Journal of Applied And Basic Machine Intelligence Research (ABMIR)

پژوهش‌های نظری و کاربردی هوش ماشینی

سال چهارم، شماره دوم، پاییز و زمستان ۱۴۰۵، صفحات ۱۶ – ۱

بهینه‌سازی ترکیب آلیاژها برای تولید فولاد با استحکام بالا با استفاده از الگوریتم‌های تکاملی و یادگیری ماشین (بهینه‌سازی فرآیند تولید فولاد)

فاطمه زارع مهرجردی[1*]

[1] استادیار، دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر، دانشگاه میبد، میبد، ایران

مقاله پژوهشی

تاریخ دریافت:
۱۴۰۴/۰۵/۳۱

تاریخ پذیرش:
۱۴۰۴/۰۸/۰۷

کلیدواژه‌ها:
تولید فولاد، الگوریتم تکاملی، یادگیری ماشین، الگوریتم استعمار رقابتی، الگوریتم ازدحام ذرات، الگوریتم گرگ خاکستری

نویسنده‌مسئول:
fzare@meybod.ac.ir

چکیده

در این پژوهش، یک رویکرد نوین برای حل مسئله پیچیده بهینه‌سازی ترکیب شیمیایی فولاد به‌منظور دستیابی به حداکثر استحکام تسلیم ارائه‌شده است. به دلیل ناکارآمدی روش‌های سنتی مبتنی بر آزمون‌وخطا، از یک رویکرد ترکیبی و دومرحله‌ای استفاده‌شده است. در مرحله اول، یک مدل یادگیری ماشین به نام جنگل تصادفی بر روی مجموعه داده‌های واقعی از ترکیبات فولادی آموزش داده‌شده است تا به‌عنوان یک تابع برازندگی دقیق برای پیش‌بینی استحکام عمل کند. در مرحله دوم، نُه الگوریتم تکاملی و فرابتکاری شامل الگوریتم ژنتیک، ازدحام ذرات، شبیه‌سازی تبرید، زنبورعسل، کرم شب‌تاب، جستجوی گرانشی، رقابت استعماری، بهینه‌سازی گرگ خاکستری و کلونی مورچگان برای یافتن ترکیب آلیاژی بهینه به کار گرفته‌شده‌اند. نتایج ۱۰ اجرای مستقل نشان داده است که الگوریتم ازدحام ذرات با کسب بهترین استحکام تسلیم برترین عملکرد را در یافتن ترکیب بهینه داشته است. الگوریتم‌های بهینه‌سازی گرگ خاکستری و رقابت استعماری نیز عملکرد بسیار نزدیکی به الگوریتم ازدحام ذرات از خود نشان داده‌اند. در مقابل، الگوریتم شبیه‌سازی تبرید با وجود سرعت بالا، به یک راه‌حل زیر بهینه همگرا شده است و الگوریتم کرم شب‌تاب نیز از نظر زمان اجرا بسیار ناکارآمد عمل کرده است. تحلیل نتایج بهترین ترکیب‌های به‌دست‌آمده نشان می‌دهد که برای حداکثر کردن استحکام تسلیم، فولاد باید حاوی درصد بالایی از عنصر کبالت و عناصر کاربیدساز قوی (مانند کروم و تنگستن) باشد، درحالی‌که درصد عناصر کلیدی مانند نیکل، کربن و وانادیوم می‌تواند بسیار پایین یا نزدیک به صفر باشد. این رویکرد، راهکاری کارآمد برای طراحی مواد با خواص مطلوب بدون نیاز به آزمایش‌ها تجربی گسترده را فراهم می‌آورد.

: 10.22034/ABMIR.2025.23571.1158

E-ISSN: 2821-2037

/The Author 2026. Published by Yazd University This is an open access article under the CC BY 4.0 License https://creativecommons.org/licenses/by/4.0/).

۱- مقدمه

فولاد، به‌عنوان یکی از حیاتی‌ترین و پرکاربردترین مواد در صنایع مختلف ازجمله ساختمان‌سازی، خودروسازی و هوافضا، به دلیل خواص مکانیکی منحصربه‌فردش از اهمیت بالایی برخوردار است . استحکام تسلیم[1] فولاد، یک عامل کلیدی در تعیین کارایی، ایمنی و بهینگی وزن سازه‌های مهندسی است. افزایش استحکام تسلیم به معنای توانایی بیشتر ماده در تحمل تنش‌های بیشتر بدون وقوع تغییر شکل دائمی است، که این امر مستقیماً به ایمنی، دوام و کاهش وزن سازه‌ها منجر می‌شود. به‌عنوان مثال، در صنایع هوافضا، استفاده از آلیاژهای فولادی با استحکام بالا امکان طراحی بدنه‌ها و موتورهای سبک‌تر و کارآمدتر را فراهم می‌کند [۱]. برای دستیابی به استحکام موردنیاز، ترکیبات مختلفی از عناصر آلیاژی (نظیر کروم، نیکل و...) به فولاد پایه اضافه می‌شود. بااین‌حال، یافتن نسبت بهینه این آلیاژها که منجر به حداکثر استحکام شود، یک مسئله بسیار پیچیده، غیرخطی و چندبُعدی با فضای جستجوی بسیار گسترده است .روش‌های سنتی مبتنی بر آزمون‌وخطا، به دلیل هزینه بسیار بالا و زمان‌بر بودن، کارایی لازم را ندارند و اغلب به راه‌حل‌های زیر بهینه و هدررفت منابع مادی منجر می‌شوند، که این خود چالش اصلی در طراحی فولادهای نسل جدید است.

در سال‌های اخیر، با پیشرفت‌های چشم‌گیر در حوزه هوش مصنوعی و یادگیری ماشین، رویکردهای نوین و کارآمدی برای حل این مسائل مطرح‌شده است. بسیاری از پژوهش‌ها از مدل‌های شبکه عصبی مصنوعی یا دیگر مدل‌های یادگیری ماشین برای پیش‌بینی استحکام فولاد بر اساس ترکیب شیمیایی آن استفاده کرده‌اند. بااین‌حال، اغلب این مدل‌ها قابلیت تفسیرپذیری ندارند و نمی‌توانند اهمیت نسبی هر عنصر را در تعیین استحکام مشخص کنند، که این امر برای مهندسان مواد حیاتی است. هم‌چنین، این مدل‌ها به‌تنهایی توانایی پیش‌بینی دارند و فاقد قابلیت بهینه‌سازی و یافتن بهترین ترکیب ممکن هستند.

برای حل مشکل بهینه‌سازی، الگوریتم‌های تکاملی[2] به‌عنوان یک ابزار قدرتمند ظهور کرده‌اند که از فرآیندهای تکامل بیولوژیکی الهام گرفته‌اند و می‌توانند به‌صورت کارآمد در فضاهای جستجوی پیچیده، بهترین راه‌حل را جستجو نمایند. شکاف اصلی پژوهشی در این حوزه، فقدان یک چارچوب جامع است که بتواند مزایای مدل‌های دقیق (با قابلیت تفسیر) و قدرت جستجوی طیف وسیعی از الگوریتم‌های فراابتکاری را به‌صورت آماری و قابل‌اعتماد با یکدیگر ترکیب کند [۲].

در همین راستا، نوآوری و سهم اصلی پژوهش حاضر، در ارائه یک روش ترکیبی و دومرحله‌ای برای حل این مسئله است. این رویکرد، مدل یادگیری ماشین و قدرت جستجوی الگوریتم‌های تکاملی را با هم ترکیب می‌کند. نوآوری‌های کلیدی این مقاله عبارت‌اند از:

۱) استفاده از مدل رگرسیون جنگل تصادفی به‌عنوان معیار ارزیابی استحکام. این مدل علاوه بر دقت بالا، به دلیل قابلیت تفسیرپذیری، سهم هر عنصر آلیاژی را در فرآیند استحکام‌بخشی به‌روشنی مشخص می‌کند.

۲) انجام جامع‌ترین مقایسه عملکرد با به‌کارگیری و ارزیابی ۹ الگوریتم تکاملی و فراابتکاری مختلف. نتایج این مقایسه بر اساس تحلیل آماری ۱۰ بار اجرای مجدد گزارش‌شده است، که این شیوه، پایداری[3] و تکرارپذیری نتایج بهینه‌سازی را تضمین کرده و برتری یک الگوریتم خاص را به‌صورت قطعی اثبات می‌کند.

۳) معرفی ترکیب شیمیایی بهینه و نهایی برای تولید فولاد با حداکثر استحکام تسلیم، که به‌عنوان یک دستورالعمل علمی، مستقیماً قابل‌استفاده در مطالعات آزمایشگاهی و فاز صنعتی است.

این پژوهش نه تنها یک مدل پیش‌بینی دقیق ارائه می‌دهد، بلکه با تبدیل فضای جستجوی پیچیده به یک مسئله قابل‌حل محاسباتی، ارزش کاربردی و صنعتی نتایج را برجسته می‌کند. چارچوب پیشنهادی، زمان طراحی و توسعه آلیاژهای جدید را از ماه‌ها (آزمایشگاهی) به چند دقیقه (محاسباتی) کاهش داده و به مهندسان

[1] Yield Strength
[2] Evolutionary Algorithms
[3] Robustness

کمک می‌کند تا به جای روش‌های سنتی پرهزینه، به نسخه‌ای بهینه‌سازی‌شده و معتبر برای تولید فولاد دست یابند.

