو خارجی برای دست‌یابی به سازه‌ی با مشخصات مطلوب پیشنهاد کرده‌اند؛ که علاوه بر بهبود سرعت جستجو و نرخ همگرایی الگوریتم، دست‌یابی به مجموعه‌ی بهینه‌ی پرتو نزدیک به راه‌حل‌های پرتو واقعی را میسر می‌سازد.

در مسائلی با تعداد متغیر اندک و تابع هدف ساده، استفاده از الگوریتم‌های بهینه‌سازی کلاسیک به راحتی ممکن است؛ اما زمانی که تعداد متغیرها قابل توجه باشد و یا تابع هدف مسئله به‌صورت غیرخطی و پیچیده باشد، روش‌های فراابتکاری کارایی بهتری خواهند داشت. هدف از پژوهش حاضر، ارائه‌ی رویکردی ساده و نوین برای تشخیص آسیب در مسائل پیچیده‌ی سازه‌ی است. تمرکز پژوهش حاضر بر مقایسه‌ی دقت و سرعت همگرایی الگوریتم‌های بهینه‌سازی فراابتکاری مختلف بوده است. همچنین سعی شده است تا با استفاده از الگوریتم‌های بهینه‌سازی ژنتیک،<sup>[۳۸،۳۹]</sup> اجتماع ذرات<sup>[۴۰]</sup> و آموزش و یادگیری (TLBO)<sup>[۲۷،۳۳،۳۲]</sup> رویکردی برای شناسایی محل و میزان آسیب در سازه‌های عمرانی بر پایه‌ی مشخصات مودال سازه ارائه شود. در اثر آسیب‌های وارده بر سازه‌های عمرانی، ماتریس جرم تغییر قابل ملاحظه‌ای نمی‌کند. در حقیقت، آسیب‌های وارده بر سازه، سبب تغییر قابل توجهی در ماتریس سختی سازه می‌شود. بنابراین در پژوهش حاضر، درگام اول با استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری و تعریف تابع هدف مناسب، پس از کمیته‌سازی تابع هدف، ماتریس سختی سازه‌ی آسیب‌دیده محاسبه و سپس با استفاده از آن، محل و میزان هرگونه خرابی در سازه مشخص شده است. به‌منظور بررسی عددی رویکرد مذکور، کارایی روش پیشنهادی برای هر سه الگوریتم بهینه‌سازی، با استفاده از مدل‌های عددی تحت بارگذاری دینامیکی مشخص کنترل شده است. نوآوری پژوهش حاضر، ارائه‌ی رویکردی بوده است که بتوان با کمیته‌سازی تابع هدفی متشکل از بسامد و مود شکل اول سازه، سختی المان‌ها یا طبقات سازه را مستقیماً تعیین کرد. رویکرد مذکور در واقع مقدار سختی المان‌ها را به گونه‌ای تعیین می‌کند که مشخصات مودال سازه‌ی تعیین شده توسط آن، بیشترین تطابق را با مشخصات مودال سازه‌ی واقعی (حاصل از آنالیز نتایج به‌دست آمده از حسگرهای متصل بر سازه) داشته باشد. همچنین در پژوهش حاضر، به مقایسه‌ی دقت و سرعت همگرایی روش‌های فراابتکاری مختلف، شامل: بهینه‌سازی ژنتیک، اجتماع ذرات و آموزش و یادگیری در تعیین سختی المان‌های ۳ سازه‌ی مختلف، شامل: قاب یک‌بندی ۳ طبقه، قاب یک‌بندی ۶ طبقه و یک خرپای دو‌بندی پرداخته شده است. از آنجایی که رویکرد ارائه شده بر کمیته‌سازی یک تابع هدف مشخص تلاش می‌کند، برخلاف بسیاری از روش‌های موجود در ادبیات فنی نسبت به خطاهای محیطی حساسیت کمتری دارد.

## ۱.۱. تعریف مسئله

بررسی و تحلیل سازه‌ها، با در دست داشتن مشخصات سازه به آسانی ممکن است. منظور از مشخصات سازه، ماتریس‌های جرم، سختی و میرایی است. در صورت مشخص شدن ماتریس‌های مذکور، می‌توان مشخصات مودال سازه، نظیر بسامدهای طبیعی و شکل‌های مودی را برای سازه تعیین کرد. همچنین در این حالت به‌راحتی می‌توان پاسخ سازه را نسبت به هر نوع بارگذاری دلخواه مشخص کرد.

ماتریس جرم سازه، از جرم المان‌های تشکیل‌دهنده‌ی سازه حاصل می‌شود. در صورتی که درجه‌های آزادی به‌صورت گسسته باشند، معمولاً ماتریس جرم به‌صورت یک ماتریس قطری است. اما در صورتی که سازه با استفاده از درجه‌های آزادی پیوسته مدل شود، ماتریس جرم از حالت قطری خارج می‌شود و درایه‌های خارج از

شکل مودی اول سازه را تعیین کرد. در پژوهش حاضر، با ارائه‌ی رویکردی با استفاده از اطلاعات بسامدی مود اول، ماتریس سختی سازه تعیین شده است. پس از تعیین اطلاعات مودال سازه، میان ماتریس سختی و ماتریس جرم، رابطه‌ی ۱ برقرار است:

$$[K]_{n \times n} [\phi]_{n \times n} = [M]_{n \times n} [\Omega^2]_{n \times n} [\phi]_{n \times n} \quad (1)$$

که در آن،  $[K]$  ماتریس سختی،  $[M]$  ماتریس جرم،  $[\phi]$  ماتریسی شامل بردارهای شکل‌های مودی و  $[\Omega^2]$  ماتریس قطری شامل توان دوم بسامدهای طبیعی سازه هستند، که ابعاد همه‌ی آنها  $n \times n$  است ( $n$  تعداد درجه‌های آزادی است).

در صورتی که فقط برای بسامد و شکل مودی اول، رابطه‌ی ۱ در نظر گرفته شود، با استفاده از رابطه‌ی ۲، به تعداد درجه‌های آزادی، معادله به دست می‌آید:<sup>[۳۵]</sup>

$$[K]_{n \times n} \{\varphi_1\}_{n \times 1} = \omega_1^2 [M]_{n \times n} \{\varphi_1\}_{n \times 1} \quad (2)$$

که در آن،  $\{\varphi_1\}$  و  $\omega_1$  به ترتیب شکل مودی و بسامد طبیعی اول سازه هستند. با در دست داشتن ماتریس جرم، بسامد و شکل مودی اول سازه، به تعداد درجه‌های آزادی، معادله حاصل می‌شود. این در حالی است که تعداد مجهولات در ماتریس سختی برابر مجذور درجه‌های آزادی ( $n^2$ ) است، که در صورت استفاده از تقارن در ماتریس سختی، تعداد مجهولات به  $(n^2 + n)/2$  تقلیل می‌یابد. با توجه به آنکه همواره تعداد درجه‌های آزادی بزرگ‌تر یا مساوی ۱ است، لذا همواره تعداد مجهولات از تعداد معادله‌ها در رابطه‌ی ۲ بیشتر است. با توجه به آنکه هر مود سازه،  $n$  معادله را تشکیل می‌دهد، به منظور تعیین تمامی درایه‌های ماتریس سختی، فقط نیاز به مشخصات  $(n + 1)/2$  مود سازه است. در صورتی که از ابتدا فرض شود که ماتریس سختی یک ماتریس قطری است، آنگاه می‌توان مسئله را به صورت تحلیلی نیز حل کرد؛ البته باید به این نکته توجه شود که در این حالت یک قید بسیار محدودکننده، قطری بودن ماتریس سختی، از همان ابتدا اعمال شده است، که الزاماً به پاسخ صحیحی نمی‌رسد.

