



# شناسایی خرابی موضعی در تیرهای فولادی با الگوریتم ELM و مقایسه با الگوریتم ترکیبی ELM و PSO



## مجتبی حنطه

دانش آموخته دکتری - دانشگاه سمنان -  
سمنان - ایران

## حسین حسین زاده کریمی

دانش آموخته کارشناسی ارشد - دانشگاه آزاد  
اسلامی - کهگیلویه و بویر احمد-ایران

## چکیده:

با افزایش کاربرد تیرهای فولادی در سازه‌های عمرانی، تشخیص زود هنگام خرابی موضعی آنها برای ایمنی و دوام سازه ضروری است. روش‌های هوشمند و داده محور در سال‌های اخیر به دلیل سرعت و دقت بالا، جایگزین روش‌های سنتی و پرهزینه‌ی غیر مخرب شده‌اند. در این پژوهش، روشی سریع، ساده و کارا برای شناسایی خرابی در تیرهای فولادی ارائه شده است که از الگوریتم یادگیری سریع ELM و نسخه بهینه شده آن با الگوریتم PSO استفاده می‌کند. تعداد ۲۰۰ داده شامل دامنه جابجایی، عمق ترک و نسبت فرکانس طبیعی جمع آوری و با روش بالانس داده (Oversampling) متعادل سازی شده‌اند. برای افزایش دقت، ویژگی‌های ترکیبی جدیدی از متغیرهای اصلی استخراج شدند. نتایج نشان می‌دهد که مدل پایه ELM با ۱۰۰ نورون، دقت ۴۰٪ دارد؛ اما نسخه بهینه شده آن با PSO تنها با ۱۰ نورون، دقت را به ۶۱.۷٪ افزایش می‌دهد. پس از متعادل سازی داده‌ها، دقت کمی کاهش یافت که به دلیل تنوع بالاتر در داده‌های کم تعداد (خراب) است. همچنین، استفاده از شبکه عصبی چند لایه و ترکیب دو مدل (با روش رأی گیری بین خروجی‌ها) باعث ارتقای دقت تا ۵۵٪ شد. این یافته‌ها بیانگر تأثیر مثبت بهینه سازی پارامتری و ترکیب مدل‌ها در بهبود عملکرد تشخیص خرابی است.

## Local Damage Detection in Steel Beams Using the ELM Algorithm and Comparison with the Hybrid ELM-PSO Approach Hosein Hoseinzadeh Karimi, Mojtaba Hanteh

1. M.Sc-Islamic Azad University, Kohgiluyeh and Boyer-Ahmad, Iran

2. Ph.D-Semnan University, Semnan, Iran

### Abstract

With the growing use of steel beams in civil infrastructure, early detection of localized damage is essential to ensure structural safety and longevity. In recent years, intelligent data-driven methods have increasingly replaced traditional non-destructive testing techniques due to their superior speed and accuracy. This study presents a fast, simple, and efficient approach for damage identification in steel beams using the Extreme Learning Machine (ELM) algorithm and its optimized version based on Particle Swarm Optimization (PSO). A total of 200 data samples-comprising displacement amplitude, crack depth, and natural frequency ratio-were generated and balanced using the oversampling technique. To enhance prediction accuracy, new composite features were extracted from the primary variables. The results indicate that the baseline ELM model with 100 hidden neurons achieved an accuracy of 40%, whereas the PSO-optimized variant, with only 10 neurons, improved the accuracy to 61.7%. After class balancing, a slight decrease in accuracy was observed, attributed to the increased variability within the minority (damaged) class. Additionally, the use of a multilayer perceptron (MLP) and ensemble modeling through majority voting further improved the accuracy to 55%. These findings highlight the effectiveness of parameter optimization and model fusion in improving the performance of structural damage detection systems.

Keyword: Extreme Learning Machine, Particle Swarm Optimization, Damage Detection, Steel Beam, Neural Network.

پایب سلامت سازه است. نقشه شدت خرابی نیز با بهره‌گیری از تحلیل سیگنال و تفاوت پاسخ دینامیکی قبل و بعد از آسیب تولید شده و ناحیه‌های دارای بیشترین احتمال خرابی را به صورت رنگی مشخص می‌کند. این نوع نمایش، مبنایی برای ارزیابی عملکرد مدل‌های یادگیری ماشین در تشخیص و مکان‌یابی آسیب محسوب می‌شود و در مطالعات اخیر نیز به عنوان مرجع معتبر مورد استفاده قرار گرفته است. روش‌های غیرمخرب سنتی (اولتراسونیک، رادیوگرافی) زمان‌بر و هزینه‌بر هستند، در حالی که روش‌های داده‌محور به ویژه الگوریتم‌های یادگیری ماشین، جایگزینی سریع و دقیق برای روش‌های سنتی غیرمخرب فراهم آورده‌اند و در عین حال سرعت و انعطاف بالاتری ارائه می‌دهند. این روش‌ها با تحلیل الگوهای پیچیده در داده‌های لرزش، تغییر شکل یا تنش، امکان شناسایی

## ۱. مقدمه:

امروزه با استفاده روز افزون از تیرهای فولادی در سازه‌های بلند و صنعتی، مشاهده می‌شود که خرابی موضعی می‌تواند باعث حوادث جانی و اقتصادی بسیاری گردد. لیکن شناسایی و پیش‌بینی خرابی در سازه‌های فولادی از اهمیت بسیاری در حوزه مهندسی عمران و معماری برخوردار است؛ چرا که خرابی‌های ناگهانی می‌توانند به خسارات جانی و مالی گسترده منجر شوند. شکل (۱)، نمونه‌ای از خرابی موضعی در تیر فولادی را همراه با نقشه شدت آسیب نشان می‌دهد. ترک ایجاد شده بر جان تیر موجب کاهش سختی موضعی و تغییر در فرکانس‌های طبیعی عضو می‌شود؛ موضوعی که اساس روش‌های داده‌محور در



همچنین در همین سال، Jiang و همکاران نیز مدل ELMPSO را برای پیش‌بینی تغییرشکل سازه‌ای به کار برده و با استفاده از داده‌های شبیه‌سازی شده FEM دقت ۶۰٪ را گزارش کردند [۴]. هم‌زمان، Tavares و همکاران روش‌های یادگیری ماشین را برای شناسایی خرابی در سازه‌های سبک وزن به کار بردند و اثبات کردند که الگوریتم‌های پیشرفته AI می‌توانند در محیط‌های مختلف SHM دقیق عمل کنند [۵]. در ۲۰۲۱، Dillen و همکاران یک روش ترکیبی گرادین پایه/ماتریوربستیک برای بهینه‌سازی ابعاد و توپولوژی سازه‌های فولادی ارائه کردند که می‌تواند در طراحی اولیه سازه با ملاحظه مقاومت به خرابی موضعی مفید باشد [۶]. در سال ۲۰۲۲، Cuong-Le و همکاران با ترکیب PSO و SVM مدلی عملی برای شناسایی خرابی‌های تیر ارائه دادند که نسبت به روش‌های سنتی قابلیت تعمیم بالاتری نشان داد [۷]. در ۲۰۲۴، Zhang, Shi و Huang با به کارگیری تحلیل موجک و یادگیری عمیق در تیرهای مرکب فولادبتن، دقت تشخیص را به بیش از ۹۰٪ رساندند و قدرت تفکیک موقعیتی ترک‌ها را افزایش دادند [۸]. در تازه‌ترین پژوهش Vu-Van-Tuan و همکاران، با تلفیق آنالیز فرکانس طبیعی و الگوریتم‌های یادگیری ماشین، مدلی برای شناسایی آسیب در تیرهای فولادی ارائه دادند که دقتی معادل ۹۲٪ داشت [۹].