در ادامه، ساختار مقاله بدین صورت تقسیم‌بندی شده است :بخش دوم، به‌مرور انتقادی و مفصل‌تر کارهای گذشته در زمینه مدل‌سازی و بهینه‌سازی مواد اختصاص دارد؛ بخش سوم به توضیح روش پیشنهادی و جزئیات پیاده‌سازی الگوریتم‌ها پرداخته است؛ در بخش چهارم، نتایج حاصل از شبیه‌سازی‌ها و تحلیل آماری مقایسه‌ای مورد تحلیل قرارگرفته است؛ و درنهایت، در بخش پنجم نتیجه‌گیری و ارائه پیشنهادهایی برای پژوهش‌های آینده آورده شده است.

۲- مروری بر کارهای گذشته

در زمینه طراحی و بهینه‌سازی مواد با استفاده از رویکردهای محاسباتی، مطالعات متعددی انجام‌شده است که عموماً از یک رویکرد ترکیبی (هیبرید) استفاده می‌کنند که شامل یک مدل یادگیری ماشین برای پیش‌بینی خواص مواد و یک الگوریتم تکاملی برای بهینه‌سازی است. در همین راستا، تحقیقاتی مانند کار زو و همکاران نشان می‌دهد که می‌توان از یک رویکرد ترکیبی استفاده کرد. ابتدا با یک شبکه عصبی خواص را پیش‌بینی و سپس از الگوریتم ژنتیک برای بهینه‌سازی ترکیب آلیاژها استفاده کرد [۳].

لئو و همکاران [٤] یک رویکردی نوین را برای بهینه‌سازی ترکیب شیمیایی فولاد ضدزنگ آستنیتی با هدف کاهش هزینه و تسریع در طراحی گریدهای جدید فولاد بدون افت خواص مکانیکی ارائه دادند. آن‌ها با استفاده از داده‌های تجربی، یک مدل پیش‌بینی‌کننده با الگوریتم رگرسیون گرادیان بوستینگ ایجاد کردند که دقت پیش‌بینی بالایی را نسبت به سایر الگوریتم‌های یادگیری ماشین نشان داد. برای بهینه‌سازی پارامترهای مدل رگرسیون گرادیان بوستینگ، از بهینه‌سازی بیزی استفاده کردند و مدل نهایی به دقت قابل قبولی در پیش‌بینی استحکام تسلیم و دست‌یافتند. درنهایت، الگوریتم NSGA-III برای بهینه‌سازی چند-هدفه را به کار گرفتند تا هم‌زمان چندین خاصیت مکانیکی را به حداکثر برساند و مجموعه راه‌حل‌های بهینه ترکیب شیمیایی را به دست آوردند.

در پژوهشی دیگر از دویکلاریچ و همکاران [۵]، از داده‌های تجربی و یک الگوریتم بهینه‌سازی چند-هدفه تکاملی برای بهینه‌سازی هم‌زمان چندین خاصیت آلیاژهای فولاد استفاده‌شده است، با این هدف که تعداد آزمایش‌ها تجربی به حداقل برسد. این رویکرد توانایی شناسایی ترکیبات شیمیایی جدیدی برای آلیاژهای بسیار برتر را نشان داد که با روش‌های کلاسیک نیاز به هزاران آزمایش دارند، اما با این روش تنها به ۸۰ نمونه جدید نیاز است. هم‌چنین، این رویکرد قادر به تعیین غلظت عناصر آلیاژی برای مجموعه‌ای مشخص از خواص موردنیاز برای کاربردهای خاص است. در این پژوهش، علاوه بر اهداف معمول مانند حداکثر کردن تنش کششی و زمان تا پارگی، اهداف دیگری مانند هزینه و وزن نیز در نظر گرفته‌شده‌اند.

مطالعه انجام‌شده توسطیان و همکاران [٦]، یک مدل ریاضی برای پیش‌بینی دمای شمش فولاد ارائه می‌دهد تا مشکل دقت پایین در پیش‌بینی دما را برطرف کند. برای این منظور، یک الگوریتم بهینه‌سازی ازدحام ذرات بهبودیافته طراحی‌شده است که با استفاده از یک طرح چند-جمعیتی، توانایی جستجوی سراسری و مقاومت آن در برابر گیر افتادن در بهینه‌های محلی را افزایش می‌دهد. این طرح چند-جمعیتی شامل چهار راهکار اصلاحی است: استراتژی بهبود مقداردهی اولیه موقعیت، استراتژی جهش برای جمعیت ذرات، استراتژی تنظیم وزن اینرسی و استراتژی خروج از بهینه‌های محلی. نتایج به‌دست‌آمده نشان می‌دهد که این الگوریتم بهبودیافته در پیش‌بینی دمای شمش‌های فولاد نسبت به سایر الگوریتم‌های مشابه و دیگر روش‌های بهینه‌سازی، دقت بسیار بالاتری دارد.

باباچنکو و همکاران [۷]، رویکردی را برای بهینه‌سازی ترکیب شیمیایی فولادهای ساختاری پرمقاومت ارائه دادند. این رویکرد بر پایه یک روش مدل‌سازی فیزیکی-شیمیایی است که در انستیتوی آهن و فولاد توسعه‌یافته است. اصل این روش، توصیف ترکیب شیمیایی مذاب با استفاده از پارامترهای مدل انتگرالی تعاملات بین‌اتمی است که وضعیت شیمیایی و ساختاری مذاب را مشخص می‌کنند. داده‌های تجربی برای به‌دست آوردن یک مدل رگرسیون برای خواص مکانیکی بر اساس همین پارامترهای تعامل بین‌اتمی تجزیه‌وتحلیل شدند. درنهایت، از یک روش بهینه‌سازی چند-معیاره برای رسیدن به هدف نهایی استفاده‌شده است.

مقاله [۸]، یک مدل ترکیبی انجام‌شده توسط لو و همکاران را ارائه می‌دهد که از الگوریتم بهینه‌سازی گرگ خاکستری چند-هدفه و ماشین بردار پشتیبان برای پیش‌بینی خواص مواد کامپوزیتی استفاده می‌کند. این مدل بر روی شش مجموعه داده، که سه مورد آن‌ها دارای ویژگی سری زمانی هستند، مورد ارزیابی قرارگرفته است. نتایج نشان می‌دهند که مدل پیشنهادی عملکرد بسیار خوبی در پیش‌بینی خواص دارد. آن‌ها نتیجه می‌گیرند که هرچه داده‌های بیشتری درمجموعه آموزشی وجود داشته باشد، عملکرد مدل بهتر خواهد بود و مدل‌های یادگیری ماشین پتانسیل زیادی در آزمایش خواص مواد کامپوزیتی و طراحی مواد جدید دارند. هم‌چنین، تحلیل‌ها نشان داد که حذف متغیرهایی با هم‌بستگی خطی ضعیف می‌تواند دقت پیش‌بینی مدل را در برخی مجموعه‌های داده افزایش دهد.

پنگ و همکاران [۹]، یک روش ترکیبی برای پیش‌بینی دقیق و کارآمد خواص مکانیکی فولاد کم‌آلیاژ ارائه دادند. این روش، الگوریتم بهینه‌سازی کپک لجن[1] را با رگرسیون بردار پشتیبان (SVR) ترکیب می‌کند تا مشکل بهینه‌سازی پارامترهای SVR را حل کند. با استفاده از این روش، آن‌ها قادر به پیش‌بینی دو خاصیت مهم استحکام کششی و تنش تسلیم شدند. نتایج آزمایش‌ها که با استفاده از داده‌های پایگاه داده NIMS انجام‌شده، نشان می‌دهد که مدل ترکیبی از نظر دقت و کارایی محاسباتی عملکرد بهتری دارد. این مدل می‌تواند به‌طور قابل‌توجهی زمان توسعه و هزینه تولید فولادهای آلیاژی جدید را کاهش دهد.

با وجود تلاش‌های ارزشمند محققان قبلی در به‌کارگیری رویکردهای ترکیبی برای بهینه‌سازی مواد، بررسی دقیق این مطالعات کاستی‌های مهمی را آشکار می‌سازد که شکاف پژوهشی این حوزه را تشکیل می‌دهند. اولاً، تکیه بر مدل‌های جعبه سیاه[2] در پژوهش‌های پیشین، منجر به عدم تفسیرپذیری نتایج شده و امکان درک سهم واقعی هر عنصر آلیاژی در استحکام را از مهندسان سلب کرده است. ثانیاً، مطالعات اغلب به یک یا نهایتاً دو الگوریتم تکاملی محدود شده‌اند و نتایج آن‌ها به دلیل عدم انجام مقایسه جامع و فقدان تحلیل آماری (در چندین بار اجرا)، از پایداری و اعتبار کافی برخوردار نیستند. تحقیق حاضر در راستای پوشش دادن همین شکاف‌ها صورت گرفته است .قوت و ایده اصلی این پژوهش، در ارائه یک رویکرد جامع است که اولاً از مدل رگرسیون جنگل تصادفی (به دلیل دقت و قابلیت تفسیرپذیری بالا) به‌عنوان تابع ارزیابی استفاده می‌کند و ثانیاً، با به‌کارگیری و ارزیابی ۹ الگوریتم تکاملی و فراابتکاری مختلف و گزارش نتایج بر اساس تحلیل آماری ۱۰ بار اجرای مجدد، عملکرد الگوریتم‌ها را به‌صورت قابل‌اتکا و مستحکم مقایسه می‌کند. این رویکرد به ما امکان می‌دهد که با بهره‌گیری از دقت بالای مدل پیش‌بینی‌کننده، مقادیر بهینه آلیاژها را برای دستیابی به حداکثر استحکام فولاد با کارایی و اعتبار آماری بالاتری، همراه با کاهش زمان و هزینه جستجو کنیم.

