

Research Article

Convergence of memetic Algorithms through Neural Network Integration

Mohammadreza Dehghani MahmoudAbadi ^{*1}  | Elham Dehghan Tezerjani ² 

¹Faculty of Computer Engineering,
University of Azad Islamic Bafgh, Bafgh,
Iran,
Mohammad347@gmail.com

²Faculty of Computer Engineering,
University of Azad Islamic Bafgh, Bafgh,
Iran,
Phdmrdma@gmail.com

Correspondence

***Mohammadreza Dehghani MahmoudAbadi**, Assistant professor,
Faculty of Computer Engineering,
University of Azad Islamic Bafgh, Bafgh,
Iran,
Mohammad347@gmail.com

Main: Memetic Algorithms

Received: 29 July 2025

Revised: 15 Agust 2025

Accepted: 18 Agust 2025

Abstract

Memetic algorithms have demonstrated strong potential in addressing computationally expensive optimization problems by combining population-based search with iterative objective function evaluations. Despite their effectiveness, a key limitation of conventional Memetic algorithms is their relatively slow convergence rate, which often requires a large number of generations to achieve optimal or near-optimal solutions. To mitigate this issue, this study introduces a novel hybrid framework that integrates neural networks into the memetic algorithm paradigm. In the proposed approach, the neural network functions as a guiding mechanism, dynamically steering the search process to accelerate convergence and enhance solution quality. The algorithm's performance was systematically evaluated on a diverse set of benchmark optimization problems. Experimental results reveal that the hybrid method significantly improves convergence speed while achieving up to an 88% increase in solution quality compared to baseline Memetic algorithms. These findings underscore the capability of the proposed hybrid algorithm to substantially enhance both the efficiency and effectiveness of memetic algorithms. Furthermore, the approach demonstrates strong generalization ability, suggesting its applicability to a wide range of real-world optimization domains.

<https://doi.org/10.82195/NTDS.2025.1213478>

Keywords: Memetic Algorithm, Neural Network, Optimization, Hybrid, Evaluation.

پژوهشی

همگرایی الگوریتم های ممیک از طریق یکپارچه سازی شبکه عصبی

محمد رضا دهقانی محمودآبادی^{*۱} | الهام دهقان طرزجانی^۲ 

چکیده:

این پژوهش به تحلیل و بهبود الگوریتم های ممیک در حل مسائل بهینه سازی پیچیده می پردازد. الگوریتم های ممیک باتکیه بر جستجوی مبتنی بر جمعیت و ارزیابی مکرر تابع هدف در شرایطی که محاسبه تابع هدف پرهزینه باشد، عملکرد مناسبی دارند. یکی از چالش های اصلی آن ها نرخ پایین همگرایی و نیاز به تعداد نسل های متعدد برای دستیابی به پاسخ بهینه است. به منظور رفع این محدودیت، در این مطالعه یک الگوریتم ترکیبی مبتنی بر تلفیق شبکه عصبی و چارچوب ممیک ارائه شده است. در این روش شبکه عصبی نقش هدایت کننده فرایند جستجو را ایفا کرده و با بهبود دینامیک همگرایی سرعت رسیدن به پاسخ بهینه را افزایش می دهد. کارایی الگوریتم پیشنهادی با مجموعه ای از آزمون های معیار مورد ارزیابی قرار گرفته و نتایج نشان می دهد که سرعت همگرایی به طور چشمگیر افزایش یافته و کیفیت پاسخ ها تا ۸۸٪ بهبود یافته است. این یافته ها تأیید می کنند که الگوریتم ترکیبی نه تنها عملکرد الگوریتم ممیک را به طور قابل توجهی ارتقا می دهد، بلکه قابلیت تعمیم و کاربرد آن در طیف وسیعی از مسائل بهینه سازی را فراهم می آورد.

^۱ گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، بافق، ایران،

Mohammad347@gmail.com

^۲ گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، بافق، ایران،

phdmrdma@gmail.com

نویسنده مسئول

* محمد رضا دهقانی محمودآبادی، استادیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، بافق، ایران،
Mohammad347@gmail.com

عنوان اصلی: الگوریتم های ممیک

تاریخ دریافت: ۷ مرداد ۱۴۰۴

تاریخ بازنگری: ۲۴ مرداد ۱۴۰۴

تاریخ پذیرش: ۲۷ مرداد ۱۴۰۴

<https://doi.org/10.82195/NTDS.2025.1213478>

کلیدواژه ها: الگوریتم ممیک، شبکه عصبی، بهینه سازی، ترکیبی، ارزیابی.

۱-مقدمه

در سال‌های اخیر الگوریتم‌های ممیتیک به‌عنوان یکی از رویکردهای نوین و کارآمد در حل مسائل بهینه‌سازی پیچیده توجه گسترده‌ای را به خود جلب کرده‌اند. ویژگی بارز این الگوریتم‌ها عدم وابستگی به مشتقات تابع هدف است که امکان به‌کارگیری آن‌ها را در طیف وسیعی از مسائل بهینه‌سازی پیوسته و گسسته فراهم می‌سازد [۱]. علاوه بر این ماهیت تصادفی و توانایی کاهش احتمال گرفتار شدن در بهینه‌های محلی، جایگاه ویژه‌ای برای این الگوریتم‌ها در حوزه‌های علوم رایانه، مهندسی و بهینه‌سازی ایجاد کرده است. عملکرد مبتنی بر جمعیت و قابلیت ارزیابی مکرر تابع هدف این الگوریتم‌ها را به گزینه‌ای مناسب برای کاربردهایی تبدیل کرده است که محاسبه تابع هدف در آن‌ها مانند شبیه‌سازی‌های پیچیده و پردازش‌های سنگین در سیستم‌های مهندسی هزینه‌بر است [۲].