با توجه به پیشینه فوق، اگرچه مطالعات متعددی با الگوریتم‌های ELM و PSO برای پیش‌بینی رفتار سازه‌ای انجام شده است، اما بررسی ترکیب هم‌زمان آنها با داده‌های کم‌حجم و فرایند ایجاد ویژگی‌های جدید با ترکیب متغیرهای موجود برای بهبود عملکرد مدل (مهندسی ویژگی) به جهت شناسایی ترک‌های موضعی در تیرهای فولادی هنوز به‌طور کامل انجام نشده است. این پژوهش بر آن است تا با تمرکز بر داده‌های کم‌حجم و پردازش سریع، ضمن مقایسه ELM پایه و ELM+PSO، نقش MLP و روش ترکیبی را در بهبود دقت تشخیص بررسی کند. در این راستا، چارچوبی عملی برای شناسایی خرابی موضعی در تیرهای فولادی ارائه خواهد شد که قابلیت پیاده‌سازی آسان در نرم‌افزارهای رایج و محیط‌های محدود را داشته باشد. هدف اصلی این پژوهش ارائه یک فرآیند ساده و سریع است که با حداقل تنظیمات، بتواند خرابی موضعی تیرهای فولادی را شناسایی کند. مراحل کار به صورت زیر است:

✓ استخراج ۲۰۰ نمونه داده شامل دامنه جابجایی، عمق ترک و نسبت فرکانس طبیعی با برچسب دودویی

✓ پیش‌پردازش، بالانس داده، استخراج ویژگی‌های ترکیبی و نرمال‌سازی

✓ آموزش ELM پایه و بهینه‌سازی تعداد نورون‌ها با PSO در یک چارچوب یکپارچه

✓ تنظیم هایپرپارامتر (تعداد لایه‌ها یا نورون‌ها) شبکه MLP و آموزش آن

✓ ترکیب پیش‌بینی‌ها با روش ترکیبی رأی‌گیری اکثریت

✓ ارزیابی نهایی با معیارهای دقت

در ادامه، فلوچارت مراحل کار در شکل (۲) نمایش داده شده است.

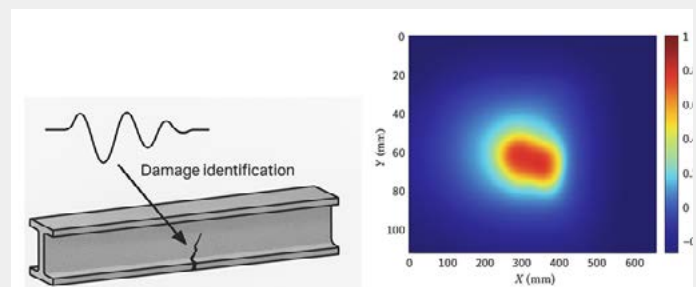
## شکل ۲. فلوچارت مراحل تحقیق

Figure 2. Flowchart of the research methodology.

## ۲. روش شناسی:

در این بخش، پس از توضیح کلی مراحل، جزئیات جمع‌آوری داده‌ها، پیش‌پردازش و بیکربندی دقیق مدل‌ها با ارجاع به مبانی فیزیکی و منابع معتبر ارائه شده است تا قابلیت

زود هنگام نقص‌های موضعی را میسر می‌کنند. ماشین یادگیری سریع به عنوان یک الگوریتم یادگیری سریع با ساختار ساده، در سال‌های اخیر توجه پژوهشگران را به خود جلب کرده است؛ زیرا ELM از طریق تولید تصادفی وزن‌های اولیه و حل تحلیلی وزن‌های خروجی، زمان آموزش کوتاهی ارائه می‌دهد و برای مسائل دسته‌بندی در پایش سلامت سازه مناسب است. در کنار ELM، الگوریتم‌های بهینه‌سازی مثل الگوریتم ازدحام ذرات برای تنظیم پارامترهای مدل به کار می‌روند تا عملکرد و قابلیت تعمیم مدل افزایش یابد. همچنین، افزودن ویژگی‌های مبتنی بر حوزه فرکانس و موجک از سیگنال‌های لرزش تیرها توانسته است دقت تشخیص را بهبود بخشد. با این وجود، بسیاری از مطالعات به بررسی تکنیک‌های پیچیده و حجیم پرداخته‌اند که نیازمند داده‌های گسترده و محاسبات طولانی است. در مقابل، این پژوهش تلاش دارد با استفاده از نمونه‌های کم‌حجم و الگوریتم‌های سبک، چارچوبی ساده و قابل اجرا در محیط‌های محدود مانند کارگاهی یا شبیه‌سازی سریع ارائه دهد.



شکل ۱. شمای ساختگی شناسایی خرابی موضعی و شدت آن در تیر فولادی (طراحی این مطالعه).

Figure 1. Schematic illustration of localized damage identification and damage severity in a steel beam (designed for this study).

از سال ۲۰۲۰ تاکنون، روش‌های مبتنی بر ترکیب تحلیل فرکانسی، مهندسی ویژگی و الگوریتم‌های هوش مصنوعی برای شناسایی خرابی موضعی در تیرهای فولادی پیشرفت چشمگیری داشته‌اند. Sun و همکاران با مرور جامعی از پایش سلامت پل‌ها با استفاده از کلان‌داده و هوش مصنوعی نشان دادند که ادغام تحلیل فرکانس و یادگیری ماشین می‌تواند از ارزیابی وضعیت تا تشخیص خرابی را به‌طور مؤثری پوشش دهد [۱]. در پایان ۲۰۲۰، Tan و همکاران با استخراج ویژگی‌های فرکانسی و استفاده از شبکه‌های عصبی مصنوعی در تیرهای مرکب فولادبتن، دقت تشخیص خرابی را تا ۸۵٪ افزایش دادند و موقعیت ترک‌ها را به‌دقت تعیین کردند [۲]. در سال ۲۰۲۱، Rastin و همکاران یک خودمزنگار کانولوشنی عمیق بدون نظارت برای شناسایی خرابی‌های ساختاری معرفی کردند که در تشخیص ترک‌های موضعی تیرها عملکرد قابل‌قبولی داشت [۳].



## ۲/۲. پیش‌پردازش:

### ۱/۲/۲. بالانس داده‌ها:

برای رفع عدم‌توازن میان کلاس‌های سالم و معیوب، فرایند Oversampling تنها بر روی مجموعه آموزش (۷۰٪ داده‌ها) اعمال شد تا از بروز نشت اطلاعات جلوگیری شود و مجموعه تست دست‌نخورده باقی‌ماند [۱۳]. پیش از بالانس، از مجموع ۱۴۰ نمونه آموزشی، ۸۴ نمونه به کلاس سالم و ۵۶ نمونه به کلاس معیوب اختصاص داشتند. با اعمال Oversampling، تعداد نمونه‌های معیوب تا سطح کلاس سالم افزایش یافت (از ۵۶ به ۸۴ نمونه). بدین ترتیب، حجم مجموعه آموزش پس از بالانس به ۱۶۸ نمونه رسید. با افزودن ۶۰ نمونه مجموعه تست، حجم کل داده‌ها از ۲۰۰ به ۲۲۸ نمونه افزایش یافت. این اصلاح موجب بهبود تعادل کلاس‌ها در مرحله آموزش شد، بدون آنکه ساختار داده‌های تست تحت تأثیر قرار گیرد.