۳- مفاهیم اصلی

در این پژوهش، از یک رویکرد ترکیبی و دومرحله‌ای برای بهینه‌سازی ترکیب آلیاژها به‌منظور دستیابی به حداکثر استحکام فولاد استفاده‌شده است. هدف پژوهش حاضر، بررسی و مقایسه عملکرد نه الگوریتم تکاملی مختلف در بهینه‌سازی ترکیبات فولاد است. روش پیشنهادی شامل دو مرحله اصلی آموزش مدل پیش‌بینی‌کننده با استفاده از رگرسیون جنگل تصادفی[3] و سپس استفاده از آن به‌عنوان تابع برازندگی برای الگوریتم‌های تکاملی است. در ادامه توضیحاتی در مورد پایگاه داده مورداستفاده، الگوریتم رگرسیون جنگل تصادفی، مراحل مربوط به نه الگوریتم‌های تکاملی مورداستفاده و روش پیشنهادی ترکیبی و دومرحله‌ای آورده شده است.

۳-۱ پایگاه داده مورداستفاده

پژوهش حاضر بر پایه یک مجموعه داده تجربی با نام "steel_strength.csv" که شامل ۲۴۶۹ نمونه است، بنا شده است و از پلتفرم Kaggle[4] تهیه‌شده است. این مجموعه داده‌ها، ترکیبات مختلفی از آلیاژها و استحکام نهایی فولاد حاصل از هر ترکیب را در برمی‌گیرد. متغیرهای ورودی شامل مقادیر وزنی آلیاژهای کربن

[1] Slime Mould Algorithm
[2] Black Box
[3] Random Forest Regression
[4] https://www.kaggle.com/datasets/fuarresvij/steel-test-data?select=steel_strength.csv

(C)، منگنز (Mn)، سیلیسیوم (Si)، کروم (Cr)، نیکل (Ni)، مولیبدن (Mo)، وانادیوم (V)، نیتروژن (N)، نیوبیوم (Nb)، کبالت (Co)، تنگستن (W)، آلومینیوم (Al)، تیتانیوم (Ti) و آهن(Fe) هستند. متغیر خروجی نیز استحکام تسلیم فولاد با واحد مگاپاسکال (MPa) است.

۳-۲ الگوریتم رگرسیون جنگل تصادفی به‌عنوان تابع هزینه

در این پژوهش، به دلیل پیچیدگی روابط غیرخطی میان ترکیب آلیاژها و استحکام نهایی فولاد، از مدل رگرسیون جنگل تصادفی به‌عنوان یک الگوریتم یادگیری گروهی قدرتمند و مقاوم برای پیش‌بینی استحکام تسلیم استفاده‌شده است. این الگوریتم، که برای وظایف رگرسیون (پیش‌بینی مقادیر عددی پیوسته) به کار می‌رود، با ساخت یک جنگل از چندین درخت تصمیم در طول آموزش و سپس میانگین‌گیری از پیش‌بینی‌های فردی، از مشکل بیش‌برازش جلوگیری کرده و توانایی بالایی در مدل‌سازی روابط پیچیده بین ویژگی‌ها نشان می‌دهد. مکانیزم اصلی جنگل تصادفی شامل دو تکنیک کلیدی نمونه‌برداری تصادفی با جایگذاری[1] از داده‌ها و انتخاب تصادفی زیرمجموعه‌ای از ویژگی‌ها در هر گره برای انشعاب است که پایداری و دقت مدل را به‌طور قابل‌توجهی افزایش می‌دهند [۱۰، ۱۱].

پیش از آموزش مدل، پایگاه داده مورداستفاده، تحت بررسی‌های کیفی قرارگرفته است. از آنجایی که متغیرهای ورودی (درصد وزنی آلیاژها) ماهیت فیزیکی یکسانی داشتند، هیچ‌گونه نرمال‌سازی یا استانداردسازی اعمال نشده است. بااین‌حال، تمام نمونه‌های دارای مقادیر گم‌شده حذف شدند و نمونه‌های پرت[2] که از نظر فیزیکی غیرمنطقی بودند، از مجموعه داده‌ها خارج گردیدند تا از صحت و اعتبار مدل اطمینان حاصل شود.

در ادامه برای تعیین بهینه‌ترین پارامترها و ارزیابی مدل، از روش اعتبارسنجی متقاطع ۱۰ تایی[3] استفاده‌شده است. این فرآیند با بررسی سیستماتیک پارامترهای کلیدی (ازجمله تعداد درختان و حداکثر عمق مجاز برای هر درخت) به‌منظور ایجاد تعادل بهینه بین عملکرد مدل و زمان محاسباتی انجام‌گرفته و تعداد درختان برابر ۱۰۰ و حداکثر عمق برابر ۱۰ انتخاب‌شده است. این تنظیمات تضمین می‌کند که عملکرد مدل، قابلیت تعمیم بالایی در پیش‌بینی دقیق بر روی ترکیبات آلیاژی جدید را دارد. درنهایت، ارزیابی عملکرد مدل جنگل تصادفی با استفاده از اعتبارسنجی متقابل ۱۰ تایی بر اساس دو معیار میانگین ضریب تعیین R^2 با مقدار ۰/۷۹۳۲ همراه با انحراف معیار ۰/۰۹۲۶ و میانگین خطای مطلق MAE با مقدار ۸۹/۵۱ همراه با انحراف معیار ۲۲/۰۵ گزارش‌شده است.

مقدار بالای R^2 نشان‌دهنده توانایی قوی مدل در توضیح واریانس داده‌ها است. درنهایت، این مدل رگرسیون جنگل تصادفی با پارامترهای بهینه‌شده و دقت اثبات‌شده، به‌عنوان تابع برازندگی در الگوریتم‌های تکاملی به کار گرفته‌شده است. این مدل، هر راه‌حل (ترکیب آلیاژی) پیشنهادی توسط ۹ الگوریتم تکاملی را با دقت بالا ارزیابی کرده و امتیاز برازندگی (استحکام تسلیم پیش‌بینی‌شده) آن را برای هدایت فرآیند بهینه‌سازی و جستجو در فضای راه‌حل فراهم می‌آورد.

۳-۳ الگوریتم‌های تکاملی مورداستفاده

در این پژوهش، نه الگوریتم تکاملی مختلف برای بهینه‌سازی ترکیب آلیاژها مورداستفاده قرارگرفته‌اند. در ادامه، توضیحات و مراحل گام‌به‌گام هر الگوریتم شرح داده‌شده است.

الف. الگوریتم ژنتیک[4] (GA): الگوریتم ژنتیک از فرآیندهای تکامل طبیعی، مانند انتخاب طبیعی، جهش و تقاطع برای حل مسائل بهینه‌سازی الهام گرفته است. این الگوریتم با ایجاد یک جمعیت از راه‌حل‌های کاندید، بهترین راه‌حل‌ها را برای تولید نسل‌های بعدی انتخاب و با ترکیب و تغییر آن‌ها، به‌تدریج به راه‌حل‌های بهینه نزدیک می‌شود. مراحل الگوریتم ژنتیک بدین صورت است:

۱) ایجاد جمعیت اولیه: یک مجموعه تصادفی از افراد (کروموزوم‌ها) ایجاد می‌شود که هر کدام یک ترکیب آلیاژی را نشان می‌دهند.

[1] Bootstrap Aggregation
[2] Outliers
[3] 10-Fold Cross-Validation
[4] Genetic Algorithm (GA)

۲) ارزیابی برازندگی: برای هر کروموزوم، مدل رگرسیون جنگل تصادفی، استحکام فولاد را پیش‌بینی می‌کند و این مقدار، امتیاز برازندگی آن در نظر گرفته می‌شود.
۳) انتخاب: کروموزوم‌هایی که امتیاز برازندگی بالاتری دارند، برای تولید نسل بعدی انتخاب می‌شوند.
٤) تقاطع و جهش: کروموزوم‌های انتخاب‌شده با یکدیگر ترکیب (تقاطع[1]) و سپس به‌صورت تصادفی دستخوش تغییرات کوچک (جهش[2]) قرار می‌گیرند.
۵) جایگزینی: جمعیت جدید جایگزین جمعیت قدیمی می‌شود و این فرآیند تا رسیدن به‌شرط توقف تکرار می‌گردد [۱۲، ۱۳].

ب. الگوریتم ازدحام ذرات[3] (PSO): این الگوریتم از رفتار اجتماعی دسته‌جمعی پرندگان یا ماهی‌ها برای یافتن بهترین راه‌حل در فضای جستجو الهام گرفته است. در PSO، هر ذره (راه‌حل) بر اساس بهترین موقعیت خود و بهترین موقعیت کل جمعیت، موقعیت و سرعت خود را به‌روزرسانی می‌کند. مراحل الگوریتم PSO بدین صورت است:

۱) ایجاد جمعیت اولیه: یک مجموعه از ذرات به‌صورت تصادفی در فضای جستجو توزیع می‌شوند که هر ذره نشان‌دهنده یک ترکیب آلیاژی است.
۲) ارزیابی برازندگی: برای هر ذره، مدل رگرسیون جنگل تصادفی، استحکام فولاد را پیش‌بینی می‌کند.
۳) به‌روزرسانی بهترین‌ها: در هر تکرار، بهترین موقعیت هر ذره (pbest) و بهترین موقعیت کل جمعیت (gbest) شناسایی و به‌روز می‌شود.
٤) به‌روزرسانی موقعیت و سرعت: با توجه به pbest و gbest، سرعت و موقعیت هر ذره به‌روزرسانی می‌شود.
۵) تکرار: این فرآیند تا زمانی که شرط توقف برقرار شود، ادامه می‌یابد [۱٤، ۱۵].