به اصطلاح، به حالتی از دستگاه معادلات که تعداد مجهولات از تعداد معادلات کمتر باشد، دستگاه فرامعین<sup>۳۲</sup> می‌گویند. برای حل این دسته از معادلات معمولاً سراغ انواع روش‌های بهینه‌سازی می‌روند. در این حالت، یک تابع هدف از پیش تعیین شده تعریف و با سعی و خطا در فرض مجهولات، تابع هدف مذکور، کمینه می‌شود. در مسئله‌ی مطرح شده در پژوهش حاضر هدف آن است که ماتریس سختی سازه براساس کمینه‌سازی یک تابع هدف مناسب و با استفاده از چندین روش بهینه‌سازی فراابتکاری، مانند: الگوریتم ژنتیک، اجتماع ذرات، و آموزش و یادگیری تعیین شود.

### ۳.۱. الگوریتم‌های بهینه‌سازی

امروزه در بسیاری از مسائل مهندسی، یافتن پاسخ به روش‌های کلاسیک غیرممکن و یا با صرف هزینه و زمان زیادی ممکن است. یکی از راه‌های کاهش هزینه، استفاده از الگوریتم‌های بهینه‌سازی برای دستیابی به جواب بهینه است. دسته‌ای از الگوریتم‌های بهینه‌سازی ذکر شده، الگوریتم‌های فراابتکاری هستند، که با الهام از طبیعت زنده و یا طبیعت بی‌جان، سعی در حل مسائل بهینه‌سازی دارند. از جمله‌ی آنها می‌توان به الگوریتم ژنتیک، الگوریتم اجتماع ذرات، الگوریتم آموزش و یادگیری، الگوریتم مورچه‌گان و ... اشاره کرد.

#### ۱.۳.۱. الگوریتم ژنتیک

ارائه‌ی الگوریتم ژنتیک به اواخر دهه‌ی ۸۰ میلادی باز می‌گردد و از آن زمان تاکنون نسخه‌های متنوعی از آن ارائه شده است. الگوریتم ژنتیک، اولین بار توسط جان

هلند<sup>۳۳</sup> در اوایل دهه‌ی ۷۰ میلادی ارائه شده است؛ وی در سال ۱۹۷۵ میلادی با معرفی یک کتاب، الگوریتم ژنتیک را به جهان معرفی کرد، که البته در ابتدا مورد استقبال چندانی واقع نشد.<sup>[۳۴]</sup> پس از وی گلدبرگ (۱۹۸۹)<sup>[۳۴]</sup> و برخی دیگر از دانشمندان با تلاش‌های خود، الگوریتم ژنتیک را بهبود و کاربردی‌تر ساختند و با انتشار کتاب‌های متعددی با هدف ارائه‌ی نسخه‌های اصلاح شده‌ی خود، الگوریتم ژنتیک را به یکی از متداول‌ترین روش‌های حل مسائل بهینه‌سازی تبدیل کردند. به‌طور کلی نظریه‌ی ژنتیک براساس سیر تکامل طبیعی جانداران با الهام از نظریه‌ی داروین ابداع شده است.

الگوریتم ژنتیک براساس سیر تکاملی جانداران در طبیعت ارائه و در آن از دو مفهوم کروموزوم و ژن استفاده می‌شود، که عبارت‌اند از:

**کروموزوم:** یک کروموزوم، یک رشته از اعداد یا یک ماتریس است، که می‌توان هر عضو از جمعیت را با آن مشخص کرد. در اصل می‌توان گفت که هر بردار در فضای مسئله را می‌توان با یک کروموزوم نمایش داد.

**ژن:** هر کروموزوم از تعدادی ژن تشکیل شده است، که با توجه به نوع الگوریتم، یک یا چند ژن می‌توانند یک متغیر مسئله را تعیین کنند.

سه عملگر اصلی الگوریتم ژنتیک، انتخاب طبیعی<sup>۳۵</sup>، ادغام<sup>۳۶</sup> و جهش<sup>۳۷</sup> هستند، که در ادامه شرح داده شده‌اند:<sup>[۳۸]</sup>

-- **انتخاب طبیعی:** این عملگر براساس قانون جنگل در هر گام از بین جمعیت نسل والدین و نسل فرزندان، نسل والدین جدید را انتخاب می‌کند. عملگر انتخاب طبیعی، در حالت ایده‌آل باید احتمال انتخاب جمعیت مناسب‌تر (دارای تابع هدف بهتر) را بیشتر از جمعیت نامناسب قرار دهد، اما باید به‌گونه‌ای باشد که امکان انتخاب تمام جمعیت وجود داشته باشد تا از نخیه‌گرایی اجتناب شود. پس از محاسبه‌ی تابع هدف هر یک از کروموزوم‌ها و مرتب‌کردن آنها از کمترین به بیشترین مقدار، انتخاب والد براساس یکی از روش‌های انتخاب والد از بالا به پایین<sup>۳۸</sup>، انتخاب تصادفی والد<sup>۳۹</sup> و یا انتخاب تصادفی وزن‌دار<sup>۴۰</sup> انجام می‌شود. روش انتخاب تصادفی وزن‌دار والدین از مزایای دو روش دیگر استفاده می‌کند.

-- **ادغام:** پس از انتخاب نسل والدین با استفاده از عملگر انتخاب طبیعی، نوبت به تولید فرزندان اولیه می‌رسد. این کار با اعمال عملگر ادغام صورت می‌گیرد. در این مرحله، به‌صورت تصادفی عضوهای جمعیت به دسته‌های دوتایی تقسیم می‌شوند و کروموزوم‌های دو عضو هر دسته با جابه‌جا کردن ژن‌های خود، نسل فرزندان اولیه را تشکیل می‌دهند.

-- **جهش:** در طبیعت پدیده‌ای به نام جهش به این صورت رخ می‌دهد که گاهی از یک پدر و مادر، فرزندی کاملاً متفاوت زاده می‌شود. به‌منظور اعمال این پدیده‌ی طبیعی در الگوریتم ژنتیک، از عملگر جهش استفاده می‌شود، که با انتخاب تعداد اندکی از ژن‌های جمعیت فرزندان اولیه، در آنها تغییری به‌صورت تصادفی صورت می‌گیرد.

در پژوهش حاضر از جعبه‌ابزار ارائه شده توسط چیرفیلد<sup>۴۱</sup> و همکاران (۱۹۹۴)<sup>[۳۹]</sup> استفاده شده است و پارامترهای در نظر گرفته شده برای الگوریتم ژنتیک مطابق جدول ۱ هستند. شایان ذکر است که در پژوهش حاضر، هر یک از پارامترها پس از چند بار اجرای الگوریتم ژنتیک با در نظر گرفتن سرعت مناسب همگرایی تعیین شده‌اند.

جدول ۱. پارامترهای الگوریتم ژنتیک استفاده شده در پژوهش حاضر.

پارامتر	مقدار
تعداد جمعیت	۱۰۰
تکرار نسل	۱۰۰
درصد تفاوت نسل‌ها	۰/۸
درصد ادغام	۰/۷

جدول ۲. پارامترهای الگوریتم اجتماع ذرات استفاده شده در پژوهش حاضر.

پارامتر	مقدار
تعداد جمعیت	۱۰۰
تکرار نسل	۱۰۰
پارامتر شناختی	۱/۴۹۶۲
پارامتر اجتماعی	۱/۴۹۶۲
اینرسی وزنی	۰/۷۲۹۸

### ۲.۳.۱. الگوریتم اجتماع ذرات

در تدوین الگوریتم اجتماع ذرات از پرواز گروهی پرندگان، شنای گروهی ماهی‌ها، و زندگی اجتماعی آنها الهام گرفته شده است، که با استفاده از یک سری روابط ساده فرمول‌بندی می‌شود. نظیر سایر الگوریتم‌های تکاملی دیگر، الگوریتم اجتماع ذرات نیز با ایجاد یک جمعیت تصادفی از افراد، که در اینجا به عنوان مثال یک گروه از ذرات خواننده می‌شوند، آغاز می‌شود. مشخصات هر ذره در گروه براساس مجموعه‌ای از پارامترها تعیین می‌شود، که باید مقادیر بهینه‌ی آنها تعیین شود. در روش کنونی، هر ذره یک نقطه از فضای جواب مسئله را نشان می‌دهد. هر کدام از ذرات، حافظه دارند و بهترین موقعیتی که در فضای جستجو به آن می‌رسند را به خاطر می‌سپارند. بنابراین حرکت هر ذره در دو جهت صورت می‌گیرد: [۳۱]

• به سوی بهترین موقعیتی که تاکنون اختیار کرده است؛

• به سوی بهترین موقعیتی که همه‌ی ذرات تا به حال اختیار کرده‌اند.