### ۲/۲/۲. مهندسی ویژگی‌ها:

دو ویژگی ترکیبی بر اساس روابط فیزیکی استخراج گردید [۱۴]:

۱. حاصل ضرب دامنه و عمق ترک
۲. نسبت فرکانس به دامنه

### ۳/۲/۲. نرمال‌سازی:

مقیاس‌گذاری تنها روی داده‌های آموزش انجام شد و سپس پارامترهای بدست‌آمده بر روی مجموعه تست اعمال گردید تا از نشت اطلاعات جلوگیری شود [۱۵].

### ۳/۲. مدل‌ها و الگوریتم‌ها:

#### ۱/۳/۲. ماشین یادگیری سریع (ELM):

ماشین یادگیری سریع یک شبکه عصبی پیش‌خور است که برای طبقه‌بندی آماری و تحلیل رگرسیون با یک لایه پنهان به کار گرفته می‌شود، به صورتی که نیازی به تنظیم پارامترهای گره‌های پنهان نباشد. این گره‌های پنهان می‌توانند به صورت تصادفی تخصیص داده شده و وزن‌ها متناسب با آن جهت فرایند مدلسازی، برآورد گردد. در اغلب موارد، وزن خروجی گره‌های پنهان معمولاً در یک مرحله گنجانده می‌شود که اساساً به یادگیری یک مدل به صورت خطی می‌پردازد. برخلاف روش‌های معمول یادگیری، مدل ELM نه تنها سعی می‌کند خطای داده‌های آموزش را حداقل کند بلکه سعی در به حداقل رساندن مقادیر وزن‌های خروجی نیز دارد. با توجه به تئوری بارلت برای شبکه‌های عصبی پیش‌خور، کاهش مقادیر وزن‌ها در کنار کاهش خطای آموزش باعث تعمیم‌پذیری بهتری می‌شود. تابع خروجی‌های تعمیم‌یافته به صورت رابطه (۱) بیان می‌گردد:

$$f(x) = h(x)\beta = \sum_{i=1}^L \beta_i h_i(x) \quad (1)$$

در این رابطه،  $x$  بردار ورودی شامل ویژگی‌های سازه‌ای است. تابع  $h_i(x)$  خروجی نورون  $i$ ام در لایه پنهان را نشان می‌دهد که از اعمال تابع فعال‌سازی بر ترکیب خطی ورودی‌ها حاصل می‌شود. مقدار  $L$  تعداد نورون‌های لایه پنهان است و  $\beta_i$  وزن‌های لایه خروجی هستند که در ELM از طریق شبه‌معکوس مورینوروز تعیین می‌شوند. خروجی کلی مدل با نماد  $f(x)$  بیان شده است. تابع  $h(x)$  در واقع فضای  $d$  بعدی ورودی را به یک فضای  $L$  بعدی نگاشت می‌کند. بین لایه نهان و لایه خروجی نیز، وزن وجود دارد [۱۶ و ۱۷].

#### ۲/۳/۲. الگوریتم بهینه‌سازی ازدحام ذرات (PSO):

الگوریتم PSO در مقایسه با روش‌های بهینه‌سازی مشابه دیگر برای رسیدن به نتایج مناسب، به فراخوانی تابع کمتری نیاز دارد. از جمله مزایای دیگر الگوریتم می‌توان به پیاده‌سازی کامپیوتری آسان آن اشاره نمود که به آسانی با شرایط قیود و متغیرها در یک مسئله خاص منطبق می‌شود. در فرمول‌بندی الگوریتم، ذره  $i$ ام در موقعیت  $x$

بازتولید فرآیند تضمین شود.

### ۱/۲. جمع‌آوری داده‌ها:

برای ایجاد مجموعه‌ی داده مرجع، ۲۰۰ نمونه اطلاعاتی با سه متغیر کلیدی تیر فولادی جمع‌آوری گردید. پس از تولید مجموعه داده، نمونه‌ها با نسبت ۷۰٪ برای آموزش و ۳۰٪ برای تست به صورت تصادفی تقسیم‌بندی شدند تا امکان ارزیابی مستقل عملکرد مدل فراهم گردد.

### • دامنه جابجایی:

دامنه جابجایی ( $D$ ) بیانگر مقدار جابجایی اوج است که تیر در اثر تحریک دینامیکی (مانند بار چرخه‌ای یا ارتعاش آزاد) تجربه می‌کند یا به بیان دیگر بیانگر بیشترین مقدار جابجایی تیر در مود اول ارتعاشی است. افزایش دامنه جابجایی معمولاً نشان‌دهنده‌ی کاهش سختی موضعی یا خوردگی است. مقادیر به صورت یکنواخت در بازه‌ی ۰/۱ تا ۵/۰ میلی‌متر می‌باشد. این بازه برگرفته از داده‌های تجربی تیرهای فولادی تحت بارگذاری لرزه‌ای می‌باشد [۱۰].

### • عمق ترک:

مطالعات آزمایشگاهی نشان داده‌اند که در تیرهای فولادی، ترک اولیه معمولاً در جان یا محل تمرکز تنش ایجاد می‌شود، اولین ترک بیشترین اثر را بر فرکانس طبیعی دارد و سایر ترک‌ها تا قبل از گسترش، نقش فرعی دارند. بنابراین مبنای مدلسازی عمق بزرگ‌ترین ترک انتخاب شده است.

زیرا بیشترین اثر را بر پاسخ دینامیکی دارد، معیار اصلی کاهش سختی موضعی است و در ادبیات SHM نیز همین معیار استفاده می‌شود. عمق ترک ( $C$ ) موضعی در محل شکستگی از ۰/۰ تا ۳/۰ میلی‌متر به صورت یکسان در بازه‌ای که طبق نتایج آزمایشگاهی برای آغاز ترک‌های موضعی در فولاد مناسب تشخیص داده شده است؛ می‌باشد [۱۱].

### • نسبت فرکانس طبیعی:

$$f_{\text{damaged}}$$

نسبت فرکانس طبیعی ( $f$ ) به شکل  $f_{\text{damaged}}$  تعریف شده است. این نسبت تغییرات مود ارتعاشی قبل و بعد از خرابی را نشان می‌دهد.  $f_{\text{damaged}}$  فرکانس طبیعی تیر بعد از ایجاد ترک یا کاهش سختی است و  $f_{\text{undamaged}}$  فرکانس طبیعی تیر در حالت سالم است. در ترک‌های موضعی، کاهش فرکانس معمولاً بین ۱۰ تا ۳۰٪ است. تغییرات این نسبت تحت تأثیر تغییر سختی مقطع پس از ترک مطابق مرجع [۱۲] در بازه‌ی ۰/۸ تا ۱/۲ می‌باشد.