پ. الگوریتم شبیه‌سازی تبرید[4] (SA): الگوریتم SA از فرآیند فیزیکی خنک‌سازی فلزات (آنیلینگ) الهام گرفته است. این الگوریتم با پذیرش احتمالی راه‌حل‌های بدتر در مراحل اولیه، از گیر افتادن در بهینه‌های محلی جلوگیری می‌کند. با گذشت زمان و کاهش دما، احتمال پذیرش راه‌حل‌های بدتر کاهش‌یافته و جستجو به سمت یک بهینه سراسری هدایت می‌شود. مراحل الگوریتم بدین صورت است:

۱) ایجاد راه‌حل اولیه: یک ترکیب آلیاژی به‌صورت تصادفی انتخاب می‌شود.
۲) ایجاد راه‌حل همسایه: در هر مرحله، یک راه‌حل همسایه در نزدیکی راه‌حل فعلی تولید می‌شود.
۳) ارزیابی و انتقال: برازندگی راه‌حل جدید ارزیابی می‌شود. اگر بهتر از راه‌حل فعلی بود، جایگزین آن می‌شود. در غیر این صورت، با یک احتمال مشخص که به دما بستگی دارد، ممکن است راه‌حل بدتر نیز پذیرفته شود.
٤) کاهش دما: با گذشت زمان، دما به‌تدریج کاهش می‌یابد و این فرآیند تکرار می‌شود تا دما به یک مقدار مشخص برسد [۱۲].

ت. الگوریتم زنبورعسل[5] (ABC): الگوریتم ABC بر اساس رفتار هوشمندانه جمعی زنبورهای عسل برای یافتن منابع غذایی استوار است. این الگوریتم از سه نوع زنبور (کارگر، تماشاچی و دیده‌بان) برای جستجو، بهره‌برداری و اکتشاف منابع غذایی (راه‌حل‌ها) استفاده می‌کند. مراحل الگوریتم به شرح زیر است:

۱) ایجاد جمعیت اولیه: یک مجموعه تصادفی از راه‌حل‌ها (موقعیت منابع غذایی) ایجاد می‌شود.
۲) زنبورهای کارگر: زنبورهای کارگر به جستجوی منابع غذایی جدید در نزدیکی منابع فعلی می‌پردازند.
۳) زنبورهای تماشاچی: زنبورهای تماشاچی با توجه به کیفیت منابع غذایی یافته شده توسط زنبورهای کارگر، یک منبع را انتخاب کرده و به جستجو در اطراف آن می‌پردازند.
٤) زنبورهای دیده‌بان: اگر یک منبع غذایی به مدت طولانی بهبود نیابد، زنبور کارگر مربوط به آن به یک زنبور دیده‌بان تبدیل‌شده و به جستجوی تصادفی یک منبع جدید می‌پردازد [۱٦، ۱۷].

[1] Crossover
[2] Mutation
[3] Particle Swarm Optimization (PSO)
[4] Simulated Annealing (SA)
[5] Artificial Bee Colony (ABC)

ث. الگوریتم کرم شب‌تاب[1] (FA): الگوریتم FA از رفتار کرم‌های شب‌تاب در طبیعت الهام می‌گیرد. این الگوریتم با فرض اینکه کرم‌های شب‌تاب به سمت کرم‌های درخشان‌تر جذب می‌شوند، راه‌حل‌ها را به سمت بهترین راه‌حل‌های موجود هدایت می‌کند. میزان درخشندگی هر کرم نشان‌دهنده کیفیت راه‌حل است. مراحل الگوریتم بدین صورت است:

۱) ایجاد جمعیت اولیه: یک مجموعه تصادفی از کرم‌های شب‌تاب در فضای جستجو ایجاد می‌شود.
۲) ارزیابی درخشندگی: درخشندگی هر کرم شب‌تاب بر اساس امتیاز برازندگی (استحکام فولاد) آن تعیین می‌شود.
۳) حرکت کرم‌ها: هر کرم شب‌تاب به سمت کرم شب‌تابی که درخشندگی بیشتری دارد، حرکت می‌کند.
٤) تکرار: این فرآیند تا رسیدن به شرایط توقف تکرار می‌شود و کرم‌ها به سمت درخشان‌ترین موقعیت‌ها همگرا می‌شوند [۱۸، ۱۹].

ج. الگوریتم جستجوی گرانشی[2] (GSA): این الگوریتم بر اساس قانون گرانش نیوتن عمل می‌کند. درGSA ، هر عامل جستجو به‌عنوان یک جرم در نظر گرفته می‌شود که راه‌حل‌های بهتر دارای جرم بیشتری هستند. این عوامل جستجو بر اساس نیروی گرانشی که به آن‌ها وارد می‌شود، به سمت راه‌حل‌های با جرم بیشتر (بهینه‌تر) جذب می‌شوند. مراحل الگوریتم بدین صورت است:

۱) ایجاد جمعیت اولیه: یک مجموعه از عوامل جستجو (اجرام) به‌صورت تصادفی در فضای جستجو توزیع می‌شود.
۲) ارزیابی جرم: جرم هر عامل جستجو بر اساس امتیاز برازندگی آن تعیین می‌شود (عامل با برازندگی بهتر، جرم بیشتری دارد).
۳) محاسبه نیرو: نیروهای گرانش بین عوامل جستجو محاسبه می‌شود.
٤) به‌روزرسانی موقعیت: موقعیت هر عامل جستجو بر اساس نیروی واردشده به آن تغییر می‌کند و به سمت عوامل با جرم بیشتر (راه‌حل‌های بهتر) کشیده می‌شود [۲۰، ۲۱].

ح. الگوریتم استعمار رقابتی[3] (ICA): این الگوریتم از فرآیند اجتماعی–سیاسی استعمار برای بهینه‌سازی الهام گرفته است. در این الگوریتم، راه‌حل‌ها به‌عنوان کشورها دسته‌بندی می‌شوند که بهترین آن‌ها امپریالیست‌ها و بقیه مستعمره‌ها هستند. مستعمره‌ها به سمت امپریالیست خود جذب‌شده و امپراتوری‌ها بر سر تصاحب مستعمرات یکدیگر رقابت می‌کنند. مراحل الگوریتم بدین صورت است:

۱) ایجاد جمعیت اولیه: یک مجموعه از کشورها (راه‌حل‌ها) به‌صورت تصادفی ایجاد می‌شود که بهترین آن‌ها به‌عنوان امپریالیست و بقیه به‌عنوان مستعمره انتخاب می‌شوند.
۲) جذب مستعمرات: مستعمرات هر امپراتوری به سمت امپریالیست خود جذب می‌شوند.
۳) رقابت امپریالیستی: امپراتوری‌ها بر سر تصاحب مستعمرات یکدیگر رقابت می‌کنند.
٤) حذف امپراتوری ضعیف: ضعیف‌ترین امپراتوری به‌تدریج از بین می‌رود و این فرآیند تا زمانی که یک امپراتوری قدرتمند باقی بماند، ادامه می‌یابد [۲۲، ۲۳].

خ. الگوریتم بهینه‌سازی گرگ خاکستری[4] (GWO): این الگوریتم، یک الگوریتم فراابتکاری جدید است که رفتار اجتماعی و سلسله‌مراتب گرگ‌های خاکستری در طبیعت را شبیه‌سازی می‌کند. در این الگوریتم، گرگ‌ها به سه دسته آلفا (رهبر)، بتا و دلتا (گرگ‌های راهنما) و امگا (سایر گرگ‌ها) تقسیم می‌شوند و فرآیند جستجو و شکار را به‌طور گروهی انجام می‌دهند. مراحل الگوریتم به‌صورت زیر است:

۱) ایجاد جمعیت اولیه: یک مجموعه از گرگ‌ها به‌صورت تصادفی در فضای جستجو ایجاد می‌شود.
۲) تعیین سلسله‌مراتب: بهترین سه راه‌حل به‌عنوان گرگ‌های آلفا، بتا و دلتا (رهبران) تعیین می‌شوند.
۳) شبیه‌سازی شکار: سایر گرگ‌ها (امگا) موقعیت خود را بر اساس موقعیت گرگ‌های آلفا، بتا و دلتا به‌روزرسانی می‌کنند.

[1] Firefly Algorithm (FA)
[2] Gravitational Search Algorithm (GSA)
[3] Imperialist Competitive Algorithm (ICA)
[4] Grey Wolf Optimizer (GWO)

٤) تکرار: این فرآیند تکرار می‌شود تا زمانی که همگرایی رخ دهد و بهترین موقعیت پیدا شود [٢٤، ٢٥].

د. الگوریتم کلونی مورچگان[1] (ACO): الگوریتم ACO از رفتار کلونی مورچه‌ها برای یافتن کوتاه‌ترین مسیر بین لانه و منبع غذا الهام گرفته است. مورچه‌ها با به‌جا گذاشتن ماده‌ای به نام فرومون[2] در مسیرهای طی‌شده، به یکدیگر در یافتن مسیرهای بهتر کمک می‌کنند. مراحل الگوریتم بدین صورت است:

١) ایجاد جمعیت اولیه: مجموعه‌ای از مورچه‌ها به‌صورت تصادفی در فضای جستجو توزیع می‌شوند.

٢) حرکت مورچه‌ها: مورچه‌ها بر اساس یک احتمال خاص، که تابعی از فاصله و مقدار فرومون در هر مسیر است، حرکت می‌کنند.

٣) به‌روزرسانی فرومون: پس از هر تکرار، مقدار فرومون در مسیرهای طی‌شده توسط مورچه‌ها به‌روزرسانی می‌شود (مسیرهای بهتر، فرومون بیشتری دریافت می‌کنند).