باوجود مزایای قابل توجه الگوریتم‌های ممیتیک در برخی شرایط با چالش‌هایی همچون نرخ همگرایی پایین و یکنواختی جمعیت مواجه می‌شوند؛ مسائلی که می‌توانند منجر به کاهش تنوع و محدود شدن احتمال دستیابی به راه‌حل‌های نوآورانه شوند به‌منظور رفع این محدودیت‌ها در سال‌های اخیر رویکردهای هیبریدی مبتنی بر ترکیب الگوریتم‌های ممیتیک و شبکه‌های عصبی موردتوجه پژوهشگران قرار گرفته است. شبکه‌های عصبی الهام‌گرفته از ساختار و عملکرد مغز انسان توانایی یادگیری روابط غیرخطی و پیچیده را از حجم بالایی از داده‌ها دارند و استفاده از آن‌ها می‌تواند به ارتقای فرایند یادگیری و جستجوی الگوریتم‌های تکاملی کمک کند [۳].

الگوریتم‌های ممیتیک که بر پایه اصول انتخاب طبیعی داروینی و جستجوی تصادفی بنا شده‌اند، فرایند بهینه‌سازی را با ایجاد جمعیتی از راه‌حل‌های اولیه تصادفی آغاز کرده و سپس با به‌روزرسانی تدریجی جمعیت به سمت یافتن راه‌حل‌های بهینه حرکت می‌کنند. هدف اصلی این الگوریتم‌ها بهره‌برداری از اطلاعات موجود در جمعیت برای انتخاب کارآمدترین افراد و تولید نسل‌های جدیدی از راه‌حل‌ها است. باوجود پیشرفت‌های متعدد در ساختار و عملکرد آن‌ها نسخه مورد استفاده در این پژوهش فرم ساده و کلاسیک از الگوریتم ممیتیک محسوب می‌شود که بر اصول بنیادین این رویکرد استوار است [۴].

در مقایسه با روش‌های سنتی بهینه‌سازی الگوریتم‌های ممیتیک مزایای مهمی از جمله توانایی جستجوی هم‌زمان چندین نقطه در فضای مسئله، مقابله با بهینه‌های محلی و قابلیت کار با ترکیب متغیرهای پیوسته و گسسته را دارند. این ویژگی‌ها امکان ارائه مجموعه‌ای از راه‌حل‌های قابل قبول را فراهم می‌کنند که به‌جای تمرکز بر یک پاسخ منفرد امکان انتخاب بهترین گزینه را از میان چندین راه‌حل فراهم می‌سازد. بااین حال یکی از چالش‌های رایج این الگوریتم‌ها کندی همگرایی در مراحل پایانی جستجو است؛ به‌ویژه هنگامی که ناحیه‌ای نزدیک به بهینه جهانی شناسایی شده باشد. بهره‌گیری از استراتژی‌های نخبه‌گرایانه نظیر حفظ و انتقال بهترین راه‌حل‌ها به نسل‌های بعدی می‌تواند کارایی همگرایی را به طور قابل توجهی بهبود بخشد [۵].

برای ارتقای بیشتر عملکرد الگوریتم ممیتیک، به‌ویژه در مرحله همگرایی نهایی، استفاده از شبکه‌های عصبی به‌عنوان مکمل پیشنهاد می‌شود. در این رویکرد شبکه‌های عصبی با یادگیری ویژگی‌های جمعیت و میزان شایستگی هر عضو مسیر جستجو را به سمت نواحی امیدبخش هدایت می‌کنند. این تلفیق نه تنها کیفیت راه‌حل‌های حاصل را بهبود می‌بخشد، بلکه بهره‌وری کلی فرایند بهینه‌سازی را نیز افزایش می‌دهد. در این پژوهش رویکرد ترکیبی نوآورانه بر پایه تلفیق الگوریتم ممیتیک و شبکه عصبی بازگشتی چندلایه ارائه شده است. الگوریتم پیشنهادی با بهره‌گیری از توانمندی‌های هر دو روش قادر است مسائل بهینه‌سازی پیچیده را با سرعت و دقت بالا حل کند. در این چارچوب از نسخه ساده‌ای از الگوریتم ممیتیک با رمزگذاری باینری استفاده از روش انتخاب چرخ رولت، ترکیب یکنواخت، جایگزینی نخبه‌گرا و جستجوی محلی بهره گرفته شده است که بنیان ساختار پیشنهادی را تشکیل می‌دهد [۶].

ساختار مقاله به‌صورت زیر سازمان‌دهی شده است: در بخش دوم مروری جامع بر الگوریتم‌های ممیتیک ارائه می‌شود؛ بخش سوم به‌مرور اجمالی شبکه‌های عصبی اختصاص دارد؛ در بخش چهارم، الگوریتم ترکیبی پیشنهادی تشریح می‌گردد؛ در بخش پنجم، نتایج آزمایش‌های تجربی و تحلیل آن‌ها ارائه می‌شود؛ و نهایتاً بخش ششم به جمع‌بندی یافته‌ها و نتیجه‌گیری اختصاص یافته است.