در این روش، تغییر موقعیت هر ذره در فضای جستجو تحت تأثیر تجربه و دانش خود و همسایگان است. در مجموع با رابطه‌ی ۳، روش اجتماع ذرات به سمت جواب بهینه حرکت می‌کند:

$$X_i^{(t+1)} = X_i^t + wV_i^t + C_1 \text{rand}(0; 1)(pbest_i - X_i^t) + C_2 \text{rand}(0; 1)(gbest_i - X_i^t) \quad (3)$$

که در آن  $X_i^t$  موقعیت کنونی ذره،  $X_i^{(t+1)}$  موقعیت ذره در تکرار جدید،  $pbest_i$  بهترین موقعیتی که ذره‌ی  $i$  تاکنون اختیار کرده و  $gbest_i$  بهترین موقعیت بهترین ذره (بهترین موقعیتی که تمام ذرات تاکنون اختیار کرده‌اند) است.  $\text{rand}(0, 1)$  یک عدد تصادفی بین ۰ و ۱ است، که برای حفظ تنوع و گوناگونی گروه به کار می‌رود.  $C_1$  و  $C_2$  به ترتیب پارامترهای شناختی و اجتماعی هستند. انتخاب مقدار مناسب برای پارامترهای  $C_1$  و  $C_2$  منجر به تسریع همگرایی الگوریتم و جلوگیری از همگرایی زودرس در بهینه‌های محلی می‌شود. مطالعات اخیر نشان می‌دهند که انتخاب مقدار بزرگ‌تری برای پارامتر شناختی  $C_1$  نسبت به پارامتر اجتماعی  $C_2$  مناسب‌تر است، اما باید همواره شرط  $C_1 + C_2 > 4$  رعایت شود. پارامتر  $w$  اینرسی وزنی نام دارد، که برای تضمین همگرایی در اجتماع ذرات به کار می‌رود. اینرسی وزنی، جهت کنترل تأثیر سوابق سرعت‌های پیشین در سرعت‌های جاری استفاده می‌شود.

کد استفاده شده برای پیاده‌سازی الگوریتم اجتماع ذرات در پژوهش حاضر، توسط نویسندگان در نرم‌افزار متلب <sup>۴۲</sup> پیاده‌سازی و پارامترهای آن در جدول ۲ ارائه شده است. این تذکر لازم است که در پژوهش حاضر هر یک از مسائل بررسی شده در ابتدا، چندین بار به ازاء مقادیر پارامترهای مختلف با به کارگیری الگوریتم اجتماع ذرات اجرا شده است، تا مقادیر مناسب آنها که مسئله با سرعت مناسبی همگرا شود، تعیین شود.

جدول ۳. پارامترهای الگوریتم آموزش و یادگیری استفاده شده در پژوهش حاضر.

پارامتر	مقدار
تعداد جمعیت	۱۰۰
تکرار نسل	۱۰۰

### ۳.۳.۱. الگوریتم آموزش و یادگیری

یکی از جدیدترین الگوریتم‌های مبتنی بر مقدار میانگین، الگوریتم مبتنی بر آموزش و یادگیری است، که از نوشتار راو<sup>۴۳</sup> و همکاران (۲۰۱۱) و براساس فرایند آموزش و یادگیری رخ داده در کلاس درس الهام گرفته شده است. [۳۲]

الگوریتم آموزش و یادگیری به دلیل داشتن پارامترهای کنترلی محدود، روشی ساده برای بهینه‌سازی مسائل است و قدرت بالایی در دستیابی به جواب بهینه دارد و از دو مرحله‌ی اصلی آموزش دهنده (معلم) و آموزش گیرنده (دانش آموز) تشکیل شده است. در روش حاضر، بهترین عضو جمعیت به عنوان معلم و بقیه‌ی اعضاء جمعیت به عنوان دانش آموز در نظر گرفته می‌شوند. در واقع، در روش اخیر، معلم به معنای واقعی وجود ندارد و در هر مرحله بهترین عضو جمعیت به عنوان معلم انتخاب می‌شود. در اینجا مراحل الگوریتم آموزش و یادگیری تشریح شده است:

مرحله‌ی آموزش دهنده (معلم): در این مرحله، معلم که در واقع همان بهترین عضو جمعیت است، سعی دارد با آموزش، علم دانش‌آموزان را افزایش دهد و میانگین را به سمت خود جذب کند. اگر بهترین فرد، به عنوان معلم در نظر گرفته شود، در بهترین حالت می‌توان در نظر گرفت که میانگین کلاس، پس از آموزش بر میانگین معلم منطبق خواهد شد. این فرض فقط یک فرض ایده‌آل است، که احتمال رخ دادن آن ناچیز است. زیرا در صورت برابری میانگین با معلم، گویی علم تمامی دانش‌آموزان پس از آموزش برابر با علم معلم شده است، که تقریباً غیرممکن است. در واقع می‌توان فرض کرد که میانگین دانش‌آموزان پس از آموزش افزایش یافته و مقدار آن به معلم نزدیک شده است، ولی از آن کمتر بوده است. این فرض منطقی‌تر و به واقعیت نزدیک‌تر است.

مرحله‌ی آموزش گیرنده (دانش آموز): در این مرحله، که پس از آموزش توسط معلم رخ می‌دهد، بحث، حل تمرین و همفکری دانش‌آموزان سبب افزایش سطح علمی آنها می‌شود. در واقع، از تعامل میان دانش‌آموزان، یادگیری متقابل به وجود می‌آید.

کد استفاده شده برای پیاده‌سازی الگوریتم آموزش و یادگیری توسط نویسندگان در نرم‌افزار متلب پیاده شده و پارامترهای در نظر گرفته شده برای اجرای آن در جدول ۳ خلاصه شده‌اند. این تذکر لازم است که در پژوهش حاضر هر یک از مسائل مورد بررسی در ابتدا چند بار به ازاء مقادیر پارامترهای مختلف با به کارگیری الگوریتم آموزش و یادگیری اجرا شده است، تا مقادیر مناسب آنها که مسئله با سرعت مناسبی همگرا شود، تعیین شود.

#### ۴.۱. تابع هدف

فرض می‌شود که مقدار هر یک از پارامترهای واقعی مربوط به جرم و سختی در سازه آسیب دیده پس از زلزله مطابق جدول ۴ است. این تذکر لازم است که انتظار می‌رود با الگوریتم‌های ذکر شده، مقادیر مشابه سختی طبقات موجود در جدول ۴ با استفاده از ماتریس جرم و مود اول سازه با اندکی خطا حاصل شود. سیستم پایش سلامت، بسامد طبیعی، و شکل مودی اول سازه ۳ طبقه را پس از آنالیزهای بیان شده در بخش ۲.۱ مطابق رابطه ۵ گزارش داده است:

$$\omega = 16,6015 \text{ rad/s} \quad \{\varphi_1\} = \begin{Bmatrix} 0,4123 \\ 0,7588 \\ 1 \end{Bmatrix} \quad (5)$$

#### ۲.۵.۱. سازه‌ی ۶ طبقه

همچنین در پژوهش حاضر، یک سازه‌ی ۶ طبقه با جرم‌های متمرکز برای طبقات مطابق شکل ۲ در نظر گرفته شده است. با فرض مجهول بودن سختی طبقات در سازه ۶ طبقه، تعداد متغیرهای مسئله برابر تعداد طبقات و یا به عبارتی دیگر برابر با ۶ است.