٤) تکرار: این فرآیند ادامه می‌یابد تا مورچه‌ها به سمت مسیر بهینه همگرا شوند [٢٦، ٢٧].

٤-٣ روش پیشنهادی ترکیبی و دومرحله‌ای

در این پژوهش یک چارچوب بهینه‌سازی ترکیبی و دومرحله‌ای (شکل (١)) برای غلبه بر ناکارآمدی روش‌های سنتی آزمون‌وخطا و رفع نقص مدل‌ها در پژوهش‌های پیشین طراحی‌شده است. نوآوری اصلی این رویکرد در ادغام قدرت مدل‌سازی دقیق جنگل تصادفی و قدرت جستجوی جامع الگوریتم‌های فرابتکاری دیده می‌شود .در مرحله اول، مدل رگرسیون جنگل تصادفی به‌عنوان یک تابع برازندگی دقیق و تفسیرپذیر به کار گرفته‌شده است .این مدل، جایگزین آزمایش‌های فیزیکی گران‌قیمت گردیده و یک فضای بهینه‌سازی دیجیتالی با دقت بالا ایجاد کرده است. این دقت بالا تضمین‌کننده آن است که مسیر جستجو برای الگوریتم‌های تکاملی به‌درستی هموار می‌شود. بدین ترتیب، مسئله پیچیده تولید فولاد، به یک مسئله قابل‌حل محاسباتی با کارایی بالا تبدیل‌شده است.

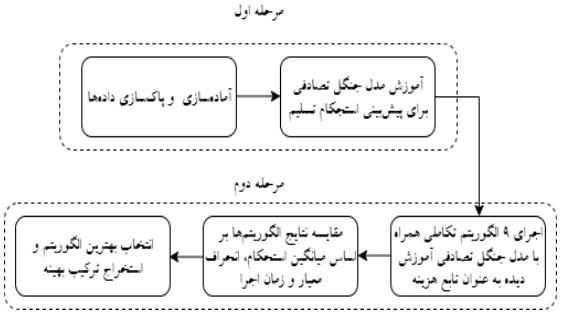

شکل (١): خلاصه‌ای از روش پیشنهادی ترکیبی و دومرحله‌ای

در مرحله دوم، نُه الگوریتم تکاملی مختلف که مکانیزم‌های جستجوی متنوعی را پوشش می‌دهند، به‌صورت موازی به کار گرفته‌شده‌اند .این مقایسه جامع با هدف تضمین پایداری آماری نتایج انجام‌شده است تا بهینه‌ترین ترکیب آلیاژی، بر اساس عملکرد قوی و تکرارپذیر یک الگوریتم (نه شانس) تعیین گردد .برای حفظ اعتبار نتایج، تمام الگوریتم‌ها تحت شرایط یکسان اجراشده‌اند؛ به این معنی که پارامترهای اصلی آن‌ها مانند اندازه جمعیت و تعداد تکرارها، برای تمامی الگوریتم‌ها به‌صورت یکسان در نظر گرفته‌شده است .علاوه بر این، دو قید اصلی در این فرآیند لحاظ شده است :اول اینکه محدوده مجاز (مینیمم و ماکسیمم) برای درصد وزنی هر آلیاژ به‌صورت جداگانه کنترل‌شده است تا اطمینان حاصل شود که راه‌حل‌های پیشنهادی از نظر فیزیکی قابل‌تولید هستند. دوم، قید حیاتی مجموع درصد وزنی عناصر که باید کمتر یا مساوی ١٠٠٪ باشد، نیز در هر مرحله از الگوریتم‌های تکاملی اعمال‌شده است .با این رویکرد، راه‌حل‌های تولیدی توسط الگوریتم‌ها به‌طور مداوم با محدودیت‌های فیزیکی انطباق داده‌شده‌اند تا درنهایت، راه‌حل‌های بهینه، کاملاً منطبق با واقعیت‌های مهندسی باشند. لازم به ذکر است، به دلیل ماهیت تصادفی در فرآیند تولید جمعیت اولیه و به‌روزرسانی مکان در الگوریتم‌های تکاملی، روش پیشنهادی ١٠ بار به‌صورت مستقل اجراشده است. این تکرار برای محاسبه میانگین و انحراف معیار نتایج نهایی انجام‌شده تا پایداری آماری روش در یافتن بهترین ترکیب آلیاژی تضمین گردد.

[1] Ant Colony Optimization (ACO)

[2] Pheromone

٤- نتایج

همان‌طور که در بخش قبل گفته شد، روش پیشنهادی شامل دو مرحله است. ابتدا مدل رگرسیون جنگل تصادفی با استفاده از پایگاه داده مورداستفاده آموزش داده‌شده است. در مرحله دوم این مدل به‌عنوان تابع برازندگی در نه الگوریتم تکاملی نام‌برده استفاده‌شده است. هدف الگوریتم‌ها دستیابی به جوابی با بالاترین مقدار تابع برازندگی یا همان استحکام فولاد است. برای پیاده‌سازی روش پیشنهادی و برای یکسان بودن شرایط، تعداد جمعیت، تعداد تکرار و جمعیت اولیه تصادفی یکسان برای شروع به کار تمام الگوریتم‌های تکاملی در نظر گرفته‌شده است. پارامترهای تنظیم‌شده بر اساس اعتبارسنجی متقابل برای هر الگوریتم تکاملی در جدول (۱) آورده شده است.

یکی از قیودی که برای هر جواب در هر الگوریتم تکاملی باید بررسی شود این است که مجموع درصد آلیاژها باید از عدد ۱۰۰ بیشتر نشود. لازم به ذکر است از میان نه الگوریتم تکاملی نام‌برده، تنها الگوریتم تکاملی SA مبتنی بر جمعیت نیست و فقط با یک جواب تصادفی مراحل الگوریتم خود را انجام می‌دهد. لازم به ذکر است، کدنویسی تمام بخش‌های روش پیشنهادی در محیط برنامه‌نویسی پایتون انجام‌شده است. برای پیاده‌سازی مدل رگرسیون جنگل تصادفی از کتابخانه Scikit-learn و برای مدیریت و تجزیه‌وتحلیل داده‌ها از کتابخانه‌های Pandas و NumPy استفاده‌شده است. روش پیشنهادی، در محیط Colab و با T4 GPU اجراشده است. نمودار همگرایی حاصل از اجرای یک‌بار و بهترین حالت تمام الگوریتم‌ها در شکل (۲) آورده شده است. برای اطمینان از پایداری آماری و قابلیت اتکا به نتایج بهینه‌سازی، و با توجه به ماهیت تصادفی در فرآیند تولید جمعیت اولیه در الگوریتم‌های تکاملی، روش پیشنهادی ۱۰ بار اجراشده است. خلاصه‌ای از عملکرد نُه الگوریتم را بر اساس میانگین و انحراف معیار به‌دست‌آمده از ۱۰ اجرای مستقل در جدول (۲) آورده شده است. این جدول اثبات می‌کند که نتایج نهایی به یک نقطه تصادفی وابسته نبوده و در شرایط تکرارپذیری، همچنان برتری خود را حفظ می‌کنند.

با توجه به نتایج آماری موجود در شکل (۱) و جدول (۲)، می‌توان عملکرد الگوریتم‌ها را بر اساس مکانیسم جستجو و توانایی آن‌ها در حفظ تعادل میان اکتشاف[1] و استثمار[2] تحلیل کرد.

اکثریت الگوریتم‌های مورداستفاده که از نوع جمعیت‌محور هستند، توانستند با موفقیت چندین راه‌حل کاندید را به‌طور هم‌زمان در فضای جستجو بررسی کنند. این ویژگی ذاتی باعث شد که آن‌ها فضای راه‌حل را به‌طور گسترده‌تری جستجو کرده و با حفظ تنوع در جمعیت، از گیر افتادن در بهینه‌های محلی جلوگیری کنند. این مکانیسم‌ها باعث شدند که میانگین عملکرد هفت الگوریتم برتر در بازه بسیار کوچک همگرا شوند .الگوریتم ازدحام ذرات به دلیل توانایی بالا در استثمار (هدایت ذرات به سمت بهترین تجربه فردی و گروهی) در کنار اکتشاف کنترل‌شده، با کسب بالاترین میانگین استحکام تسلیم و کمترین انحراف معیار، از نظر پایداری آماری و قابلیت اتکا به‌عنوان بهترین گزینه مطرح می‌شود. الگوریتم‌های گرگ خاکستری و رقابت استعماری نیز با تکیه بر مکانیسم‌های رهبری قوی (گرگ‌های آلفا و امپریالیست‌ها) توانستند تعادل مشابهی برقرار کرده و نتایجی بسیار نزدیک به PSO کسب کنند.