۲- الگوریتم های ممیتیک

الگوریتم های ممیتیک به عنوان یکی از رویکردهای پیشرفته در حوزه بهینه سازی با ترکیب سازوکارهای تکاملی نظیر تولیدمثل، ترکیب ژنتیکی و جهش توانایی قابل توجهی در کاوش کارآمد فضای جستجوی مسائل پیچیده دارند. این الگوریتم ها که بر پایه اصول انتخاب طبیعی داروینی و جستجوی تصادفی شکل گرفته اند، فرایند بهینه سازی را با ایجاد جمعیتی اولیه از راه حل های تصادفی آغاز کرده و با به روز رسانی تدریجی این جمعیت در طول نسل ها، به سوی دستیابی به راه حل های بهینه حرکت می کنند. هدف محوری در این رویکرد بهره برداری بهینه از اطلاعات موجود در جمعیت برای شناسایی کارآمدترین افراد و تولید نسل های جدیدی از راه حل ها است. نسخه مورد استفاده در این پژوهش نمونه ای ساده و کلاسیک از الگوریتم ممیتیک محسوب می شود که بر مبنای بنیادین این روش استوار است. در مقایسه با روش های سنتی بهینه سازی، الگوریتم های ممیتیک از مزایای متعددی از جمله قابلیت جستجوی هم زمان در چندین نقطه از فضای مسئله، مقاومت در برابر همگرایی زودهنگام به بهینه های محلی و توانایی کار با ترکیبی از متغیرهای پیوسته و گسسته برخوردار هستند. این ویژگی ها موجب می شود که الگوریتم، به جای تمرکز بر یک پاسخ منفرد، مجموعه ای از راه حل های مناسب را ارائه دهد و امکان انتخاب بهترین گزینه از میان آن ها فراهم گردد [۷]. با وجود این مزایا یکی از چالش های اساسی الگوریتم های ممیتیک، کاهش سرعت همگرایی در مراحل پایانی جستجو است، به ویژه زمانی که ناحیه ای نزدیک به بهینه جهانی شناسایی شده باشد. برای رفع مشکل استفاده از استراتژی های نخبه گرایانه همچون حفظ و انتقال بهترین راه حل ها به نسل های بعدی روشی مؤثر به شمار می رود. این استراتژی ها با تمرکز بر ساده ترین و کارآمدترین راه حل های موجود، موجب تسریع فرایند همگرایی و بهبود بهره وری کلی می شوند [۸].

برای ارتقای عملکرد به ویژه در مرحله همگرایی نهایی ترکیب الگوریتم ممیتیک با شبکه های عصبی به عنوان یک رویکرد مکمل پیشنهاد می شود. در این چارچوب شبکه های عصبی با یادگیری الگوهای موجود در جمعیت و ارزیابی شایستگی افراد فرایند جستجو را به سمت نواحی امیدبخش هدایت می کنند. این هم افزایی نه تنها کیفیت راه حل های حاصل را ارتقا می دهد، بلکه موجب افزایش سرعت و دقت فرایند بهینه سازی نیز می گردد [۹].

در این مطالعه رویکرد ترکیبی نوآورانه مبتنی بر تلفیق الگوریتم ممیتیک و شبکه عصبی بازگشتی چندلایه ارائه شده است. الگوریتم پیشنهادی با بهره گیری هم زمان از نقاط قوت هر دو روش قادر است مسائل بهینه سازی پیچیده را با کارایی بالاتری حل کند. در این ساختار از نسخه ای ساده از الگوریتم ممیتیک با رمزگذاری باینری، انتخاب به روش چرخ رولت، ترکیب یکنواخت، جایگزینی نخبه گرا و جستجوی محلی استفاده شده است که شالوده چارچوب پیشنهادی را تشکیل می دهد [۱۰].

۳- شبکه های عصبی

در حوزه علوم رایانه شبکه های عصبی مصنوعی به عنوان یکی از ابزارهای پیشرفته پردازش اطلاعات شناخته می شوند که الهام گرفته از ساختار سیستم عصبی زیستی به ویژه مغز انسان طراحی شده اند. این شبکه ها از مجموعه ای از نورون های مصنوعی متصل به یکدیگر تشکیل شده اند که در قالب لایه های مجزا سازماندهی می شوند. هر شبکه شامل یک لایه ورودی یک یا چندلایه پنهان و یک لایه خروجی است که داده های ورودی را به صورت سلسله مراتبی و در مسیر پیشرو پردازش می کند. در لایه های پنهان نورون ها باهدف شناسایی الگوها و روابط پیچیده موجود در داده ها فعال می شوند و تنها آن دسته از نورون هایی که قادر به ایجاد خروجی معنادار باشند در فرایند یادگیری مؤثر واقع می شوند [۲].

شبکه های عصبی در حل مسائل بهینه سازی از مکانیزم های یادگیری الهام گرفته از فرایندهای شناختی انسان بهره می برند. در این رویکرد وزن اتصالات سیناپسی میان نورون ها بر اساس تعامل ورودی ها و خروجی ها به روز رسانی شده و خروجی شبکه متناسب با ترکیب خاصی از ورودی ها شکل می گیرد. فرایند تنظیم این وزن ها از طریق الگوریتم های یادگیری انجام می شود و منجر به استخراج الگوهای فعال سازی بهینه خواهد شد [۱۱].