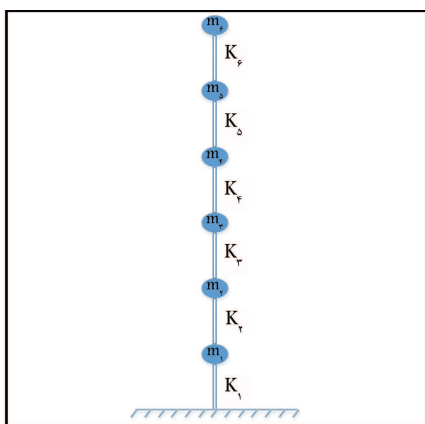
فرض شده است که مقدار هر یک از پارامترهای واقعی مربوط به جرم و سختی در سازه‌ی آسیب دیده پس از زلزله مطابق جدول ۵ است. شایان ذکر است که انتظار می‌رود با الگوریتم‌های ذکر شده، مقادیر مشابه سختی طبقات موجود در جدول ۵ با

جدول ۴. مشخصات سازه‌ی ۳ طبقه.

طبقه	جرم (ton.f)	سختی (kN/m)
۱	۵۰	۶۰۰۰۰
۲	۴۵	۵۵۰۰۰
۳	۳۵	۴۰۰۰۰

جدول ۵. مشخصات سازه‌ی ۶ طبقه.

طبقه	جرم (ton.f)	سختی (kN/m)
۱	۶۰	۸۰۰۰۰
۲	۶۰	۸۰۰۰۰
۳	۵۵	۷۵۰۰۰
۴	۵۰	۷۰۰۰۰
۵	۴۵	۶۰۰۰۰
۶	۳۰	۴۵۰۰۰



شکل ۲. شکل شماتیک سازه‌ی ۶ طبقه.

برای استفاده از هر یک از روش‌های الگوریتم ژنتیک، اجتماع ذرات و آموزش و یادگیری نیاز به تعریف یک تابع هدف دارد تا پس از چند نسل با کمینه‌سازی تابع هدف، مقدار بهینه‌ی پاسخ حاصل شود. جهت تعیین ماتریس سختی در سازه‌ای با ماتریس جرم مجهول و بسامد و مود شکل اول معلوم، تابع هدف توسط رابطه ۴ تعریف می‌شود: [۱۶]

$$f = (\omega^* - \omega)^2 + \|\{\varphi^*\} - \{\varphi\}\| \quad (4)$$


که در آن،  $f$  تابع هدف،  $\omega^*$  و  $\{\varphi^*\}$  به ترتیب بسامد و مود شکل اول سازه با ماتریس سختی فرضی در هر نسل،  $\omega$  و  $\{\varphi\}$  به ترتیب بسامد و مود شکل اول سازه حاصل از سیستم پایش سلامت هستند. علامت  $\|\cdot\|$  نیز نرم یا اندازه‌ی بردار است.

#### ۵.۱. سازه‌های بررسی شده

در پژوهش حاضر دو سازه‌ی ۳ و ۶ طبقه، همراه با یک خرابی ۶ المانی بررسی شده‌اند. در ادامه، مشخصات هر کدام از سازه‌ها بیان شده است. هدف مسئله در سازه‌های ۳ و ۶ طبقه‌ای، تعیین سختی المان‌ها و در سازه‌ی خرابی تعیین سطح مقطع المان‌ها با استفاده از الگوریتم‌های بهینه‌سازی و به‌کارگیری مشخصات مودال سازه مطابق با تابع هدف ارائه شده است. در حقیقت، یک سیستم مشخص که مشخصات مودال آن معلوم است، با الگوریتم‌های ذکر شده، ارزیابی و تطابق مشخصات المان‌های به‌دست‌آمده با مقادیر واقعی بررسی می‌شود. از آنجایی که روش موردنظر قابل تعمیم به هر سازه‌ای است، سازه‌های موردنظر توسط نویسندگان به‌منظور بررسی کارایی، دقت، و سرعت همگرایی الگوریتم‌های موردنظر در نظر گرفته شده‌اند. قیود هر مسئله، شامل شرایط مرزی تکیه‌گاهی است، که در هر مسئله با استفاده از کد تحلیل سازه اعمال می‌شوند. شایان ذکر است که هدف از پژوهش حاضر، نشان دادن توانایی روش‌های موردنظر در تشخیص خرابی المان‌های سازه‌ای است؛ لذا مقادیر اولیه‌ی سختی المان‌ها یا طبقات با فرض مهندسی در نظر گرفته شده‌اند.

#### ۱.۵.۱. سازه‌ی ۳ طبقه

در بخش حاضر، یک سازه‌ی ۳ طبقه که جرم‌های هر طبقه به‌صورت متمرکز هستند، بررسی شده است و شکل شماتیک آن در شکل ۱ مشاهده می‌شود. با فرض مجهول بودن سختی طبقات در سازه‌ی ۳ طبقه، تعداد متغیرهای مسئله برابر تعداد طبقات و یا به عبارتی دیگر برابر با ۳ است.




شکل ۱. شکل شماتیک سازه‌ی ۳ طبقه.

$$\omega = ۱,۳۴۹ rad/s \quad \{\varphi_1\} = \begin{Bmatrix} ۰,۳۹۶۶ \\ ۰,۱۷۳۱ \\ ۰,۵۹۷۳ \\ ۰,۰۷۳۸ \\ ۱ \\ ۰,۱۸۹۹ \end{Bmatrix} \quad (۷)$$

## ۲. نتایج و بحث

در شکل ۴، نمودار همگرایی تابع هدف سازه‌ی ۳ طبقه در هر گام برای ۳ روش الگوریتم ژنتیک، اجتماع ذرات و آموزش و یادگیری مقایسه شده است، که مطابق آن، می‌توان به عملکرد بهتر و سرعت همگرایی بیشتر در الگوریتم‌های اجتماع ذرات و آموزش و یادگیری پی برد. همان‌طور که مشخص است، الگوریتم‌های اجتماع ذرات و آموزش و یادگیری به ترتیب در کمتر از ۶۰ و ۳۰ نسل عملاً به نتیجه‌ی مطلوب رسیده‌اند. این در حالی است که روش الگوریتم ژنتیک پس از گذشت بیش از حدوداً ۶۰ نسل به پاسخ نامطلوب‌تری نسبت به اجتماع ذرات و آموزش و یادگیری رسیده است. میزان تابع هدف در تکرار آخر به ازاء هر یک از الگوریتم‌های ژنتیک، اجتماع ذرات، و آموزش و یادگیری به ترتیب برابر  $۸ \times ۱۰^{-۵}$ ،  $۳ \times ۱۰^{-۵}$  و  $۵ \times ۱۰^{-۵}$  بوده است. شایان ذکر است که در اجرای مجدد هر یک از الگوریتم‌ها، ممکن است عملکرد روش‌های ذکر شده نسبت به یکدیگر تغییر کند. پس از چند بار اجرای الگوریتم‌ها، مقدار متوسط مدت زمان اجرای برنامه‌های الگوریتم ژنتیک، اجتماع ذرات و آموزش و یادگیری به ترتیب برابر ۳/۳۸، ۳/۷۶ و ۱/۹۲ ثانیه بوده است. این موضوع حاکی از سریع‌تر بودن روش آموزش و یادگیری در همگرایی است. همچنین، نتایج نشان داد که در تکرارهای متوالی، روش‌های اجتماع ذرات و آموزش و یادگیری، عملکرد بهتری در حل مسئله‌ی مذکور داشته است. معیارهای آماری به‌دست آمده به ازاء ۵ بار اجرای هر یک از الگوریتم‌های ذکر شده شامل مقادیر کمترین، بیشترین، میانگین و انحراف معیار تابع هدف برای آنها در جدول ۷ ارائه شده‌اند.

مقادیر به‌دست آمده در روابط ۸ الی ۱۰، به ترتیب مقدار بسامد و مود شکل اول حاصل از الگوریتم‌های ژنتیک، اجتماع ذرات و آموزش و یادگیری برای سازه‌ی ۳ طبقه هستند. همان‌طور که مشخص است، هر سه روش با دقت بالایی به مقدار مطلوب (رابطه‌ی ۵) نزدیک هستند.