در مقابل، عملکرد الگوریتم شبیه‌سازی تبرید کاملاً متفاوت از بقیه الگوریتم‌ها بود. این الگوریتم یک روش تک‌نقطه‌ای است که جستجوی خود را تنها بر اساس یک راه‌حل در هر لحظه انجام می‌دهد. اگرچه SA بسیار سریع اجرا شد، اما با میانگین ۱۷۷۷/۱۳۶۰ مگاپاسکال و انحراف معیار بسیار بالا، نتوانست به راه‌حل بهینه‌ای دست یابد. چرایی این شکست را باید در مکانیسم‌های داخلی آن جستجو کرد:

[1] Exploration

[2] Explotation

جدول (۱): پارامترهای الگوریتم‌های تکاملی

نام الگوریتم	پارامتر	مقدار
الگوریتم ژنتیک	اندازه جمعیت	۵۰
	تعداد نسل‌ها	۲۰۰
	نرخ تقاطع	۰/۸
	نرخ جهش	۰,۱
الگوریتم ازدحام ذرات	تعداد ذرات	۵۰
	تعداد تکرارها	۲۰۰
	ضریب شناختی (c1)	۱/۵
	ضریب اجتماعی (c2)	۱/۵
	ضریب اینرسی (w)	۰/۹ – ۰/٤
الگوریتم شبیه‌سازی تبرید	تعداد تکرارها	۲۰۰
	دمای اولیه	۱۰۰۰
	ترخ سرد شدن	۰/۹۹
الگوریتم زنبورعسل	تعداد منابع غذایی (جمعیت)	۵۰
	تعداد تکرارها	۲۰۰
	تعداد تلاش‌های ناموفق زنبورها برای بهبود یک منبع غذایی	۱۰
الگوریتم کرم شب‌تاب	تعداد کرم‌های شب‌تاب	۵۰
	تعداد نسل‌ها	۲۰۰
	ضریب جذب (β0)	۱
	ضریب آلفا (α)	۰/۵
	ضریب گاما (γ)	۰/۱
الگوریتم جستجوی گرانشی	تعداد عوامل جستجو	۵۰
	تعداد تکرارها	۲۰۰
	ثابت گرانشی اولیه (G0)	۱۰۰
	ضریب آلفا	۲۰
الگوریتم بهینه‌سازی گرگ خاکستری	تعداد گرگ‌ها	۵۰
	تعداد تکرارها	۲۰۰
الگوریتم استعمار رقابتی	تعداد کشورها	۵۰
	تعداد تکرارها	۲۰۰
	تعداد امپریالیست‌ها	۵
	نرخ انقلاب	۰/۳
	نرخ جذب	۱/۵
الگوریتم کلونی مورچگان	تعداد مورچه‌ها	۵۰
	تعداد تکرارها	۲۰۰
	ضریب تأثیر فرومون (α)	۱
	ضریب تأثیر فاصله (β)	۲
	نرخ تبخیر	۰/۵

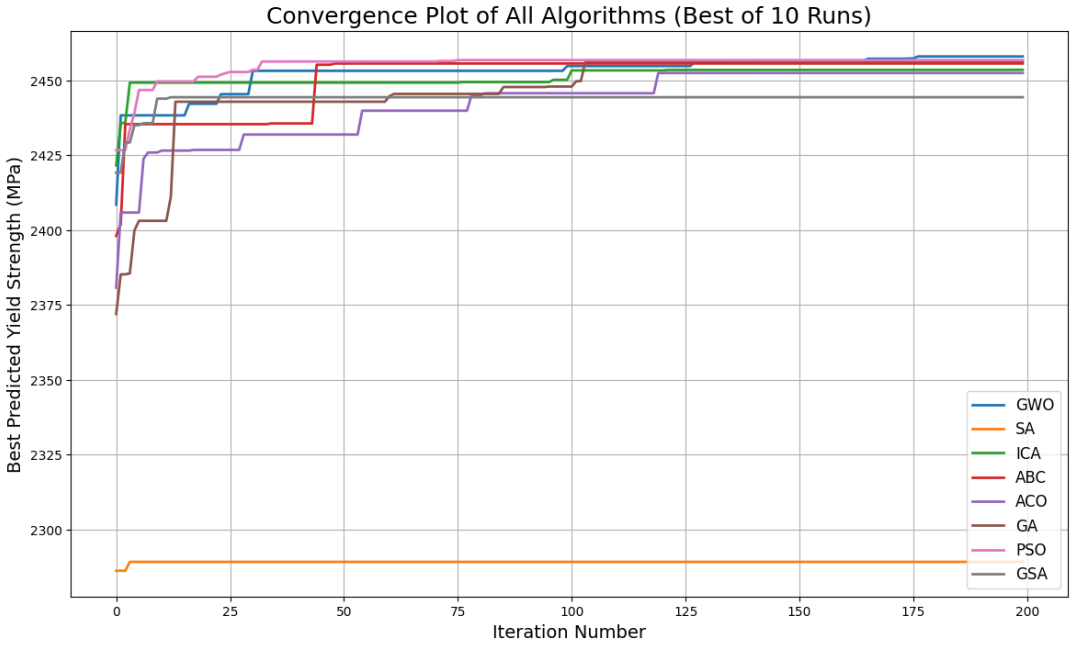

شکل (۲): نمودار همگرایی حاصل از نه الگوریتم تکاملی

جدول (۲): نتایج حاصل از عملکرد نُه الگوریتم بر اساس میانگین و انحراف معیار به‌دست‌آمده از ۱۰ اجرای مستقل

نام الگوریتم	میانگین استحکام تسلیم	انحراف معیار	زمان اجرا (برحسب ثانیه)
الگوریتم استعمار رقابتی	۲٤٥۲/۲۷۲۰	۱/٦٤۲٥	۱٤۳/٦۸۲۷
الگوریتم ازدحام ذرات	۲٤٥٥/٦۷۳۷	۱/۲۷۱٤	۱۱۳/۱۹۳۷
الگوریتم بهینه‌سازی گرگ خاکستری	۲٤٥٥/۲٥۰۳	۱/۹۲٥۹	۱۱٤/۸۱٦٥
الگوریتم زنبورعسل	۲٤٥۲/۲۳٦۷	٤/۰۳۹۸	۲۳۲/۲۰٦۰
الگوریتم کلونی مورچگان	۲٤٥۱/۷۳٤۷	۰/۹۷۲۹	۱۱۲/۳۲٦۳
الگوریتم جستجوی گرانشی	۲٤۳۷/۱۸٦۳	٥/۲۰۷۰	۱۱۷/٦۰۹۳
الگوریتم ژنتیک	۲٤٤٥/۲۱٤۷	۹/۰٤۷۲	۱۱۱/٦۲٦۸
الگوریتم کرم شب‌تاب	۲٤۳۲/٥٥۳۷	٦/۲۱۳٤	۲۲٦۰/۹۸۳۲
الگوریتم شبیه‌سازی تبرید	۱۷۷۷/۱۳٦۰	۳٦۷/۹۹۸۲	۲/٤۱۸۲

- جستجوی همسایگی ضعیف: SA در هر تکرار، تنها یک راه‌حل را در فضای همسایگی راه‌حل فعلی تولید می‌کند. در یک فضای جستجوی بزرگ و پیچیده (مانند مسئله جاری با ۱٤ متغیر)، جستجوی نقطه‌ای SA نمی‌تواند کل فضا را پوشش دهد و به سرعت در یک دره محلی کوچک گیر می‌افتد.
- تابع پذیرش و کاهش دما SA : از طریق تابع پذیرش، در دماهای بالا احتمال پذیرش راه‌حل‌های بدتر را برای خروج از بهینه‌های محلی حفظ می‌کند (اکتشاف). بااین‌حال، با کاهش سریع دما، احتمال پذیرش راه‌حل‌های بدتر تقریباً به صفر می‌رسد (تغییر به سمت استثمار). با توجه به سرعت بسیار بالای اجرای SA، می‌توان نتیجه گرفت که نرخ کاهش دما بسیار تند بوده است. این امر باعث شده که SA قابلیت اکتشاف خود را قبل از یافتن منطقه بهینه سراسری از دست داده و در یک بهینه محلی ضعیف تثبیت شود.

عملکرد الگوریتم کرم شب‌تاب (FA) نیز به دلیل داشتن ساختار پیچیده همراه با حلقه‌های تکرار تودرتو (محاسبه فاصله بین تمامی

عوامل در هر تکرار)، با صرف بالاترین زمان اجرا ناکارآمدترین الگوریتم در این مسئله بود. از سوی دیگر، مکانیسم جذابیت FA در فضاهای جستجوی ناهموار ممکن است باعث شود که عوامل به سرعت در اطراف راه‌حل‌های ضعیف ولی روشن محلی تجمع کنند و قادر به فرار نباشند، که این امر دلیل اصلی مقدار استحکام نسبتاً پایین به‌دست‌آمده توسط این الگوریتم است.

درنهایت، مقایسه نتایج نشان می‌دهد که هر الگوریتم بر اساس ساختار و روش جستجوی خود، عملکرد متفاوتی داشته است که این تفاوت‌ها کاملاً منطقی و مطابق با اصول علمی این الگوریتم‌ها هستند. این داده‌ها به‌خوبی نشان می‌دهند که برای این مسئله بهینه‌سازی، الگوریتم‌ها PSO،GWO و ICA مؤثرترین ابزار بوده‌اند و توانستند درصد آلیاژها را با زمان منطقی و خیلی سریع‌تر از روش‌های معمولی و سنتی آزمون‌وخطا به دست آورند. جدول (۳) درصد بهترین آلیاژهای به‌دست‌آمده برای تولید فولاد با بالاترین استحکام توسط نه الگوریتم تکاملی مورد بررسی طی ۱۰ بار اجرا را نشان داده است.

نتایج حاصل از الگوریتم‌های تکاملی، به‌ویژه نتایج مربوط به ترکیبات شیمیایی سه الگوریتم برتر PSO، GWO و ICA شباهت قابل‌توجهی را نشان می‌دهند. این همگرایی قوی به یک ناحیه بهینه در فضای جستجو، اطمینان می‌دهد که ترکیبات حاصله نزدیک‌ترین راه‌حل‌های ممکن برای مسئله تولید فولاد با حداکثر استحکام تسلیم هستند.