### ۱/۱/۲. تخصیص برچسب:

برای برچسب‌گذاری، ۶۰٪ نمونه‌ها سالم و ۴۰٪ معیوب در نظر گرفته شد. نسبت ۴۰۶۰ با هدف شبیه‌سازی نسبت مشاهده شده خرابی در پایگاه‌های داده SHM انتخاب شد. این نسبت براساس فراوانی نمونه‌های اقلیت در دیتاست‌های پایش سلامت سازه مطابق مرجع [۱۳] انتخاب شده است.



در تکرار  $k+1$ ام به وسیله رابطه (۲) موقعیت خود را بهبود می‌بخشد، که در این رابطه سرعت اصلاح شده ذره نام است که از رابطه (۳) حاصل شده است و گام زمانی می‌باشد که با استفاده از رابطه (۴) تعیین می‌شود. در این پژوهش مقدار برابر واحد فرض شده است [۱۶و۱۷].

$$x_{k+1}^i = x_k^i + v_{k+1}^i \Delta t \quad (2)$$

$$v_{k+1}^i = wv_k^i + c_1 \frac{(p_k^i - x_k^i)}{\Delta t} + c_2 \frac{(p_k^g - x_k^i)}{\Delta t} \quad (3)$$

$$\Delta t = \frac{1}{k_{Max}} \quad (4)$$

MLP متشکل از یک لایه ورودی، یک یا چند لایه مخفی، و یک لایه خروجی است. در هر لایه مخفی، نورون‌ها به صورت کامل به لایه قبلی و بعدی متصل‌اند. توابع فعال‌سازی در لایه‌های مخفی معمولاً غیرخطی هستند؛ رایج‌ترین آنها  $\text{ReLU}^2$  و  $\text{tanh}$  می‌باشند. فرایند آموزش این شبکه‌ها بر اساس الگوریتم پس‌انتشار خطا انجام می‌شود که طی آن، وزن‌ها با استفاده از گرادیان نزولی اصلاح می‌شوند. تابع هزینه رایج در طبقه‌بندی دودویی در رابطه (۸) آورده شده است.

$$loss = -(y_{true} \times \log(y_{pred}) + (1 - y_{true}) \times \log(1 - y_{pred})) \quad (8)$$

در این رابطه،  $y_{true}$  برچسب واقعی هر نمونه (سالم یا معیوب) و  $y_{pred}$  احتمال پیش‌بینی شده توسط مدل است. تابع هزینه Cross-Entropy به صورت منفی لگاریتم درست‌نمایی تعریف می‌شود و با کمینه‌سازی آن، وزن‌های شبکه عصبی به‌روزرسانی می‌گردد. این تابع برای مسائل طبقه‌بندی دودویی مانند تشخیص خرابی تیر مناسب است. برای بهینه‌سازی تابع هزینه از الگوریتم‌هایی چون SGD، Adam یا LBFGS استفاده می‌شود. همچنین، تنظیم هاینر پارامترها (تعداد لایه‌ها، نورون‌ها، نرخ یادگیری و ...) نقش مهمی در عملکرد نهایی MLP دارد. استفاده از Cross-validation و Grid Search برای یافتن ترکیب بهینه‌ی این پارامترها توصیه می‌شود [۱۸و۱۹]. شبکه MLP به‌ویژه برای داده‌هایی که دارای ویژگی‌های غیرخطی پیچیده هستند مناسب است، اما نسبت به داده‌های با نویز زیاد حساس بوده و نیازمند تنظیم دقیق است.

#### ۴.۳/۲. روش ترکیبی:

روش‌های ترکیبی یکی از قدرتمندترین تکنیک‌ها در یادگیری ماشین هستند که با ترکیب چند مدل مختلف یا مشابه، سعی در بهبود دقت پیش‌بینی و افزایش پایداری مدل دارند. هدف اصلی در این روش‌ها کاهش واریانس، کاهش بایاس یا افزایش دقت کلی است. سه رویکرد اصلی در ترکیب مدل‌ها عبارتند از: Bagging (مانند Boosting)، Random Forest (مانند XGBoost) و Voting (رای گیری اکثریت) [۲۰].

در روش رأی‌گیری اکثریت، دو نوع کلی وجود دارد: رأی‌گیری اکثریت سخت<sup>۲</sup> که بر اساس بیشترین تعداد رأی کلاس برنده را انتخاب می‌کند و رأی‌گیری اکثریت نرم<sup>۳</sup> که بر اساس میانگین احتمالات پیش‌بینی شده تصمیم می‌گیرد. روش‌های Voting زمانی مؤثر هستند که مدل‌های پایه از الگوریتم‌های مختلف با رفتارهای پیش‌بینی متفاوت استفاده کنند. مزیت کلیدی روش‌های ترکیبی، کاهش احتمال بیش‌برازش<sup>۴</sup> در داده‌های آموزشی است. همچنین، این روش‌ها می‌توانند در برابر نویز و داده‌های پرت عملکرد پایدارتری داشته باشند. طراحی مناسب این روش مستلزم انتخاب دقیق مدل‌های پایه، تخصیص وزن مناسب به آنها و بررسی همبستگی بین خطاهای پیش‌بینی است [۲۱].

#### ۴.۳/۲. معیارهای ارزیابی:

در مسائل مدلسازی که هدف پیش‌بینی مقادیر پیوسته یا ارزیابی عملکرد بر اساس خطای عددی است، استفاده از شاخص‌های آماری متداول نشان داده شده در روابط (۹) تا (۱۱) مانند ضریب همبستگی خطی، ریشه میانگین مربعات خطا و میانگین مطلق درصد خطا،

در روابط فوق  $v_k^i$  مقدار بردار سرعت در تکرار  $k$ ام،  $r_1$  و  $r_2$  اعداد تصادفی بین صفر و یک و  $v_k^i$  نشان‌دهنده بهترین موقعیت ذره نام و موقعیت بهترین ذره در تمام جامعه تا تکرار  $k$ ام می‌باشد و دیگر ضرایب، پارامترهای وابسته به مسئله هستند. برای مثال  $c_1$  (شتاب شناسایی) و  $c_2$  (شتاب جمعی)، پارامترهای شناختی و اجتماعی نامیده می‌شوند و تعیین‌کننده میزان اطمینان به جریان ذرات و یا حرکت جامعه می‌باشند و  $w$  پارامتر اینرسی وزنی نامیده می‌شود؛ این پارامتر نقش مهمی را در رفتار همگرایی الگوریتم PSO ایفا می‌کند به طوری که مقدارهای زیاد  $w$  باعث افزایش مقدار بردار سرعت می‌شود و در هر تکرار گام‌های بزرگتری برداشته خواهد شد و با کوچک شدن  $w$  این گام‌ها کوچکتر می‌شود که برای رسیدن به حالت بهینه در گام‌های آخر مفید می‌باشد، از این رو با قرار دادن یک رابطه مطابق رابطه (۵) به جای مقداری ثابت برای  $w$  می‌توان به این مهم دست یافت. انتخاب مقدار مناسب برای این پارامترها منجر به تسریع همگرایی الگوریتم و جلوگیری از همگرایی زودرس در بهینه‌های محلی می‌شود [۱۶و۱۷].