شکل ۴. نمودار همگرایی تابع هدف سازه‌ی ۳ طبقه.

استفاده از ماتریس جرم و مود اول سازه با اندکی خطا حاصل شود. جزئیات میزان خطا در بخش بحث و نتایج ارائه شده‌اند.


سیستم پایش سلامت، بسامد طبیعی و شکل مودی اول سازه‌ی ۶ طبقه را پس از آنالیزهای بیان شده در بخش ۲.۱. مطابق رابطه‌ی ۶ گزارش داده است:

$$\omega = ۹,۹۸۱۳ rad/s \quad \{\varphi_1\} = \begin{Bmatrix} ۰,۲۳۶۹ \\ ۰,۴۵۶۱ \\ ۰,۶۵۳۶ \\ ۰,۸۱۴۰ \\ ۰,۹۳۳۶ \\ ۱ \end{Bmatrix} \quad (۶)$$

## ۳.۵.۱. سازه‌ی خرابایی

در پژوهش حاضر، برای تشکیل ماتریس جرم یک سازه‌ی خرابایی ۶ طبقه، که ۶ المان دارد، مانند ماتریس سختی عمل شده است. در نتیجه، در بخش حاضر، ماتریس جرم، قطری نیست و مسئله پیچیدگی بیشتری دارد. شکل شماتیک سازه‌ی خرابایی در شکل ۳ مشاهده می‌شود. با فرض مجهول بودن سختی المان‌های خرابا در سازه‌ی خرابایی، تعداد متغیرهای مسئله برابر تعداد المان‌های خرابا و یا به عبارتی دیگر برابر با ۶ است. مشخصات مصالح و مقاطع این سازه در جدول ۶ ارائه شده است. پس از استفاده از الگوریتم‌های ذکر شده، سطح مقاطع در نظر گرفته شده با نتایج به دست آمده از الگوریتم‌ها به‌منظور بررسی دقت رویکرد ارائه شده مقایسه شده‌اند.

سیستم پایش سلامت، بسامد طبیعی، و شکل مودی اول سازه‌ی خرابایی را پس از آنالیزهای بیان شده در بخش ۲.۱. مطابق رابطه‌ی ۷ گزارش داده است:



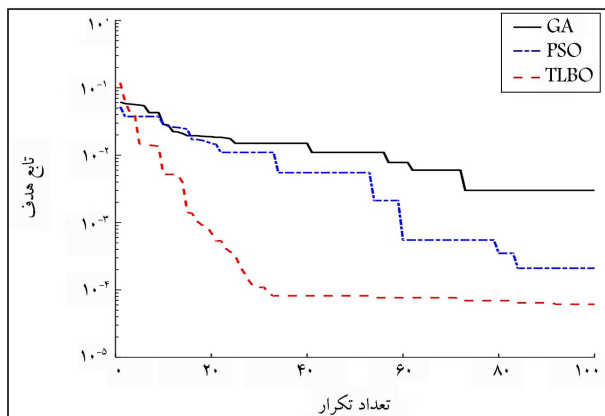
شکل ۳. شکل شماتیک سازه‌ی خرابایی.

جدول ۶. مشخصات سازه‌ی خرابایی.


المان	سطح مقطع ( $cm^2$ )	چگالی ( $ton/m^3$ )	مدول کشسانی ( $GPa$ )
۱	۲۲	۲,۵	۱۱,۳
۲	۳۵	۲,۵	۱۱,۳
۳	۱۹	۲,۵	۱۱,۳
۴	۱۰	۲,۵	۱۱,۳
۵	۲۰	۲,۵	۱۱,۳
۶	۱۶	۲,۵	۱۱,۳

جدول ۷. مقادیر کمترین، بیشترین، میانگین و انحراف معیار تابع هدف به ازاء هر الگوریتم در سازه‌ی ۳ طبقه.

الگوریتم	کمترین	بیشترین	میانگین	انحراف معیار
ژنتیک	$8 \times 10^{-5}$	$8/5 \times 10^{-5}$	$8/2 \times 10^{-5}$	$2 \times 10^{-6}$
اجتماع ذرات	$3 \times 10^{-5}$	$4/3 \times 10^{-5}$	$3/6 \times 10^{-5}$	$6 \times 10^{-6}$
آموزش و یادگیری	$5 \times 10^{-6}$	$7/1 \times 10^{-6}$	$6 \times 10^{-6}$	$10^{-6}$



شکل ۶. نمودار همگرایی تابع هدف سازه‌ی ۶ طبقه.



شکل ۵. نمودار درصد خطای بهترین پاسخ هر یک از الگوریتم‌ها در تعیین سختی طبقات سازه‌ی ۳ طبقه.

کاهش یافته است. مطابق شکل ۶، الگوریتم آموزش و یادگیری بهترین عملکرد را داشته و پس از ۳۰ تکرار به جواب مطلوب رسیده است. الگوریتم اجتماع ذرات هم عملکرد قابل قبولی را نشان داده و بعد از ۸۰ تکرار به جواب دقیق نزدیک شده است. این در حالی است که الگوریتم ژنتیک حتی بعد از ۱۰۰ تکرار به دقت دو الگوریتم دیگر نرسیده است. میزان تابع هدف در تکرار آخر به ازاء هر یک از الگوریتم‌های ژنتیک، اجتماع ذرات، و آموزش و یادگیری به ترتیب برابر  $3 \times 10^{-2}$ ،  $2 \times 10^{-2}$  و  $6 \times 10^{-5}$  بوده است.

مقدار متوسط مدت زمان اجرای هر یک از برنامه‌های الگوریتم ژنتیک، اجتماع ذرات، و آموزش و یادگیری به ترتیب برابر ۴/۴۷، ۴/۴۷ و ۴/۵۱ ثانیه بوده است. این موضوع حاکی از سریع‌تر بودن روش‌های ژنتیک و آموزش و یادگیری نسبت به اجتماع ذرات در همگرایی به پاسخ مطلوب است. معیارهای آماری به دست آمده به ازاء ۵ بار اجرای هر یک از الگوریتم‌های ذکر شده، شامل مقادیر کمترین، بیشترین، میانگین، و انحراف معیار تابع هدف برای هر سه الگوریتم ذکر شده در جدول ۸ خلاصه و ارائه شده‌اند.

مقادیر به دست آمده در روابط ۱۲ الی ۱۴، به ترتیب مقدار بسامد و مود شکل اول حاصل از الگوریتم‌های ژنتیک، اجتماع ذرات و آموزش و یادگیری برای سازه‌ی ۶ طبقه هستند. همان‌طور که مشخص است، روش آموزش و یادگیری دقت بالاتری در به دست آوردن مقدار مطلوب (رابطه‌ی ۶) نسبت به سایر روش‌ها داشته است.

$$\omega = 9,9787 \text{ rad/s} \quad \{\varphi_1\} = \begin{Bmatrix} 0,2363 \\ 0,4549 \\ 0,6516 \\ 0,8124 \\ 0,9328 \\ 1 \end{Bmatrix} \quad (12)$$

$$\omega = 16,5946 \text{ rad/s} \quad \{\varphi_1\} = \begin{Bmatrix} 0,4123 \\ 0,7588 \\ 1 \end{Bmatrix} \quad (8)$$

$$\omega = 16,5999 \text{ rad/s} \quad \{\varphi_1\} = \begin{Bmatrix} 0,4123 \\ 0,7588 \\ 1 \end{Bmatrix} \quad (9)$$

$$\omega = 16,6012 \text{ rad/s} \quad \{\varphi_1\} = \begin{Bmatrix} 0,4123 \\ 0,7588 \\ 1 \end{Bmatrix} \quad (10)$$

به منظور مشخص شدن میزان تطبیق نتایج با مقادیر دقیق، مقدار درصد خطا برای هر کدام از متغیرها با استفاده از رابطه‌ی ۱۱ محاسبه می‌شود:

$$Error(\%) = \frac{\|K - K^*\|}{K} \quad (11)$$

که در آن، مقادیر  $K$  و  $K^*$  به ترتیب برابر سختی به دست آمده توسط هر الگوریتم و سختی واقعی سازه هستند.