با توجه به داده‌های جدول (۳) که بهترین عملکرد تک‌نقطه‌ای هر الگوریتم را طی ۱۰ اجرای مستقل نشان می‌دهد، می‌توان دریافت که الگوریتم ازدحام ذرات با کسب بالاترین استحکام تسلیم برترین ترکیب بهینه را کشف کرده است. این برتری نه تنها از نظر عددی، بلکه از نظر عملکرد آماری (که در جدول ۲ نشان داده‌شده) نیز برتری PSO را در این مسئله اثبات می‌کند. تحلیل مفصل ترکیب بهینه PSO بینش‌های کلیدی زیر را در خصوص طراحی آلیاژهای فولادی با استحکام بالا فراهم می‌سازد:

کبالت (Co): درصد کبالت در ترکیب بهینه PSO به‌صورت چشم‌گیری بالا و معادل ٪۱۱/۹۵ است. کبالت با تثبیت فاز آستنیت، درنهایت به تشکیل ریزساختار مارتنزیتی با پایداری بالاتر کمک می‌کند. حضور این عنصر در آلیاژ، به‌طور مستقیم با مقاومت در برابر نرم‌شدگی و افزایش سختی در دماهای بالا مرتبط است و یکی از محرک‌های اصلی رسیدن به استحکام تسلیم بسیار بالا در این ترکیب است.

تنگستن (W) و مولیبدن (Mo) :این دو عنصر که جزء کاربیدسازهای قوی هستند، درمجموع سهم قابل‌توجهی دارند (تنگستن ٪۵/۷۴ و مولیبدن ٪۳/۷۱). مولیبدن و تنگستن به دلیل تشکیل کاربیدهای پیچیده و ریز و هم‌چنین سفت کردن فاز زمینه‌ای نقش حیاتی در افزایش مقاومت خزشی و استحکام فولاد دارند و در این راه‌حل بهینه به‌خوبی ترکیب شده‌اند.

کروم (Cr) : درصد کروم نیز قابل‌توجه و معادل ٪۷/۳۱ است. کروم علاوه بر افزایش سختی‌پذیری، مقاومت به خوردگی را نیز بهبود می‌بخشد، اما در این ترکیب، عملکرد اصلی آن در کنار مولیبدن، به تشکیل فازهای تقویت‌کننده و تأمین تعادل بین سختی و انعطاف‌پذیری بازمی‌گردد.

نیکل (Ni) : مهم‌ترین و جالب‌ترین یافته در این پژوهش، درصد بسیار پایین نیکل در راه‌حل بهینه PSO است که تنها ٪۱/۴۶ را شامل می‌شود. در متالورژی سنتی، نیکل برای افزایش سختی‌پذیری، بهبود چقرمگی و حفظ فاز آستنیت در دماهای پایین به مقادیر بالا افزوده می‌شود. بااین‌حال، الگوریتم PSO نشان داده است که با بهینه‌سازی دقیق سهم سایر عناصر به‌ویژه کبالت و تنگستن می‌توان بدون اتکا به مقادیر بالای نیکل، به حداکثر استحکام تسلیم دست‌یافت. این یافته یک بینش اقتصادی و علمی بسیار مهم برای طراحی آلیاژهای با عملکرد بالا و کاهش هزینه‌های مرتبط با نیکل است.

عناصر با درصد نزدیک به صفر (کربن و نیوبیوم)

کربن (C) و نیوبیوم (Nb) در راه‌حل بهینه PSO، درصد بسیار پایین دارند. این یک نکته بسیار جالب است، زیرا کربن عنصر اصلی کاربیدساز در فولادها است. یافته الگوریتم نشان می‌دهد که برای دستیابی به حداکثر استحکام تسلیم در این سیستم آلیاژی خاص، اتکا به کاربیدسازی عناصر سنگین‌تر مانند تنگستن، مولیبدن و کروم کافی بوده است و نیاز به کربن یا افزودنی‌های گران‌قیمتی مانند نیوبیوم که ریزدانه‌کننده است، نیست.

عنصر پایه (آهن)

آهن (Fe): درصد آهن در ترکیب برتر ٪۶۳/۱۸ است. این مقدار به‌عنوان پایه آلیاژ عمل می‌کند و نشان می‌دهد که برای دستیابی به این سطوح از استحکام، آلیاژ بهینه نیازمند درصد قابل‌توجهی (بیش از یک‌سوم) از عناصر آلیاژی دیگر است تا بتواند به خواص مکانیکی موردنظر دست یابد.

نتایج بهینه‌سازی به‌وضوح نشان می‌دهد که برای دستیابی به حداکثر استحکام تسلیم، ترکیب بهینه فولاد باید دارای درصد بالایی از عناصر کبالت، تنگستن و کروم باشد و یافته کلیدی این پژوهش، قابلیت دستیابی به این استحکام با درصد بسیار پایین نیکل و کربن است. این بینش یک نقشه راه عملی و حیاتی برای مهندسان متالورژی در طراحی آلیاژهای فولادی با استحکام بالا فراهم می‌کند.

جدول (۳): بهترین درصد آلیاژهای به‌دست‌آمده برای تولید فولاد با بالاترین استحکام توسط نه الگوریتم تکاملی طی ۱۰ بار اجرا

نام الگوریتم	بهترین استحکام تسلیم (MPa)	C (%)	Mn (%)	Si (%)	Cr (%)	Ni (%)	Mo (%)	V (%)	N (%)	Nb (%)	Co (%)	W (%)	Al (%)	Ti (%)	Fe (%)
ICA	۲۴۵۵/۶۱۹۰	۰/۱۶۲	۱/۰۲۱	۰/۶۸	۲/۶۱	۹/۷۸	۲/۸۶	۰/۰۵۱	۰/۰۴۴	۰/۰۰	۱۴/۰۹	۴/۸۷	۱/۰۴	۰/۷۷	۶۲/۰۰
PSO	۲۴۵۷/۹۷۴۰	۰/۰۰۲	۱/۴۵	۱/۷۱	۷/۳۱	۱/۴۶	۳/۷۱	۱/۳۹	۰/۰۱۳	۰/۰۰	۱۱/۹۵	۵/۷۴	۰/۵۸	۱/۴۹	۶۳/۱۸
GWO	۲۴۵۶/۷۵۵۰	۰/۰۰۳	۱/۵۹	۰/۵۸	۵/۲۹	۴/۳۷	۳/۹۵	۲/۵۵	۰/۰۰	۰/۷۶	۱۲/۰۲	۳/۷۷	۰/۶۴	۱/۴۸	۶۲/۰۰
ABC	۲۴۵۳/۵۰	۰/۰۰۳	۰/۰۴۳	۰/۲۷	۷/۴۱	۲/۸۴	۴/۶۲	۱/۸۹	۰/۱۴	۱/۲۲	۱۲/۲۱	۳/۷۷	۰/۶۵	۱/۴۸	۶۳/۴۴
ACO	۲۴۵۲/۴۴۳۰	۰/۰۰۰۹	۱/۶۸	۲/۷۱	۳/۱۶	۱۰/۳۷	۴/۹۹	۰/۹۵	۰/۰۷۹	۰/۲۷	۱۱/۲۵	۰/۵۱	۰/۵۴	۱/۴۸	۶۲/۰۰
GSA	۲۴۴۴/۳۵۳۰	۰/۰۰	۰/۲۶	۳/۱۴	۱/۱۴	۰/۰۱۰۰	۵/۲۲	۱/۹۵	۰/۱۰۳۲	۲/۵۰	۱۲/۳۲	۳/۳۹	۱/۸۰	۱/۴۵	۶۲/۷۷
GA	۲۴۴۵/۲۱۴۷	۰/۰۰۱۰	۰/۴۱	۱/۰۴	۱۰/۷۹	۱۰/۳۳	۱/۱۹	۰/۰۱۶۲	۰/۰۱۶	۱/۲۱	۹/۳۰	۱/۲۷	۰/۳۷	۱/۴۸	۶۲/۹۳
FA	۲۴۳۹/۱۰۶۰	۰/۴۳	۱/۸۵	۲/۴۷	۱۱/۲۳	۲/۴۱	۲/۵۶	۲/۰۵	۰/۱۵	۰/۶۳	۱۱/۴۱	۰/۸۱	۰/۵۲	۱/۴۸	۶۲/۰۰
SA	۲۲۸۹/۲۰۸۰	۰/۰۷۷	۰/۷۹	۱/۰۴	۱/۸۳	۱۱/۰۸	۷/۲۴	۱/۸۸	۰/۰۳۵	۱/۴۹	۶/۳۳	۴/۲۶	۰/۴۵	۱/۵۰	۶۲/۰۰

۵- نتیجه‌گیری

پژوهش حاضر با هدف بهینه‌سازی ترکیب آلیاژها برای دستیابی به حداکثر استحکام تسلیم در فولاد، به یکی از مسائل حیاتی در صنعت متالورژی پرداخته و یک رویکرد نوین ترکیبی شامل یک مدل پیش‌بینی‌کننده رگرسیون جنگل تصادفی و نه الگوریتم تکاملی مختلف را به کار گرفته است. نتایج به‌دست‌آمده به‌وضوح نشان داد که الگوریتم ازدحام ذرات (PSO) با کسب بالاترین استحکام تسلیم معادل ۲۴۵۷/۹۷۴۰ مگاپاسکال، بهترین عملکرد را در یافتن بهینه‌ترین ترکیب آلیاژی داشت و الگوریتم‌های گرگ خاکستری (GWO) و رقابت استعماری(ICA) نیز عملکرد بسیار نزدیکی از خود نشان دادند. تحلیل ترکیب بهینه پیشنهادی نشان داد که حداکثر استحکام تسلیم با درصد بالایی از عناصر کبالت، کروم و تنگستن به دست می‌آید؛ درحالی‌که یافته کلیدی این پژوهش، قابلیت دستیابی به این استحکام با وجود درصد بسیار پایین نیکل و کربن است. از محدودیت‌های پژوهش جاری می‌توان به تمرکز صرف بر بهینه‌سازی تک‌هدفه (حداکثرسازی استحکام تسلیم) اشاره کرد و این امر منجر به نادیده گرفتن هم‌زمان سایر خواص مکانیکی حیاتی (مانند چقرمگی و شکل‌پذیری)، ملاحظات اقتصادی ترکیب پیشنهادی (به دلیل درصد بالای عناصر گران‌قیمت) و عدم‌تأیید تجربی نتایج شده است. لذا برای پژوهش‌های آینده، قویاً پیشنهاد می‌شود که از رویکرد بهینه‌سازی چندهدفه برای لحاظ کردن هم‌زمان استحکام، هزینه و خواص ثانویه استفاده گردد و در گام بعدی، ساخت و آزمایش فیزیکی ترکیب بهینه پیشنهادی برای راستی‌آزمایی اعتبار نهایی مدل صورت پذیرد.