فرایند یادگیری در شبکه های عصبی به دودسته یادگیری نظارت شده و یادگیری بدون نظارت تقسیم می شود. در یادگیری نظارت شده خروجی هدف برای هر ورودی از پیش مشخص است و شبکه با کاهش اختلاف بین خروجی واقعی و خروجی مطلوب آموزش می بیند. در مقابل در یادگیری بدون نظارت شبکه بدون استفاده از برچسب های خروجی تلاش می کند الگوهای پنهان در داده ها را به صورت خودکار کشف کند [۱۲].

۶۱ همگرایی الگوریتم‌های ممیتیک از طریق یکپارچه‌سازی شبکه عصبی/محمدرضا دهقانی محمودآبادی- الهام دهقان طرزجانی

در این پژوهش باتوجه به در دسترس بودن خروجی‌های هدف حاصل از اجرای الگوریتم ممیتیک از روش یادگیری نظارت شده استفاده شده است. این انتخاب امکان تنظیم دقیق الگوهای فعال‌سازی شبکه را فراهم کرده و دقت پاسخ‌دهی آن را در مواجهه با داده‌های جدید افزایش می‌دهد [۱۳].

ساختار مورد استفاده در این مطالعه، یک شبکه عصبی پیش‌خور سه‌لایه با انتقال اطلاعات یک‌سویه از لایه ورودی به لایه خروجی است که کارایی بالایی در تسریع همگرایی الگوریتم ممیتیک از خود نشان داده است.




Figure 1: Basic Neural Network Structure

شکل ۱: ساختار شبکه عصبی پایه

در چارچوب این شبکه هر نورون در لایه پنهان سیگنال خالص ورودی خود را با مجموع وزن‌دار داده‌های دریافتی محاسبه می‌کند و سپس خروجی آن با تابع فعال‌سازی غیرخطی مشخص می‌شود. به صورت ریاضی ورودی خالص نورون j در لایه پنهان به صورت فرمول ۱ تعریف می‌شود:

$$S_j = \sum_{i=1}^R w_{ji} p_i \quad (1)$$

که در آن w_{ji} وزن بین نورون i از لایه ورودی و نورون j از لایه پنهان، و p_i مقدار ورودی است. سپس خروجی نورون j به صورت (۲) محاسبه می‌شود:

$$f = h_j * \sum_{i=1}^R (p_i * w_{ij}) \quad (2)$$

تابع f یک تابع فعال‌سازی سیگموئید است که به صورت (۳) تعریف می‌گردد:

$$f(S_j) = \frac{1}{1 + e^{-\frac{S_j + b_j}{\theta_0}}} \quad (3)$$

در رابطه (۳) b_j به عنوان مقدار بایاس و θ به عنوان پارامتر شکل تابع در نظر گرفته شده است. خروجی‌های حاصل از لایه پنهان به لایه خروجی منتقل شده و محاسبات به همین ترتیب در (۴) و (۵) ادامه می‌یابد:

$$S_k = \sum_{j=1}^R w_{kj} O_j \quad (4)$$

$$O_k = f(S_k) \quad (5)$$

هدف نهایی شبکه تولید پاسخ دقیق در لایه خروجی است. در صورت وجود خطا میان خروجی مطلوب و خروجی شبکه، طی مراحل یادگیری وزن‌ها به روزرسانی می‌شوند تا این خطا به حداقل ممکن برسد.

در این تحقیق از شبکه عصبی سه‌لایه با الگوریتم پس انتشار خطا استفاده شده است. این شبکه مجهز به تابع انتقال تانژانت هایپربولیک و الگوریتم یادگیری نزولی گرادیان با نرخ یادگیری تطبیقی است. این پیکربندی موجب شده است تا همگرایی الگوریتم ممیتیک تسهیل گردد و کیفیت پاسخ‌های به دست آمده به طور محسوسی بهبود یابد.

۴- الگوریتم ترکیبی پیشنهادی

در این پژوهش الگوریتم بهینه‌سازی ترکیبی نوآورانه ارائه شده است که با ادغام یک شبکه عصبی در چارچوب الگوریتم ممیتیک کلاسیک بهبود عملکرد این الگوریتم را هدف قرار می‌دهد. در رویکرد پیشنهادی از قابلیت یادگیری شبکه عصبی برای هدایت

فرایند جستجوی ممتیک استفاده شده است تا همگرایی سریع تر و دقیق تری نسبت به نسخه های معمول حاصل شود. این تلفیق با بهره گیری از پیش بینی های مبتنی بر یادگیری تصمیم گیری در انتخاب راه حل های مطلوب در هر نسل را بهبود می بخشد. شکل ۲ ساختار کلی الگوریتم ممتیک - عصبی پیشنهادی را به صورت نمودار جریان نمایش می دهد. مراحل اجرای الگوریتم به شرح زیر است:

- تولید تصادفی جمعیت اولیه؛
 - ارزیابی تابع هدف یا معیار برازندگی برای تمامی اعضای جمعیت؛
 - شناسایی بهترین و ضعیف ترین اعضای جمعیت بر اساس مقادیر تابع هدف؛
 - آموزش شبکه عصبی با استفاده از داده های مربوط به متغیرهای طراحی و مقادیر تابع هدف؛
 - پیش بینی ترکیب های بهینه متغیرها توسط شبکه عصبی آموزش دیده به منظور بهبود تابع هدف؛
 - جایگزینی ضعیف ترین اعضای جمعیت با ترکیب های پیش بینی شده و مطلوب تر؛
 - اعمال مراحل کلاسیک الگوریتم ممتیک شامل انتخاب، ترکیب و جهش؛
 - تکرار فرایند با استفاده از نسل جدید تا تحقق معیارهای همگرایی.
- در الگوریتم ارائه شده شبکه عصبی نقش یک راهنمای تطبیقی را ایفا می کند که با تحلیل داده های جمعیت، ترکیب های امیدوارکننده برای بهبود تابع هدف ارائه می دهد. سازوکار جایگزینی آگاهانه افراد با عملکرد ضعیف، حفظ تنوع ژنتیکی در جمعیت و کاهش احتمال همگرایی زود هنگام را امکان پذیر می سازد. به این ترتیب فرایند جستجو نه تنها سریع تر به نواحی بهینه فضای مسئله نزدیک می شود، بلکه کیفیت راه حل نهایی نیز به طور قابل توجهی افزایش می یابد.
- برای ارزیابی اثربخشی الگوریتم پیشنهادی، آن بر روی مجموعه ای از توابع معیار استاندارد آزمون شده است. نتایج نشان می دهد که الگوریتم ترکیبی ارائه شده، هم در بهبود دقت نهایی پاسخ و هم در افزایش سرعت همگرایی، عملکرد برتری نسبت به الگوریتم ممتیک سنتی از خود نشان می دهد. در بخش های بعدی مقاله جزئیات این ارزیابی ها و مقایسه کمی با روش های پایه ارائه خواهد شد.




Figure 2: Diagram of the Proposed Hybrid Method

شکل ۲: نمودار روش ترکیبی پیشنهادی

۵- آزمایش‌ها و نتایج

در این مطالعه، از نسخه توسعه‌یافته‌ای از الگوریتم ممیتیک با قابلیت یادگیری خودکار و پشتیبانی شده توسط شبکه عصبی (الگوریتم ممیتیک - عصبی) استفاده شده است. عملکرد این الگوریتم با اجرای مجموعه‌ای از آزمایش‌های معیار ارزیابی شده و نتایج آن با نسخه استاندارد الگوریتم ممیتیک مقایسه گردیده است.

برای اطمینان از مقایسه عادلانه، پارامترهای هر دو الگوریتم مطابق با مقادیر مرسوم در ادبیات علمی تنظیم شده‌اند. این پارامترها شامل احتمال ترکیب برابر با ۸۰٪، احتمال جهش ۳٪ و اندازه جمعیت ثابت به ترتیب ۱۰ یا ۱۰۰ عضو در هر آزمایش است. به‌منظور تضمین شرایط اولیه یکسان، از یک بذر تصادفی مشترک برای تولید توالی عددی اولیه در هر دو الگوریتم استفاده شده است.

فرایند ارزیابی شامل اجرای ده آزمایش مستقل بوده که در هر یک، جمعیتی با اندازه مشخص و یکسان در هر دو الگوریتم تولید شده و عملکرد آن‌ها مورد تحلیل قرار گرفته است. این رویکرد امکان مقایسه دقیق و معتبر بین الگوریتم ممیتیک - عصبی و نسخه استاندارد آن را فراهم می‌سازد.

۵-۱- عملکرد مدل‌های ارائه شده

مدل موردبررسی در این بخش یک مسئله بهینه‌سازی با ساختاری پیوسته، محدب و غیرمتعارف است که به‌گونه‌ای طراحی شده است تا تعداد زیادی حداقل محلی ایجاد کند. ویژگی چندحالتی بودن این تابع آزمون چالشی جدی برای اغلب الگوریتم‌های جستجوی سراسری به همراه دارد. با این حال نکته قابل توجه این است که محل استقرار حداقل‌های محلی در این مدل به‌صورت منظم در فضای جستجو توزیع شده‌اند؛ امری که از یک‌سو دشواری مسئله را افزایش می‌دهد، اما از سوی دیگر امکان ارزیابی دقیق‌تری از توان الگوریتم‌ها در عبور از بهینه‌های محلی و رسیدن به بهینه جهانی فراهم می‌سازد.

این مسئله بهینه‌سازی را می‌توان به‌صورت ریاضی به‌عنوان یافتن بردار طراحی $x^n \in \mathbb{R}$ تعریف کرد، به‌گونه‌ای که مقدار تابع هدف $f(x)$ به حداقل ممکن برسد $\min_{x^n \in \mathbb{R}} f(x)$ در بخش‌های بعدی، ساختار تحلیلی (6) تابع هدف، به همراه نتایج حاصل از اجرای الگوریتم‌های ممیتیک کلاسیک و ترکیبی پیشنهادی موردبررسی و مقایسه قرار خواهد گرفت.

$$f(x) = 10n + \sum_{i=0}^n (x_i^2 - 10(\cos 2\pi x_i)), n = 2 \quad (6)$$

با محدودیت‌های جانبی زیر:

$$-5/12 \leq x_i \leq 5/12$$

ماهیت چندمدلی این مسئله باعث می‌شود فرایند دستیابی به بهینه جهانی برای بسیاری از الگوریتم‌های بهینه‌سازی چالش‌برانگیز باشد، زیرا این روش‌ها ممکن است در بهینه‌های محلی گرفتار شوند. در مسئله موردبررسی، حداقل جهانی تابع هدف در نقطه $x_i = 0$ برای تمام i قرار دارد و مقدار بهینه آن برابر با $f(x) = 0$ است. این مسئله با استفاده از الگوریتم ممیتیک کلاسیک و الگوریتم ترکیبی ممیتیک - عصبی پیشنهادی موردبررسی و حل قرار گرفته است.