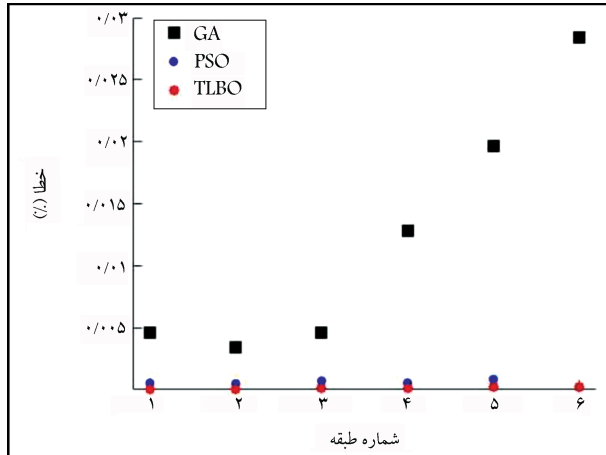
در شکل ۵، مقایسه‌ی درصد خطای بهترین پاسخ هر یک از روش‌ها در تعیین سختی طبقات مشاهده می‌شود، که مطابق آن، روش آموزش و یادگیری در تمام طبقات، کمترین خطا را در برآورد سختی داشته است. با استفاده از شکل ۵ می‌توان به خطای بیشتر در روش ژنتیک پی برد. این بدان معناست که برای جواب دقیق‌تر در روش الگوریتم ژنتیک نیاز به تعداد نسل بیشتری است، که نشان از زمان اجرای بیشتر و به تبع آن هزینه‌ی بالاتر است. بنابراین، در تعداد نسل برابر، روش آموزش و یادگیری عملکرد مطلوب‌تری دارد.

نمودار همگرایی تابع هدف برای سازه‌ی ۶ طبقه به ازاء الگوریتم‌های استفاده شده در شکل ۶ مشاهده می‌شود. از آنجایی که سازه‌ی ۶ طبقه در مقایسه با سازه‌ی ۳ طبقه، مجهولات بیشتری دارد، سرعت همگرایی تابع هدف در هر سه الگوریتم




جدول ۸. مقادیر کمترین، بیشترین، میانگین و انحراف معیار تابع هدف به ازاء هر الگوریتم در سازه ۶ طبقه.

الگوریتم	کمترین	بیشترین	میانگین	انحراف معیار
ژنتیک	$3 \times 10^{-2}$	$3/9 \times 10^{-2}$	$3/4 \times 10^{-2}$	$4 \times 10^{-2}$
اجتماع ذرات	$2 \times 10^{-4}$	$4/3 \times 10^{-2}$	$3/1 \times 10^{-4}$	$1/1 \times 10^{-4}$
آموزش و یادگیری	$6 \times 10^{-5}$	$1/1 \times 10^{-4}$	$8/6 \times 10^{-5}$	$1/8 \times 10^{-5}$



شکل ۷. نمودار درصد خطای بهترین پاسخ هر یک از الگوریتم‌ها در تعیین سختی طبقات سازه ۶ طبقه.



شکل ۸. نمودار همگرایی تابع هدف سازه ۶ طبقه.

اول حاصل از الگوریتم‌های ژنتیک، اجتماع ذرات و آموزش و یادگیری برای سازه ۶ طبقه خرابی هستند. همان‌طور که پیداست، روش آموزش و یادگیری دقت بالاتری در به‌دست آوردن مقدار مطلوب (رابطه ۷) نسبت به سایر روش‌ها دارد. در شکل ۹، نمودار درصد خطای سطح مقطع المان‌های سازه ۶ طبقه به ازاء هر سه الگوریتم ژنتیک، اجتماع ذرات و آموزش و یادگیری مشاهده می‌شود. نکته قابل توجه، خطای قابل ملاحظه‌ی الگوریتم اجتماع ذرات به ازاء المان شماره ۵ است. اما روش آموزش و یادگیری در تعیین سختی تمام المان‌ها، خطای بسیار کمی را نشان داده است. الگوریتم ژنتیک هم در المان‌های ۲، ۴ و ۵ خطای نسبتاً زیادی دارد، که نشان‌دهنده‌ی کارایی کمتر الگوریتم ژنتیک نسبت به دو الگوریتم دیگر است.

$$\omega = 9,9838 \text{ rad/s} \quad \{\varphi_1\} = \begin{Bmatrix} 0,2368 \\ 0,4563 \\ 0,6537 \\ 0,8140 \\ 0,9336 \\ 1 \end{Bmatrix} \quad (13)$$

$$\omega = 9,9813 \text{ rad/s} \quad \{\varphi_1\} = \begin{Bmatrix} 0,2369 \\ 0,4561 \\ 0,6536 \\ 0,8140 \\ 0,9336 \\ 1 \end{Bmatrix} \quad (14)$$

در شکل ۷، درصد خطای الگوریتم‌ها در محاسبه خطای سازه ۶ طبقه مشاهده می‌شود، که همانند سازه ۳ طبقه، در سازه ۶ طبقه نیز میزان خطای الگوریتم ژنتیک از دوروش دیگر به مراتب بیشتر است.

در شکل ۸، مقایسه‌ی همگرایی ۳ الگوریتم برای سازه ۶ طبقه مشاهده می‌شود، که مطابق آن، همچنان الگوریتم‌های اجتماع ذرات و آموزش و یادگیری با سرعت بیشتری نسبت به الگوریتم ژنتیک به جواب بهینه همگرا می‌شوند. اما الگوریتم ژنتیک حتی بعد از ۱۰۰ تکرار هم خطای قابل ملاحظه‌ای دارد. شایان ذکر است که در این حالت ماتریس سختی، قطری نیست و پیچیدگی مسئله بسیار بیشتر است. میزان تابع هدف در تکرار آخر به ازاء هر یک از الگوریتم‌های ژنتیک، اجتماع ذرات و آموزش و یادگیری به ترتیب برابر  $0,012$ ،  $6 \times 10^{-4}$  و  $4 \times 10^{-4}$  است.

پس از اجرای ۵ بار هر یک از الگوریتم‌های ژنتیک، اجتماع ذرات و آموزش و یادگیری، مقدار متوسط مدت زمان اجرای آنها به ترتیب برابر  $16,76$  و  $12,76$  ثانیه بوده است. این موضوع حاکی از سریع‌تر بودن روش آموزش و یادگیری در همگرایی است. معیارهای آماری به‌دست آمده شامل مقادیر: کمترین، بیشترین، میانگین و انحراف معیار تابع هدف به ازاء ۵ بار اجرای هر یک از الگوریتم‌های مذکور، در جدول ۹ خلاصه و ارائه شده‌اند.

همچنین در صورتی که تعداد نسل‌ها و یا جمعیت بیشتر در نظر گرفته شود، پاسخ به‌دست آمده به مراتب دقیق‌تر است. بنابراین به نظر می‌رسد که در استفاده از الگوریتم ژنتیک نیاز به جمعیتی بزرگ‌تر و یا تعداد نسل‌های بیشتر به‌منظور افزایش دقت است. برای مثال، به ازاء تعداد جمعیت برابر  $200$  و پس از ۵ بار اجرای برنامه، مقدار کمترین تابع هدف در تکرار آخر به ازاء هر یک از الگوریتم‌های ژنتیک، اجتماع ذرات، و آموزش و یادگیری به ترتیب به مقادیر  $0,008$ ،  $5 \times 10^{-4}$  و  $2 \times 10^{-4}$  کاهش یافته است.

مقادیر به‌دست آمده در روابط ۱۵ الی ۱۷، به ترتیب مقدار بسامد و مود شکل

جدول ۹. مقادیر کمترین، بیشترین، میانگین و انحراف معیار تابع هدف به ازاء هر الگوریتم در سازه‌ی خرپایی.