References

[1] W. D. Callister Jr, and D. G. Rethwisch, "Materials science and engineering: an introduction," John wiley & sons, 2020.

[2] Z. Hassani, and M. Khosravi, "Diagnosis of coronary heart disease using hybrid intelligent systems based on whale optimization algorithm, simulated annealing and support vector machine," Engineering Management and Soft Computing, 6(2), 167–181, 2020.

[3] Z. Zhu, Y. Liang, and J. Zou, "Modeling and composition design of low-alloy steel's mechanical properties based on neural networks and genetic algorithms," Materials, Vol. 13, No. 23, p. 5316, 2020.

[4] C. Liu, X. Wang, W. Cai, J. Yang, and H. Su, "Optimal design of the austenitic stainless-steel composition based on machine learning and genetic algorithm," Materials, Vol. 16, No. 16, p. 5633., 2023.

[5] G. S. Dulikravich, and I. N. Egorov-Yegorov, "Robust optimization of concentrations of alloying elements in steel for maximum temperature, strength, time-to-rupture and minimum cost and weight," ECCOMAS–Computational Methods for Coupled Problems in Science and Engineering, pp. 25-28, 2005.

[6] M. Liu, P. Yan, P. Liu, J. Qiao, and Z. Yang,. "An improved particle-swarm-optimization algorithm for a prediction model of steel slab temperature," Applied Sciences, Vol. 12, No. 22, p. 11550, 2022.

[7] O. Babachenko, H. Kononenko, I. Snigura, and N. Togobytska, "Optimisation of chemical composition of high-strength structural steels for achieving mechanical property requirements," 2021.

[8] H. Lu, S. Behbahani, X. Ma, and T. Iseley, "A multi-objective optimizer-based model for predicting composite material properties," Construction and Building Materials, Vol. 284, p. 122746, 2021.

[9] Z. Che, C. Peng, "Improving support vector regression for predicting mechanical properties in low-alloy steel and comparative analysis," Mathematics, Vol. 12, No. 8, p. 1153, 2024.

[10] R. Tapio, "Comparative Analysis of Multiple Linear Regression and Random Forest Regression in Predicting Academic Performance of Students in Higher Education," Asian Research Journal of Mathematics, Vol. 21, No. 4, pp. 170-181, 2025.

[11] J. Z. Ahmadabadi, F. Z. Mehrjardi, M. Ghanbary, and M. Mirzaei, "Identification of Effective Factors and Prediction of Ischemic Heart Disease Using Machine Learning Methods and Data from the Yazd Health Study (YaHS)," Journal of Shahid Sadoughi University of Medical Sciences, Vol. 32, No. 7, pp. 8067-8079, 2024.

[12] F. Z. Mehrjardi, and A. M. Latif, "Detection of copy-move forgery in digital images using genetic algorithm and simulating annealing algorithm, "Vol. 2, No. 2, pp. 1-16, 2025.

[13] F. Z. Mehrjardi, A. M. Latif, and M. Sardari Zarchi, "An Optimal Hybrid Method to Detect Copy-move Forgery," Journal of AI and Data Mining, Vol. 11, No. 3, pp. 429-442, 2023.

[14] J. Kennedy, and R. Eberhart, "Particle swarm optimization," In Proceedings of ICNN'95-international conference on neural networks, Vol. 4, pp. 1942-1948, 1995.

[15] L. Abualigah, A. Sheikhan, A. M. Ikotun, R. A. Zitar, A. R. Alsoud, I. Al-Shourbaji, and H. Jia, "Particle swarm optimization algorithm: review and applications," Metaheuristic optimization algorithms, p. 1-14, 2024.

[16] D. Karaboga, "An idea based on honey bee swarm for numerical optimization," pp. 1-10, 2005.

[17] E. Tokgoz, "Artificial bee colony optimization techniques' utilization for intrusion detection systems' analysis," In 2025 IEEE 4th International Conference on AI in Cybersecurity (ICAIC), p. 1-16, 2025.

[18] N. F. Johari, A. M. Zain, M. H. Noorfa, and A. Udin, "Firefly algorithm for optimization problem," Applied Mechanics and Materials, Vol. 421, pp. 512-517, 2013.

[19] T. L. Le, "Firefly Algorithm-based Optimization of Control Parameters in DC Conversion Systems. Engineering," Technology & Applied Science Research, Vol. 15, No. 2, p. 20588-20594, 2025.

[20] E. Rashedi, H. Nezamabadi-Pour, and S. Saryazdi, "GSA: a gravitational search algorithm," Information sciences, Vol. 179, No. 13, pp. 2232-2248, 2009.

[21] I. T. Abbas, E. M. Abd, and M. J. A. Mohsen, "Using Gravitational Search Algorithm for Solving Nonlinear Regression Analysis," Iraqi Journal of Science, 2025.

[22] E. Atashpaz-Gargari, and C. Lucas, "Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic

competition," In 2007 IEEE congress on evolutionary computation, pp. 4661-4667, 2007.
[23] K. Shirini, H. S. Aghdasi, and S. Saeedvand, "Modified imperialist competitive algorithm for aircraft landing scheduling problem," Journal of Supercomputing, Vol. 80, No. 10, 2024.
[24] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey wolf optimizer," Advances in engineering software, Vol. 69, pp. 46-61, 2014.
[25] Y. Liu, A. As' arry, M. K. Hassan, A. A. Hairuddin, and H. Mohamad, "Review of the grey wolf optimization algorithm: variants and applications," Neural Computing and Applications, Vol. 36, No. 6, pp. 2713-2735, 2024.
[26] M. Dorigo, M. Birattari, and T. Stutzle, "Ant colony optimization," IEEE computational intelligence magazine, Vol. 1, No. 4, pp. 28-39, 2007.
[27] C. Blum, "Ant colony optimization: A bibliometric review," Physics of life reviews, Vol. 51, pp. 87-95, 2024.

Journal of Applied And Basic Machine Intelligence Research (ABMIR)

Applied and Basic Machine Intelligence Research

Vol. 4, No. 2, Autumn & Winter 2026, pp. 1 - 16

Optimization of Alloy Composition for High-Strength Steel Production Using Evolutionary Algorithms and Machine Learning (Optimization of the Steel Manufacturing Process)

Fatemeh Zare Mehrjardi [1*]

[1] Assistant Professor, Faculty of Engineering, Department of Computer Engineering, Meybod University, Meybod, Iran

Article Information

Original Research Paper

Received:
2025 August 22

Accepted:
2025 October 29

Keywords:
Steel production, Evolutionary algorithm, Machine learning, Imperialist Competitive Algorithm (ICA), Particle Swarm Optimization (PSO), Grey Wolf Optimizer (GWO)

Corresponding Author*:
fzare@meybod.ac.ir

Abstract

In this study, a novel approach is presented to solve the complex problem of optimizing the chemical composition of steel to achieve maximum yield strength. Due to the inefficiency of traditional trial-and-error methods, a hybrid, two-stage approach was employed. In the first stage, a machine learning model, namely Random Forest Regressor, was trained on a dataset of real steel compositions to serve as an accurate fitness function for predicting strength, and in the second stage, nine evolutionary and meta-heuristic algorithms were utilized to find the optimal alloy composition. These algorithms include Genetic Algorithm (GA), Particle Swarm Optimization (PSO), Simulated Annealing (SA), Artificial Bee Colony (ABC), Firefly Algorithm (FA), Gravitational Search Algorithm (GSA), Imperialist Competitive Algorithm (ICA), Grey Wolf Optimizer (GWO), and Ant Colony Optimization (ACO). The results showed that the Imperialist Competitive Algorithm (ICA) outperformed the other algorithms, achieving the best yield strength with a value of 2468.68 MPa. The Particle Swarm Optimization (PSO) and Grey Wolf Optimizer (GWO) algorithms also showed very close performance to the Imperialist Competitive Algorithm. In contrast, the Simulated Annealing (SA) algorithm, despite its high speed, converged to a sub-optimal solution, and the Firefly Algorithm (FA) was highly inefficient in terms of execution time. An analysis of the best-obtained compositions reveals that to maximize yield strength, the steel should contain a high percentage of Nickel (Ni) and Cobalt (Co), while the percentage of elements such as Carbon (C) and Vanadium (V) can be very low or close to zero. This approach provides an efficient solution for designing materials with desired properties without the need for extensive experimental testing.

: 10.22034/ABMIR.2025.23571.1158

E-ISSN: 2821-2037

/The Author 2026. Published by Yazd University This is an open access article under the CC BY 4.0 License https://creativecommons.org/licenses/by/4.0/).