نتایج به‌دست‌آمده از میانگین بیش از ۱۰ اجرای مستقل الگوریتم‌ها نشان می‌دهد که الگوریتم ترکیبی، هم از نظر سرعت همگرایی و هم کیفیت پاسخ نهایی، عملکرد برتری نسبت به الگوریتم ممیتیک کلاسیک دارد. به طور خاص، الگوریتم ممیتیک سنتی پس از ۲۰ نسل به مقدار میانگین تابع هدف برابر با ۰/۱۴۱ می‌رسد، درحالی‌که الگوریتم ترکیبی این مقدار را تنها پس از ۷ نسل به دست می‌آورد. افزون بر این، روند همگرایی در نسل‌های بعدی نیز با شیب به‌مراتب بیشتری به سمت مقدار بهینه جهانی ادامه می‌یابد.

تحلیل آماری نتایج شامل بهترین، بدترین، میانگین و انحراف معیار مقادیر حاصل از ۱۰ اجرای مختلف الگوریتم‌ها، در جدول ۱ ارائه شده است. این نتایج به‌وضوح نشان می‌دهند که الگوریتم ترکیبی ممیتیک - عصبی نه تنها از لحاظ دقت نهایی بلکه از نظر پایداری نتایج نیز نسبت به الگوریتم ممیتیک معمولی عملکرد قابل توجهی دارد.

مدل دوم بررسی‌شده، یکی از مدل‌های متداول در ارزیابی الگوریتم‌های بهینه‌سازی است که ساختار تابع آزمون آن در ادامه به‌صورت ریاضی در (۷) تعریف می‌شود:

$$\text{Minimize: } f(x) = \sum_{i=1}^n (x_i - 1)^2 \quad (7)$$

با محدودیت های جانبی:

$$-5 \leq x_i \leq 5$$

در این بخش، عملکرد الگوریتم ترکیبی ممیتیک - عصبی در حل یک مسئله بهینه سازی با حداقل جهانی شناخته شده مورد بررسی قرار گرفته است. مقدار بهینه تابع هدف در این مسئله برابر با $f(x)=0$ بوده که در نقطه $x_i=1.0$ برای تمام $i=1,2,\dots,n$ حاصل می شود. در این رابطه n نشان دهنده تعداد متغیرهای طراحی و به عبارتی، بعد مسئله است. در آزمایش حاضر، مقدار $5n$ در نظر گرفته شده است و مسئله مذکور با استفاده از هر دو الگوریتم ممیتیک کلاسیک و الگوریتم ترکیبی پیشنهادی حل شده است.

نتایج به دست آمده از میانگین بیش از ده اجرای مستقل الگوریتم ها حاکی از آن است که روش ترکیبی پیشنهادی از منظر سرعت همگرایی و کیفیت نهایی راه حل، عملکردی به مراتب برتر از الگوریتم ممیتیک معمولی ارائه می دهد. به طور مشخص الگوریتم ممیتیک استاندارد در پایان نسل پنجاهم به میانگین مقدار تابع هدف برابر با $1/26$ دست یافته است، در حالی که الگوریتم ترکیبی تنها پس از 43 نسل مقدار تابع هدف را به کمتر از 0.012 کاهش داده است. این تفاوت چشمگیر، برتری رویکرد ترکیبی در کاهش چشمگیر تعداد نسل های مورد نیاز و دستیابی به دقت بالاتر را تأیید می کند.

این یافته ها نشان می دهند که تلفیق ساختار یادگیری شبکه عصبی با الگوریتم ممیتیک نه تنها نرخ همگرایی را به طور قابل توجهی افزایش می دهد، بلکه دقت و پایداری نتایج نهایی را در مسائل بهینه سازی با ابعاد متوسط بهبود می بخشد.

به منظور ارزیابی توانمندی الگوریتم ترکیبی ممیتیک-عصبی در حل مسائل بهینه سازی محدود شده، یکی از مسائل کلاسیک با سه متغیر طراحی به عنوان مطالعه موردی انتخاب شده است. این مسئله که تحت عنوان مسئله منحنی نیز شناخته می شود، یکی از چالش های رایج در بهینه سازی غیرخطی است و ویژگی بارز آن وجود یک ناحیه بهینه جهانی با شکل هندسی تخت، کشیده، باریک و غیرمحدب در فضای طراحی است.

در چنین ساختاری شناسایی مسیر تقریبی منحنی بهینه ساده است، اما همگرایی دقیق به نقطه بهینه جهانی با توجه به شکل باریک و مغناطیسی ناحیه بهینه، برای بسیاری از الگوریتم های کلاسیک دشوار خواهد بود. از این رو این مسئله به عنوان یک آزمون مناسب برای ارزیابی دقت، سرعت همگرایی و توانایی الگوریتم ها در مدیریت فضای جستجوی محدود و غیرخطی در نظر گرفته شده است.