الگوریتم	کمترین	بیشترین	میانگین	انحراف معیار
ژنتیک	$0,012 \times 10^{-4}$	$0,023 \times 10^{-4}$	$0,017 \times 10^{-4}$	$5 \times 10^{-2}$
اجتماع ذرات	$6 \times 10^{-4}$	$9/2 \times 10^{-4}$	$7/6 \times 10^{-4}$	$1/6 \times 10^{-4}$
آموزش و یادگیری	$4 \times 10^{-4}$	$5/7 \times 10^{-4}$	$4/8 \times 10^{-4}$	$8 \times 10^{-5}$

اجتماع ذرات نیز با سرعت مناسبی به پاسخ همگرا شده است. الگوریتم ژنتیک نتایج مناسبی را ارائه نداده است، به خصوص زمانی که تعداد مجهولات سازه افزایش یافته است. در سازه‌ی خرپایی، که ماتریس سختی قطری نبوده است، میزان خطای رویکرد استفاده شده به مراتب نسبت به دو سازه‌ی دیگر افزایش یافته است؛ در نتیجه جهت بهبود نتایج می‌توان از تعداد نسل و یا جمعیت بیشتری استفاده کرد. همچنین هر چه سازه‌ی موردنظر پیچیده‌تر باشد، افزایش نسل و یا جمعیت الگوریتم ضروری‌تر می‌شود.

شایان ذکر است که در به‌کارگیری رویکرد ارائه شده در پژوهش حاضر در مسائل پیچیده باید به این دو نکته توجه شود:

الف) جواب مسئله باید یکتا باشد؛

ب) در صورت بالا بودن تعداد مجهولات، لزوم افزایش نسل و یا جمعیت الگوریتم جهت همگرایی مناسب‌تر الزامی است.

این موارد نیز برای مطالعات آتی پیشنهاد می‌شود:


۱. کارایی روش موردنظر برای داده‌های مربوط به سازه‌های آزمایشگاهی و یا سازه‌های واقعی بررسی شود؛

۲. اثر میرایی در میزان درستی نتایج بررسی شود؛

۳. تابع هدف با در نظر گرفتن بسامدهای طبیعی و شکل‌های مودی بالاتر بررسی شود؛

۴. با استفاده از داده‌های خام خروجی، مانند شتاب و ارائه‌ی یک تابع هدف مناسب، محل و میزان آسیب در سازه‌ها تشخیص داده شود؛

۵. کارایی توابع هدفی متشکل از ترم‌های بسامد طبیعی و شکل‌های مودی با ضرایبی متفاوت از یک بررسی شود.



شکل ۹. نمودار درصد خطای بهترین پاسخ هر یک از الگوریتم‌ها در تعیین سطح مقطع المان‌های سازه‌ی خرپایی.

### ۳. نتیجه‌گیری

در پژوهش حاضر، به مقایسه‌ی دقت و سرعت همگرایی روش‌های فراابتکاری مختلف در تعیین خصوصیات سازه، مانند: سختی المان‌ها، سطح مقطع المان‌ها و غیره با در دست داشتن مشخصات مودال سازه، نظیر بسامد طبیعی و شکل مودی اول سازه پرداخته شده است. همچنین، ماتریس سختی سه سازه‌ی مختلف، شامل سازه‌های ۳ طبقه، ۶ طبقه و خرپای ۶ المانی با استفاده از الگوریتم‌های فراابتکاری ژنتیک، اجتماع ذرات و آموزش و یادگیری با کمیته‌سازی تابع هدف تعیین شده است. بیشتر نتایج نشان می‌دهند که الگوریتم آموزش و یادگیری، بیشترین سرعت همگرایی به پاسخ بهینه را نسبت به سایر روش‌ها داشته است. این تذکر لازم است که الگوریتم

### پانوشته‌ها

1. Yuen
2. Bayesian Structural Model
3. Tiachacht
4. Genetic Algorithms
5. Li
6. Particle Swarm Optimization
7. Finite Element
8. Pérez-Ramírez
9. Bandara

10. Alexandrino
11. Modified Total Modal Assurance Criterion
12. Grey Wolf Optimization
13. Gradient-based Optimization
14. Slime Mold Algorithm
15. Marine Predators Algorithm
16. Ant Lion Optimizer
17. Whale Optimization Algorithm
18. Grasshopper Optimization Algorithm
19. Modal Assurance Criterion
20. Natural Frequency Vector Assurance Criterion
21. Guangzhou TV Tower

22. YiFei
23. K-means Clustering Optimizer
24. Sparse Polynomial Chaos Expansion Model
25. Kumar
26. Non-Dominated Sorting
27. Teaching-Learning-Based Optimization
28. Frequency Domain Decomposition
29. Singular Value Decomposition
30. Power Spectral Density
31. Setup
32. Overdetermined
33. John Holland
34. Deric Goldberg
35. National Selection
36. Cross-Over
37. Mutation
38. Pairing From Top To Bottom
39. Random Pairing
40. Weighted Random Pairing
41. Chipperfield
42. MATLAB
43. Rao

### منابع (References)

1. Natke, H.G. and Yao, J.T., 2013. *Structural Safety Evaluation Based on System Identification Approaches: Proceedings of the Workshop at Lambrecht/Pfalz*. Springer-Verlag. <https://doi.org/10.1007/978-3-663-05657-7>.
2. Mehrjoo, M., Khaji, N., Moharrami, H. and Bahreininejad, A., 2008. Damage detection of truss bridge joints using artificial neural networks. *Expert Systems With Applications*, 35(3), pp.1122-1131. <https://doi.org/10.1016/j.eswa.2007.08.008>.
3. Rao, A.R.M., Lakshmi, K. and Venkatachalam, D., 2012. Damage diagnostic technique for structural health monitoring using POD and self adaptive differential evolution algorithm. *Computers & Structures*, 106, pp.228-244. <https://doi.org/10.1016/j.compstruc.2012.05.009>.
4. Yan, W.J., Huang, T.L. and Ren, W.X., 2010. Damage detection method based on element modal strain energy sensitivity. *Advances in Structural Engineering*, 13(6), pp.1075-1088. <https://doi.org/10.1260/1369-4332.13.6.1075>.
5. Vafaei, M., Adnan, A.B. and Abd. Rahman, A.B., 2013. Real-time seismic damage detection of concrete shear walls using artificial neural networks. *Journal of Earthquake Engineering*, 17(1), pp.137-154. <https://doi.org/10.1080/13632469.2012.713559>.
6. Mortezaei, A. and Ronagh, H.R., 2011. An artificial neural network model for dynamic analysis of RC buildings subjected to near-fault ground motions having forward directivity. *Journal of Seismology and Earthquake Engineering*, 13(3 and 4), pp.179-194.
7. Bao, Y., Li, H., An, Y. and Ou, J., 2012. Dempster-Shafer evidence theory approach to structural damage detection. *Structural Health Monitoring*, 11(1), pp.13-26. <https://doi.org/10.1177/1475921710395813>.
8. Cowled, C.J., Thambiratnam, D.P., Chan, T.H. and Tan, A.C., 2014. Structural complexity in structural health monitoring: design of laboratory model and test plan. In *Proceedings of the 7th World Congress on Engineering Asset Management (WCEAM 2012) (pp. 171-181)*. Cham: Springer International Publishing. [https://doi.org/10.1007/978-3-319-06966-1\\_17](https://doi.org/10.1007/978-3-319-06966-1_17).
9. Weber, B. and Paultre, P., 2010. Damage identification in a truss tower by regularized model updating. *Journal of structural engineering*, 136(3), pp.307-316. [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0000105](https://doi.org/10.1061/(ASCE)ST.1943-541X.0000105).
10. Heywood, R., Roberts, W., Taylor, R. and Andersen, R., 2000. Fitness-for-purpose evaluation of bridges using health monitoring technology. *Transportation Research Record*, 1696(1), pp.193-201. <https://doi.org/10.3141/1696-23>.
11. Krämer, C., De Smet, C.A.M. and De Roeck, G., 1999. February Z24 bridge damage detection tests. In *IMAC 17, the International Modal Analysis Conference (Vol. 3727, pp.1023-1029)*. Society of Photo-optical Instrumentation Engineers.
12. Maeck, J. and De Roeck, G., 2003. Description of Z24 benchmark. *Mechanical Systems and Signal Processing*, 17(1), pp.127-131. <https://doi.org/10.1006/mssp.2002.1548>.
13. Sohn, H., Czarnecki, J.A. and Farrar, C.R., 2000. Structural health monitoring using statistical process control. *Journal of Structural Engineering*, 126(11), pp.1356-1363. [https://doi.org/10.1061/\(ASCE\)0733-9445\(2000\)126:11\(1356\)](https://doi.org/10.1061/(ASCE)0733-9445(2000)126:11(1356)).
14. Barraza, J.F., Droguett, E.L., Naranjo, V.M. and Martins, M.R., 2020. Capsule Neural Networks for structural damage localization and quantification using transmissibility data. *Applied Soft Computing*, 97, p.106732. <https://doi.org/10.1016/j.asoc.2020.106732>.
15. Meruane, V., 2016. Online sequential extreme learning machine for vibration-based damage assessment using transmissibility data. *Journal of Computing in Civil Engineering*, 30(3), p.04015042. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000517](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000517).
16. Yuen, K.V., Beck, J.L. and Katafygiotis, L.S., 2006. Efficient model updating and health monitoring methodology using incomplete modal data without mode matching. *Structural Control and Health Monitoring: The Official Journal of the International Association for Structural Control and Monitoring and of the European Association for the Control of Structures*, 13(1), pp.91-107. <https://doi.org/10.1002/stc.144>.
17. Tiachacht, S., Bouazzouni, A., Khatir, S., Behtani, A., Zhou, Y.L.M. and Wahab, M.A., 2018. Structural health monitoring of 3D frame structures using finite element modal analysis and genetic algorithm. *Journal of Vibroengineering*, 20(1), pp.202-214. <https://doi.org/10.21595/jve.2017.18571>.
18. Li, X.L., Serra, R. and Olivier, J., 2021. Performance of fitness functions based on natural frequencies in defect detection using the standard PSO-FEM approach. *Shock and Vibration*, 2021(1), p.8863107. <https://doi.org/10.1155/2021/8863107>.
19. Perez-Ramirez, C.A., Jaen-Cuellar, A.Y., Valtierra-Rodriguez, M., Dominguez-Gonzalez, A., Osornio-Rios,