$$W_{k+1} = W_{max} - \frac{W_{max} - W_{min}}{k_{max}} k \quad (5)$$

همان‌طور که در تحقیقات گذشته عنوان شده است مقادیر  $W_{max}$  و  $W_{min}$  به ترتیب برابر با  $0.9$  و  $0.4$  می‌باشد. همچنین بهترین مقادیر برای پارامترهای  $c_1$  و  $c_2$  برابر با  $1$  و  $2$  می‌باشد. در الگوریتم PSO موقعیت اولیه ذرات به صورت تصادفی در فضای مجاز طراحی  $[x^u, x^l]$  انتخاب می‌شود. سپس سرعت اولیه ذرات  $(V_1)$  در بازه  $[v_{min}, v_{max}]$  به طور تصادفی مقداردهی می‌شود. در این ماتریس  $p$  تعداد ذرات و  $n$  تعداد متغیرهای طراحی می‌باشد،  $W_{min}$  و  $W_{max}$  و  $V_1$  با استفاده از روابط (۶) و (۷) تعیین می‌شوند [۱۶و۱۷].

$$v_{min} = -\frac{1}{2}(x^u - x^l), v_{max} = \frac{1}{2}(x^u - x^l) \quad (6)$$

$$V_1 = v_{min} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & & \vdots \\ 1 & \dots & 1 \end{bmatrix} + \begin{bmatrix} r_{p,1} & \dots & r_{p,n} \\ \vdots & & \vdots \\ r_{p,p} & \dots & r_{p,n} \end{bmatrix} \cdot (v_{max} - v_{min}) \quad (7)$$

در رابطه مذکور،  $r_{p,n}$  مقادیر تصادفی بین صفر و یک می‌باشد.

#### ۳.۳/۲. شبکه پرسپترون چندلایه:

مزیت اصلی MLP، توانایی یادگیری روابط غیرخطی پیچیده در داده‌های چندبعدی است. شبکه‌های پرسپترون چندلایه زیرمجموعه‌ای از شبکه‌های عصبی مصنوعی هستند که معمولاً برای مسائل طبقه‌بندی و رگرسیون در داده‌های عددی و چندبعدی به کار می‌روند.



## جدول ۲. خصوصیات آماری داده‌های ورودی

Table 2. Statistical Characteristics of Input Data

Variable	Min	Max	Mean	Std. Dev.
Displacement range (mm)	0.127	4.936	2.472	1.445
Crack depth (mm)	0.015	2.972	1.513	0.879
Natural frequency ratio	0.804	1.200	1.008	0.123

۱/۱/۳. بالانس (Oversampling):

با توجه به توزیع اولیه ۶۰٪ سالم و ۴۰٪ معیوب، در مجموعه آموزش با استفاده از روش Oversampling (نمونه‌برداری تصادفی با جایگزینی) تعداد نمونه‌های معیوب تا سطح تعداد نمونه‌های سالم افزایش یافت تا نسبت هر دو کلاس به ۵۰٪/۵۰٪ برسد. این کار باعث شد مدل‌ها در یادگیری ویژگی‌های کلاس معیوب دقت بیشتری داشته باشند.

۲/۱/۳. نرمال‌سازی (Standardization):

برای همگن‌سازی مقیاس ویژگی‌ها، از StandardScaler استفاده گردید. طبق فرمول (۱۲) هر ویژگی  $x$  به گونه‌ای تبدیل شد که میانگین  $\mu=0$  و انحراف معیار  $\sigma=1$  شود.

$$\frac{x - \mu}{\sigma} = x' \quad (12)$$

این گام برای جلوگیری از تسلط ویژگی‌هایی با دامنه بزرگ بر یادگیری و نیز تسریع همگرایی مدل‌ها الزامی است.

۲/۲/۳. مدلسازی:

در این پژوهش چهار مدل به کار رفته است ELM پایه، ELM+PSO، MLP و Ensemble در ادامه هر مدل با جزئیات پیکربندی توضیح داده می‌شوند.

۱/۲/۳. ماشین یادگیری سریع (ELM):

شبکه ELM شامل یک لایه مخفی است که وزن‌ها و بایاس آن به صورت تصادفی مقداردهی اولیه می‌شوند و فقط وزن‌های خروجی با روش کمترین مربعات تعیین می‌گردند. پیکربندی این مدل در جدول (۳) نشان داده شده است.

## جدول ۳. مشخصات ELM

Table 3. ELM Specifications

Parameter	Value	Description
Number of hidden neurons	100	Baseline
Activation function	tanh	$\tanh(z) = g(z)$
Method for calculating output weights	Pseudoinverse	Moore-Penrose

۲/۲/۳. الگوریتم ازدحام ذرات (PSO):

برای یافتن تعداد بهینه نورون‌های مخفی ( $N_H$ )، از الگوریتم PSO بهره برده شد. پارامترهای PSO در جدول (۴) آورده شده است.

## جدول ۴. پارامترهای PSO برای بهینه‌سازی ELM

Table 4. PSO Parameters for ELM Optimization

Parameter	Value	Description
Number of particles	10	Particle swarm size
Number of iterations	10	Maximum generations
Initial inertia weight	0.5	$w_0$
Inertia damping	0.9	Inertia weight decay per iteration
Cognitive acceleration	1.5	$c_1$
Social acceleration	1.5	$c_2$

تصویر دقیق‌تری از عملکرد مدل ارائه می‌دهد. این معیارها میزان نزدیکی خروجی‌های مدل را با مقادیر واقعی هدف ارزیابی می‌کنند.

$$R = \frac{\sum_{i=1}^N (q_i - \bar{q})(\hat{q}_i - \bar{\hat{q}})}{\sqrt{\sum_{i=1}^N (q_i - \bar{q})^2 \sum_{i=1}^N (\hat{q}_i - \bar{\hat{q}})^2}} \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (q_i - \hat{q}_i)^2} \quad (10)$$

$$MAPE = \frac{100}{N} \sum_{I=1}^N \frac{|q_i - \hat{q}_i|}{q_i} \quad (11)$$

$N$  تعداد داده‌ها، مقدار مشاهداتی و مقدار برآورد شده توسط مدل می‌باشد. استفاده هم‌زمان از این سه شاخص امکان بررسی عملکرد مدل از جنبه‌های مختلف را فراهم می‌کند، که  $R$  نشان‌دهنده شدت رابطه‌ی بین متغیرهاست،  $RMSE$  میزان پراکندگی خطا را نشان می‌دهد و  $MAPE$  شاخص درصدی و مقیاس‌پذیر از خطا است. این ترکیب به‌ویژه در مقایسه‌ی الگوریتم‌های یادگیری ماشین مانند ELM، PSO و MLP می‌تواند در انتخاب مدل بهینه نقش کلیدی ایفا کند [۲۲-۲۴].

۳. روش انجام آزمایش:

۱/۳. تحلیل داده‌ها:

در این پژوهش از ۲۰۰ نمونه استفاده گردید که شامل سه ویژگی ورودی و یک برچسب خروجی می‌باشند. دسته‌بندی متغیرها در جدول (۱) و خصوصیات آماری داده‌ها در جدول (۲) آورده شده است.