در چارچوب این مدل، هدف یافتن بردار طراحی $x^3 \in R$ است به گونه ای که مقدار تابع هدف به حداقل برسد. ساختار ریاضی تابع هدف و محدودیت های آن در (۸) ارائه خواهد شد.

$$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2] + (1 - x_i)^2, n = 3 \quad (8)$$

با محدودیت های زیر:

$$C_1(x) = 1 - \left(\prod_{i=1}^n x_i \right)^2 \leq 0$$

$$C_2(x) = \left| n - \left| \sum_{i=1}^n x_i \right| \right| = 0$$

و محدودیت های جانبی:

$$-5/12 \leq x_i \leq 5/12$$

در این بخش عملکرد الگوریتم ترکیبی ممیتیک - عصبی بر روی یک تابع آزمون با حداقل جهانی شناخته شده مورد بررسی قرار گرفته است. مقدار بهینه جهانی تابع هدف برابر با $f(x)=0$ بوده و در نقطه $x_i=1.0$ برای تمام $i=1,2,\dots,n$ حاصل می شود. نتایج تجربی نشان می دهد که الگوریتم ترکیبی پیشنهادی، در مقایسه با نسخه کلاسیک الگوریتم ممیتیک، بهبود قابل توجهی در همگرایی و کیفیت راه حل ارائه می دهد.

۶۵ همگرایی الگوریتم‌های ممیتیک از طریق یکپارچه‌سازی شبکه عصبی/محمدرضا دهقانی محمودآبادی- الهام دهقان طرزجانی

به طور خاص، پس از تنها ۵۰ نسل، میانگین مقدار تابع هدف در الگوریتم ممیتیک کلاسیک برابر با ۱۶/۵۵ بوده درحالی که روش ترکیبی موفق به دستیابی به مقدار پایین‌تر از ۶/۹ در همان تعداد نسل شده است. همچنین، الگوریتم ممیتیک استاندارد برای رسیدن به مقدار تابع هدف ۳/۶۷۵ نیازمند ۱۰۰۰ نسل بوده، درحالی که این مقدار توسط الگوریتم ممیتیک - عصبی تنها در ۹۱ نسل حاصل گردیده است. این تفاوت چشمگیر، اثربخشی رویکرد ترکیبی را در کاهش قابل توجه تعداد نسل‌های موردنیاز برای دستیابی به راه‌حل بهینه، به‌وضوح نشان می‌دهد.

در ادامه، یک مسئله بهینه‌سازی با محدودیت نیز موردبررسی قرار می‌گیرد. این مسئله شامل به حداقل رساندن یک تابع هدف تحت دو محدودیت نابرابری غیرخطی است که ساختار ریاضی آن به‌صورت (۹) تعریف شده است:

$$\text{Minimize: } f(x) = (x_1 - 10)^3 + (x_2 - 20)^3 \quad (9)$$

مشمول محدودیت‌های غیرخطی:

$$\begin{aligned} (x_1 - 5)^2 + (x_2 - 5)^2 - 100 &\geq 0 \\ -(x_1 - 6)^2 - (x_2 - 5)^2 + 82.81 &\geq 0 \end{aligned}$$

و محدودیت‌های جانبی:

$$13 \leq x_1 \leq 100, 0 \leq x_2 \leq 100$$

برای تابع آزمون چندحالت‌های که در بخش فوق موردبررسی قرار گرفته است، راه‌حل بهینه جهانی برابر با (۰/۸۴۲۹۶, ۱۴/۰۹۵) و مقدار متناظر تابع هدف آن برابر با $f(x)=5961/82$ است. لازم به ذکر است که در این نقطه بهینه هر دو محدودیت مسئله به‌صورت فعال و در محدوده قابل قبول برقرار هستند. نتایج حاصل از اجرای الگوریتم‌ها نشان می‌دهد که الگوریتم ترکیبی ممیتیک - عصبی در دستیابی به این مقدار بهینه عملکرد بسیار بهتری نسبت به نسخه سنتی الگوریتم ممیتیک دارد.

نمودارهای همگرایی و مقایسه نتایج عددی حاکی از آن است که رویکرد ترکیبی پیشنهادی، با بهره‌گیری از مکانیزم‌های یادگیری شبکه عصبی، توانسته است با سرعت بیشتری به مقدار بهینه نزدیک شود و مقدار نهایی تابع هدف را به طور قابل توجهی نسبت به الگوریتم ممیتیک کلاسیک کاهش دهد. این برتری هم در نرخ همگرایی و هم در کیفیت نهایی راه‌حل مشاهده می‌شود که اهمیت استفاده از روش‌های ترکیبی در حل مسائل چند قله‌ای و پیچیده را تأیید می‌کند.

تابع موردنظر از منظر ریاضی یک مسئله بهینه‌سازی چندحالت‌ها با فرم تابع غیرخطی و محدودیت‌های فعال است که در ادامه به‌صورت تحلیلی ارائه می‌شود:

$$\text{Minimize } 418/9829n + \sum_{i=1}^n (-x_i \sin(\sqrt{|x_i|})) \quad (10)$$

با محدودیت‌های جانبی:

$$-500 \leq x_i \leq 500$$

حداقل جهانی $f(x)=0$ در $x_i=420/9687$ ($i=1:n$) است. این مشکل با ۱۰ متغیر طراحی حل شده است.