- R.A., Romero-Troncoso, R.D.J. and Amezcua-Sanchez, J.P., 2017. A two-step strategy for system identification of civil structures for structural health monitoring using wavelet transform and genetic algorithms. *Applied Sciences*, 7(2), p.111. <https://doi.org/10.3390/app7020111>.
20. Bandara, R.P., Chan, T.H. and Thambiratnam, D.P., 2014. Structural damage detection method using frequency response functions. *Structural Health Monitoring*, 13(4), pp.418-429. <https://doi.org/10.1177/1475921714522847>.
21. Alexandrino, P.D.S.L., Gomes, G.F. and Cunha Jr, S.S., 2020. A robust optimization for damage detection using multiobjective genetic algorithm, neural network and fuzzy decision making. *Inverse Problems in Science and Engineering*, 28(1), pp.21-46. <https://doi.org/10.1080/17415977.2019.1583225>.
22. Ghannadi, P., Khatir, S., Kourehli, S.S., Nguyen, A., Boutchicha, D. and Wahab, M.A., 2023. April. Finite element model updating and damage identification using semi-rigidly connected frame element and optimization procedure: An experimental validation. *In Structures*, 50, pp.1173-1190. Elsevier. <https://doi.org/10.1016/j.istruc.2023.02.008>.
23. Ghannadi, P. and Kourehli, S.S., 2022. Efficiency of the slime mold algorithm for damage detection of large-scale structures. *The Structural Design of Tall and Special Buildings*, 31(14), p.e1967. <https://doi.org/10.1002/tal.1967>.
24. YiFei, L., Minh, H.L., Khatir, S., Sang-To, T., Cuong-Le, T., MaoSen, C. and Wahab, M.A., 2023. Structure damage identification in dams using sparse polynomial chaos expansion combined with hybrid K-means clustering optimizer and genetic algorithm. *Engineering Structures*, 283, p.115891. <https://doi.org/10.1016/j.engstruct.2023.115891>.
25. Bui, Q.A.T., Al-Ansari, N., Le, H.V., Prakash, I. and Pham, B.T., 2022. Hybrid model: Teaching learning-based optimization of artificial neural network (TLBO-ANN) for the prediction of soil permeability coefficient. *Mathematical Problems in Engineering*, 2022(1), p.8938836. <https://doi.org/10.1155/2022/8938836>.
26. Khoja, I., Ladhari, T., M'sahli, F. and Sakly, A., 2022. Teaching-learning-based optimization for parameter identification of an activated sludge process model. *Mathematical Models and Computer Simulations*, 14(3), pp.516-531. <https://doi.org/10.1134/S2070048222030085>.
27. Muther, T., Syed, F.I., Dahaghi, A.K. and Negahban, S., 2022. Socio-inspired multi-cohort intelligence and teaching-learning-based optimization for hydraulic fracturing parameters design in tight formations. *Journal of Energy Resources Technology*, 144(7), p.073201. <https://doi.org/10.1115/1.4052182>.
28. Kumar, S., Tejani, G.G., Pholdee, N., Bureerat, S. and Jangir, P., 2022. Multi-objective teaching-learning-based optimization for structure optimization. *Smart Science*, 10(1), pp.56-67. <https://doi.org/10.1080/23080477.2021.1975074>.
29. Goldberg, D.E., Korb, B. and Deb, K., 1989. Messy genetic algorithms: Motivation, analysis, and first results. *Complex Systems*, 3(5), pp.493-530.
30. Holland, J.H., 1992. *Adaptation In Natural and Artificial Systems: An Introductory Analysis With Applications to Biology, Control, and Artificial Intelligence*. MIT press. <https://doi.org/10.7551/mitpress/1090.001.0001>.
31. Clerc, M., 2010. *Particle Swarm Optimization* (Vol. 93). John Wiley & Sons. <https://doi.org/10.1002/9780470612163>.
32. Rao, R.V. and Rao, R.V., 2016. Teaching-learning-based optimization algorithm (pp. 9-39). Springer International Publishing. <https://doi.org/10.1007/978-3-319-22732-0>.
33. Rao, R.V., Savsani, V.J. and Vakharia, D.P., 2011. Teaching-learning-based optimization: A novel method for constrained mechanical design optimization problems. *Computer-Aided Design*, 43(3), pp.303-315. <https://doi.org/10.1016/j.cad.2010.12.015>.
34. Zienkiewicz, O.C., Taylor, R.L. and Zhu J.Z. 2005. *The finite element method: Its basis and fundamentals*. Elsevier. <https://doi.org/10.1016/C2009-0-24909-9>.
35. Chopra, A.K., 2007. *Dynamics of structures*. Pearson Education India.
36. Figueiredo, E., Park, G., Figueiras, J., Farrar, C. and Worden, K., 2009. Structural health monitoring algorithm comparisons using standard data sets (No. LA-14393). Los Alamos National Lab.(LANL), Los Alamos, NM (United States). <https://doi.org/10.2172/961604>.
37. Brincker, R., Zhang, L. and Andersen, P., 2000. Modal identification from ambient responses using frequency domain decomposition. *In IMAC 18: Proceedings of the International Modal Analysis Conference (IMAC)*, San Antonio, Texas, USA, February 7-10, 2000 (pp.625-630).
38. Mitchell, M., 1998. *An Introduction to Genetic Algorithms*. MIT press.
39. Chipperfield, A.J., Fleming, P.J., Pohlheim, H. and Fonseca, C.M., 1994, September. A genetic algorithm toolbox for MATLAB. *In Proceedings of the International Conference on Systems Engineering*. pp.200-207.