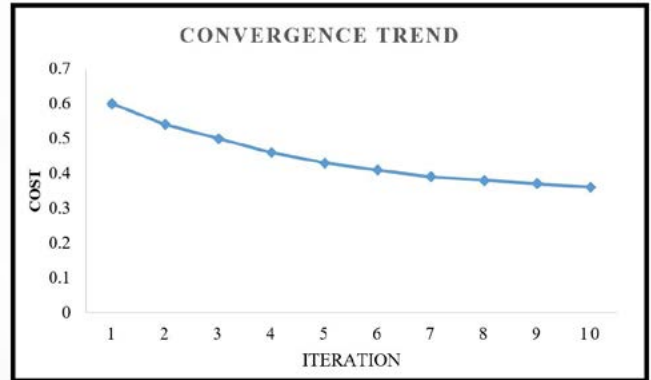
## جدول ۱. دسته‌بندی متغیرها

Table 1. Variable Classification

Variable	Type	Description
Displacement range	Input	Peak displacement range (mm)
Crack depth	Input	Depth of crack (mm)
Natural frequency ratio	Input	Ratio $\frac{f_{\text{damaged}}}{f_{\text{undamaged}}}$
Label	Output	Undamaged = 0, Damaged = 1



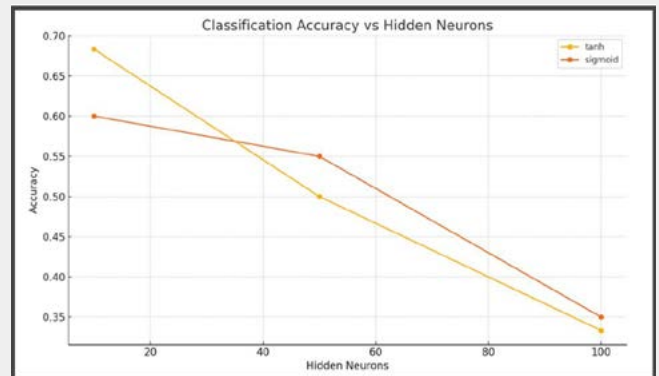
نمودار روند همگرایی (Cost = 1 - Accuracy) مقادیر در شکل (۳) آورده شده است.



شکل ۳. نمودار روند همگرایی

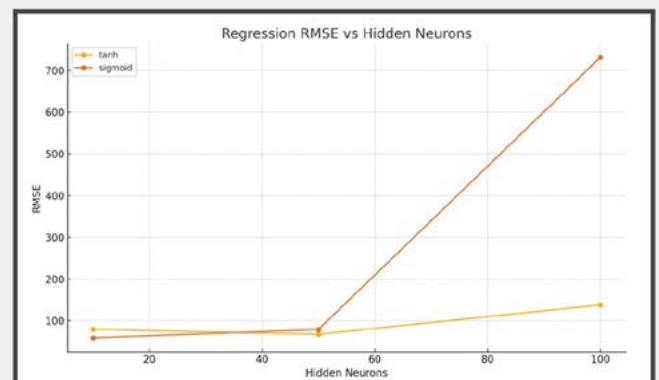
Figure 3. Convergence trend graph

نتایج اولیه در شکل (۴) نشان می‌دهد که بهینه‌سازی تعداد نورون‌ها با PSO می‌تواند به‌طور قابل توجهی عملکرد مدل‌های ELM را بهبود بخشد.



شکل ۴. دقت طبقه‌بندی و رگرسیون (RMSE)

Figure 4. Classification and regression accuracy (RMSE)



۳/۲/۳. پرسپترون چندلایه (MLP):

از MLP به‌عنوان مدل مقایسه‌ای جهت تشخیص خرابی تیرهای فولادی استفاده شده است. ساختار MLP شامل دو لایه مخفی با ۵۰ نورون در نظر گرفته شد و برای تنظیم بهینه هاپرپارامترها از جستجوی شبکه‌ای با اعتبارسنجی متقاطع استفاده گردید. تابع هزینه به کار رفته Cross Entropy بود و آموزش مدل با استفاده از بهینه‌ساز "Ibfgs"

انجام شد که برای داده‌های کوچک‌تر بسیار مناسب است. دقت نهایی این مدل پس از پیش‌پردازش حدود ۴۷٪ بدست آمد. این نتیجه نشان می‌دهد که MLP با وجود انعطاف‌پذیری، نیاز به داده‌های بیشتر یا ساختارهای پیچیده‌تر برای رسیدن به دقت بالاتر دارد. پیکربندی به کار رفته طبق جدول (۵) می‌باشد.

Table 5. MLP Specifications

Hyperparameter	Value	Description
Hidden layers	2	Number of hidden layers
Neurons per hidden layer	50	Neurons per layer
Activation function	ReLU	$\max(0, z) = g(z)$
Solver	Ibfgs	Optimizer
Regularization rate ( $\alpha$ )	0.001	To prevent overfitting

### جدول ۵. مشخصات MLP

Table 5. MLP Specifications

۳/۲/۳. روش ترکیبی:

برای افزایش پایداری و دقت مدل نهایی، پیش‌بینی‌های ELM+PSO و MLP با رأی‌گیری اکثریت ترکیب گردید. در این روش هر مدل یک رأی دارد و کلاس با بیشترین رأی به‌عنوان خروجی نهایی انتخاب می‌شود. برای هر نمونه، اگر هر دو مدل پیش‌بینی یکسان داشتند، همان نتیجه نهایی ثبت گردید و اگر اختلاف نظر وجود داشت، پیش‌بینی مدل دقیق‌تر (ELM+PSO) اولویت داشت. این ترکیب منجر به افزایش دقت نهایی تا حدود ۵۵٪ شد. از آن‌جا که مدل‌های پایه بر مبنای الگوریتم‌های متفاوتی آموزش دیده‌اند (یکی بر پایه یادگیری سریع و دیگری بر پایه گرادینان نزولی)، رفتار آنها در مواجهه با نویز یا داده‌های حدی متفاوت است و در نتیجه ترکیب آنها منجر به افزایش پایداری و دقت مدل نهایی می‌شود. مشخصات این روش در جدول (۶) آورده شده است.

### جدول ۶. مشخصات روش Ensemble

Table 6. Specifications of the Ensemble Method

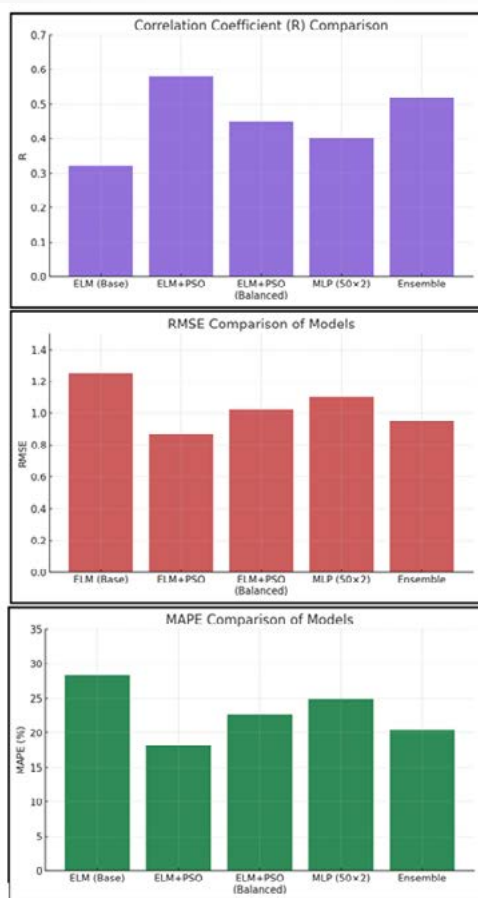
Feature	Description
Base models	ELM+PSO, MLP
Combination method	Majority voting
Weighting scheme	Equal weighting (one vote per model)

### جدول ۶. مشخصات روش Ensemble

Table 6. Specifications of the Ensemble Method


### ۴. نتایج و بحث:

برای مقایسه جامع مدل‌ها، سه شاخص آماری ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و میانگین مطلق درصد خطا (MAPE) محاسبه گردید. خلاصه نتایج در جدول (۷) و شکل (۵) و (۶) آورده شده است. تمامی نتایج گزارش شده شامل



شکل ۵. نمودار مقایسه عملکرد مدل ها

Figure 5. Comparison of model performance



شکل ۶. نمودار مقایسه دقت مدل ها (Classification Accuracy)

Figure 6. Comparison of model classification accuracy

۱/۴. مقایسه با مطالعات گذشته:

به منظور مقایسه عملکرد مدل های پیشنهادی با روش های موجود و بررسی صحت مدل ها در پیش بینی نتایج، مقادیر ضریب همبستگی مدل ها در هر پیش بینی در جدول (۱۱) نشان داده شده است. بررسی و مقایسه عملکرد مطالعات انجام شده در این پژوهش با مطالعات گذشته، نشان می دهد که استفاده از روش های پیشنهادی در مقایسه با سایر

جدول، نمودارها و شاخص های ارزیابی، صرفاً بر اساس مجموعه تست بدست آمده اند تا عملکرد واقعی مدل بدون تأثیر داده های آموزشی ارزیابی شود.

در نمودار شکل (۵) ضریب همبستگی (R) میزان تطابق بین پیش بینی مدل و داده های واقعی را بیان می کند. مدل ELM+PSO با  $R = 0.58$  بالاترین همبستگی را دارد، که نشان می دهد پیش بینی های آن بیشتر با روند واقعی داده ها هماهنگ است. مدل ترکیبی نیز با  $R = 0.52$  عملکردی نزدیک به ELM+PSO دارد، در حالی که مدل پایه ELM با  $R = 0.32$  همبستگی ضعیف تری نشان می دهد. مقدار RMSE نیز نشان دهنده میزان خطای مطلق مدل در پیش بینی مقادیر واقعی است. کمترین RMSE مربوط به ELM+PSO و بیشترین مربوط به مدل پایه ELM است. مدل ترکیبی نیز با RMSE معادل ۰٫۹۵ نسبتاً مطلوب عمل کرده و توانسته میان کاهش خطا (RMSE کمتر) و افزایش همبستگی خروجی ها (R بالاتر) توازن مناسبی برقرار کند. همچنین مقدار میانگین درصد خطای مطلق عملکرد نسبی مدل ها را در پیش بینی مقادیر مختلف ارزیابی می کند. مدل ELM+PSO با MAPE معادل ۱۸٫۲٪ کمترین خطای نسبی را دارد، که نشان دهنده دقت بالا در تخمین مقادیر واقعی است. مدل پایه ELM با MAPE برابر ۲۸٫۴٪ ضعیف ترین عملکرد را داشته و مدل ترکیبی با ۲۰٫۵٪ در رتبه دوم قرار می گیرد. در نمودار شکل (۶) نیز، مدل ELM+PSO با دقت ۶۱٫۷٪ بالاترین عملکرد را در میان مدل های بررسی شده دارد. معیار دقت به صورت Classification Accuracy تعریف شده و از معیارهای RMSE و MAPE مجزا است. بنابراین از این بخش به بعد، واژه Accuracy صرفاً برای ارزیابی مدل دسته بندی (سالم/معیوب) به کار می رود. مدل پایه ELM تنها ۴۰٪ دقت داشته که نشان می دهد بدون تنظیم پارامترها کارایی پایینی دارد. مدل ترکیبی (Ensemble) نیز با دقت ۵۵٪ نشان می دهد که ترکیب خروجی مدل ها می تواند بهبود ملموسی در دقت داشته باشد.

## جدول ۷. عملکرد مدل ها بر اساس R, RMSE, MAPE

Table 7. Model performance based on R, RMSE, and MAPE

Model	R	RMSE	MAPE (%)
ELM(100Neurons)	0.32	1.25	28.4
ELM+PSO	0.58	0.87	18.2
ELM+PSO (Balanced)	0.45	1.02	22.7
MLP(2x50)	0.40	1.10	24.9
Ensemble (ELM+MLP)	0.52	0.95	20.5



روش‌های موجود در مطالعات گذشته قادر به ارائه نتایج دقیقی بوده است. مطالعات [۳]، [۴]، [۷] و [۹] نشان می‌دهند که استفاده از ترکیب ELM با الگوریتم‌های بهینه‌سازی یا استخراج ویژگی پیشرفته باعث بهبود چشمگیر دقت و کاهش خطا شده است. همان‌طور که مشاهده می‌گردد دقت این پژوهش در مقایسه با مطالعات شبیه‌سازی [۴] در محدوده‌ی قابل قبولی قرار دارد.

## جدول ۱۱. مقایسه عملکرد با مطالعات گذشته

**Tabl11: Performance comparison with previous studies**

Data type	R	Model	Study
Steel-concrete composite beam (experimental)	0.58	ANN with frequency-domain features	[3]
FEM-based simulation of a steel beam	0.60	ELM+PSO	[4]
Numerical simulation of a steel beam	0.88	PSO-SVM	[7]
Experimental study on a steel beam	0.62	Natural frequency-based features with classical ML	[9]
Semi-experimental	0.58	ELM+PSO & Ensemble	Present study

## ۵. نتیجه‌گیری:

در این پژوهش یک چارچوب عملی و سریع برای شناسایی خرابی موضعی تیرهای فولادی ارائه شد که شامل جمع‌آوری داده، پیش‌پردازش، مدلسازی با ELM و MLP و ترکیب آنها با روش Ensemble است. همچنین ترکیب دو مدل اصلی یعنی ELM+PSO و MLP به روش "رای گیری اکثریت" انجام گرفت. نتایج حاصل از این تحقیق به صورت ذیل خلاصه می‌شود:

۱. بهینه‌سازی پارامتری با PSO برای ELM قادر است دقت را از ۰/۴۰ به ۰/۶۷ برساند و خطا را تا ۳۰٪ کاهش دهد.

۲. دقت نهایی مدل MLP پس از پیش‌پردازش حدود ۴۷٪ بدست آمد که نسبت به مدل ELM+PSO کمی پایین‌تر بود. در نتیجه می‌توان این‌طور بیان کرد که مدل MLP (۲×۵) دارای عملکرد پایدار اما کندتر می‌باشد.

۳. استفاده از MLP در کنار ELM به دلیل انعطاف‌پذیری بالا در یادگیری روابط غیرخطی، می‌تواند مکمل خوبی باشد، هرچند به داده‌های آموزشی بیشتری نیاز دارد.

۴. روش Ensemble با رای‌گیری اکثریت، ضمن بهبود ثبات پیش‌بینی‌ها، دقت نهایی را تا ۵۵٪ افزایش می‌دهد.

۵. مقایسه با مطالعات گذشته نشان داد مدل‌های ترکیبی ELM+PSO و Wavelet-ELM عملکرد بسیار مطلوبی ارائه می‌کنند و داده‌های کم‌حجم می‌توانند جایگزین موقت مناسبی برای داده‌های آزمایشگاهی باشند.

بیانیه استفاده از ابزارهای هوش مصنوعی:

در تهیه متن مقاله جهت بهبود خوانایی و روانی از ChatGPT 5 استفاده شده است. پس از استفاده از این ابزار، در مواردی که لازم بوده نویسندگان مقاله را بازنگری و ویرایش کرده و مسئولیت کامل مطالب منتشر شده در مقاله را می‌پذیرند.

تعارض منافع: هیچ گونه تعارض منافی توسط نویسندگان وجود ندارد.

## فهرست منابع

- structures using artificial intelligence techniques, *Experimental Techniques*, vol. 45, no. 4, pp. 389-410, 2021, doi: 10.1007/s40799-020-00421-5
- [6] W. Dillen, G. Lombaert, and M. Schevenels, A hybrid gradient-based/metaheuristic method for Eurocode-compliant size, shape and topology optimization of steel structures, *Engineering Structures*, vol. 239, p. 112137, 2021, doi: 10.1016/j.engstruct.2021.112137
- [7] T. Cuong-Le, T. Nghia-Nguyen, S. Khatir, and D. Boutchicha, An efficient approach for damage identification based on improved machine learning using PSO SVM, *Engineering Computations*, vol. 38, no. 2, 2022, doi: 10.1007/s00366-021-01299-6
- [8] C. Zhang, J. Shi, and C. Huang, Identification of damage in steel-concrete composite beams based on wavelet analysis and deep learning, *Structural Durability & Health Monitoring*, vol. 18, no. 4, pp. 465-483, 2024, doi: 10.32604/sdhm.2024.048705
- [9] D. T. Vu-Van-Tuan, H. M. Nguyen, and X. P. Pham, Damage detection in steel beams using natural frequency analysis and machine learning techniques, *Smart Structures and Systems*, vol. 20, no. 5, pp. 525-541, 2025, doi: 10.1177/03093247251327622
- [10] L. S. Al-Ansari, M. Al-Waily, and A. M. H. Y. Al-Hajjar, Experimental and numerical study of crack effect on frequency of simple supported beam, *Al-Khwarizmi Eng. J.*, vol. 8, no. 2, pp. 30-41, 2012, doi: https://alkejuobaghdad.edu.iq/index.php/alkej/article/view/127
- [11] N. V. Kazarinov, Y. Petrov, and A. Benin, Modeling of dynamic crack propagation under quasistatic loading, in *International Scientific Siberian Transport Forum TransSiberia 2021*, vol. 1, Mar. 2022, doi: 10.1007/978-3-030-96380-4\_63
- [12] F. Cannizzaro, N. Impollonia, S. Caddemi, and I. Cali, Explicit dynamic response of damaged beams with application to uncertain and identification problems, *Journal of Sound and Vibration*, vol. 487, p. 115608, Nov. 2020, doi: 10.1016/j.jsv.2020.115608
- [13] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, SMOTE: Synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, vol. 16, pp. 321-357, 2020, doi: 10.1613/jair.953
- [14] Ch. Wang, T. Li, Zh. Lu, Zh. Wang, T. Alballa, S. S. Albely, and H. Abd El-Wahed Khalifa, Application of artificial intelligence for feature engineering in education sector and learning science, *Alexandria Engineering Journal*, vol. 110, pp. 108-115, 2025, doi: 10.1016/j.aej.2024.09.100
- [15] F. Pedregosa et al., Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, vol. 12, pp. 2825-2830, 2011, doi: https://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf
- [16] M. Hanteh, H. Malek, and A. Kheyroddin, Proposing the combined MARS-PSO and ELM-PSO models for estimating the compressive strength of circular concrete columns wrapped with FRP sheets, *Soft Computing*, Springer Berlin Heidelberg, pp. 1-17, 2023, doi: 10.1007/s00500-023-08854-x
- [17] M. Akbari and M. Hanteh, Comparison of genetic algorithm (GA) and particle swarm optimization algorithm (PSO) for discrete and continuous size optimization of 2D truss structures, *Journal of Soft Computing in Civil Engineering*, vol. 3, no. 2, pp. 76-97, 2019, doi: 10.22115/scce.2019.195713.1117
- [18] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, MIT Press, 2016, doi: https://mnasr.github.io/deeplearninghandbook/slides/07\_regularization.pdf
- [19] H. Malek and M. Ehteshami, Analysis of Sewage Treatment Plants Data to evaluate Quality of Effluent using Experimental Results and Prediction based on Artificial Intelligence Models (Case Study: Tehran Wastewater Treatment Plant), *Journal of Structural and Construction Engineering*, vol. 10, no. 2, pp. 5-26, 2023, doi: 10.22065/jsce.2022.333652.2754
- [20] L. Rokach, Ensemble Learning: A Survey, *WIREs Data Mining and Knowledge Discovery*, vol. 8, no. 5, 2018, doi: 10.1002/widm.1249
- [21] Z.-H. Zhou, *Ensemble Methods: Foundations and Algorithms*, CRC Press, 2012, doi: https://tjzhifei.github.io/links/EMFA.pdf
- [22] T. Chai and R. R. Draxler, Root mean square error (RMSE) or mean absolute error (MAE) Arguments against avoiding RMSE in the literature, *Geoscientific Model Development*, vol. 7, no. 3, pp. 1247-1250, 2014, doi: http://dx.doi.org/10.5194/gmd-7-1247-2014
- [23] M. Hanteh and O. Rezaifar, Damage detection in precast full panel building by continuous wavelet analysis analytical method, *Structures*, vol. 29, pp. 701-713, 2021, doi: 10.1016/j.jstruc.2020.12.002
- [24] M. Hanteh, O. Rezaifar, and M. Gholhaki, Selecting the appropriate wavelet function in the damage detection of precast full panel building based on experimental results and wavelet analysis, *Journal of Civil Structural Health Monitoring*, vol. 11, no. 4, pp. 1013-1036, 2021, doi: 10.1007/s13349-021-00497-6

- [1] L. Sun, Z. Shang, Y. Xia, J. Zhu, J. Wang, and D. Parker, Review of bridge structural health monitoring aided by big data and artificial intelligence: From condition assessment to damage detection, *Journal of Structural Engineering*, vol. 146, no. 5, p. 04020073, 2020, doi: 10.1061/(ASCE)ST.1943-541X.0002535
- [2] Z. X. Tan, D. P. Thambiratnam, T. H. T. Chan, S. T. Yeung, and W. Xue, Damage detection in steel-concrete composite bridges using vibration characteristics and artificial neural networks, *Structural Infrastructure Engineering*, vol. 16, no. 8, pp. 1247-1261, 2020, doi: 10.1080/15732479.2019.1696378
- [3] Z. Rastin, G. Ghodrati Amiri, and E. Darvishan, Unsupervised structural damage detection technique based on a deep convolutional autoencoder, *Shock and Vibration*, 2021, Art. ID 6658575, doi: 10.1155/2021/6658575
- [4] S. Jiang, L. Zhao, and C. Du, Structural deformation prediction model based on extreme learning machine algorithm and particle swarm optimization, *Structural Health Monitoring*, vol. 21, no. 6, pp. 2786-2803, 2022, doi: 10.1177/1475921721107223
- [5] A. Tavares, E. Di Lorenzo, B. Peeters, A. Corigliano, F. Miulli, and F. Vestroni, Damage detection in lightweight