بررسی عملکرد الگوریتم ترکیبی ممیتیک - عصبی نشان می‌دهد که این روش در مقایسه با الگوریتم ممیتیک کلاسیک، پیشرفت قابل توجهی در کیفیت راه‌حل و سرعت همگرایی دارد. به طور میانگین، مقدار تابع هدف به‌دست‌آمده توسط الگوریتم ممیتیک استاندارد پس از ۲۰۰ نسل برابر با ۴۵/۷۳ گزارش شده است، درحالی که الگوریتم ترکیبی پیشنهادی موفق به دستیابی به مقدار ۰/۳۹ در تنها ۱۴۷ نسل و ۰/۱۸۴ در پایان ۲۰۰ نسل گردید. این نتایج به‌وضوح برتری رویکرد ترکیبی را در کاهش تعداد نسل‌های موردنیاز و بهبود دقت نهایی تأیید می‌کنند.

همان‌طور که در جدول ۱ نشان داده‌شده، مقایسه بهترین، بدترین، میانگین و انحراف معیار راه‌حل‌ها در آزمون‌های مختلف، بیانگر اثربخشی بالای سازوکار خودآموز شبکه عصبی در چارچوب الگوریتم ممیتیک است. کاهش محسوس در انحراف معیار نتایج حاصل از الگوریتم ممیتیک - عصبی نسبت به نسخه کلاسیک، نشان‌دهنده پایداری بالای عملکرد آن در شرایط مختلف است. این موضوع در کاربردهای دنیای واقعی که با محدودیت‌های زمانی و هزینه‌ای برای اجرای مکرر الگوریتم‌ها مواجه هستند، اهمیت زیادی دارد.

نتایج به‌دست‌آمده حاکی از آن است که الگوریتم پیشنهادی، با نرخ موفقیت تقریبی ۸۸٪ قادر است بدون نیاز به تکرارهای متعدد، به راه‌حل‌هایی باکیفیت بالادست یابد. این ویژگی، به‌ویژه در مسائل بهینه‌سازی مرتبط با شبیه‌سازی‌های محاسباتی

گران قیمت، می تواند نقش کلیدی در کاهش هزینه های محاسباتی و افزایش بهره وری ایفا کند؛ بنابراین، رویکرد ترکیبی ممیتیک - عصبی می تواند به عنوان یک چارچوب قدرتمند و قابل اعتماد برای حل مسائل بهینه سازی پیچیده و زمان بر مورد استفاده قرار گیرد.

Table 1: Results of Multiple Runs for Testing All Scenarios

جدول ۱: نتایج چندین اجرا برای تست همه حالت ها

تابع	ارزش بهینه	الگوریتم ممیتیک			الگوریتم ممیتیک - عصبی		
		بدترین	بهترین	میانگین	انحراف معیار	بدترین	بهترین
محدود کردن	0	0/739	0	0/141	0/187	0/01	0/001
قلمرو	0	1/564	0/439	1/26	0/69	0/4	0/012
عملکرد منحنی	0	109/95	1/36	16/55	26/4	5/4	6/9
نابرابری غیر خطی	5962	4402	5867	5265	375	5283	5336
تست چندحالت	0	181	0/436	46	56/1	0/59	0/42

۶- نتیجه گیری

در این پژوهش الگوریتم ترکیبی هوشمند مبتنی بر ادغام الگوریتم ممیتیک و شبکه عصبی مصنوعی ارائه شده است. هدف اصلی این ترکیب، بهره گیری همزمان از قابلیت های جستجوی سراسری الگوریتم ممیتیک و توانایی یادگیری تطبیقی شبکه های عصبی به منظور ارتقای سرعت همگرایی و کیفیت راه حل در مسائل بهینه سازی غیرخطی و چندوجهی است. با تلفیق این دو رویکرد الگوریتم نهایی از مزایای ساختاری هر دو بهره مند شده و به عنوان یک چارچوب بهینه سازی توانمند و سریع مطرح می شود. در ساختار پیشنهادی، یک شبکه عصبی پیش خور با قابلیت یادگیری پس انتشار برای هدایت فرآیند جستجوی ممیتیک در مسیر یافتن نقاط بهینه جهانی به کار گرفته شده است. نتایج حاصل از آزمون های تجربی اولیه نشان می دهد که استفاده از این ساختار ترکیبی منجر به بهبود چشمگیر سرعت همگرایی و افزایش کیفیت نهایی راه حل ها نسبت به الگوریتم ممیتیک کلاسیک شده است. همچنین نسخه خودآموز الگوریتم با قابلیت به روزرسانی هوشمند، عملکردی پایدار و دقیق در حل مسائل با مقیاس متوسط ارائه می دهد.

الگوریتم پیشنهادی هم اکنون در برخی کاربردهای واقعی نیز پیاده سازی شده و در حال توسعه برای مسائل با ابعاد بزرگ تر است. افزایش ابعاد مسئله نیازمند تغییرات ساختاری در معماری شبکه و تنظیم پارامترهای الگوریتم است که در تحقیقات آتی مورد بررسی قرار خواهد گرفت. نتایج آزمایش ها تأیید می کنند که این چارچوب محاسباتی می تواند به عنوان یک رویکرد پیشرفته و قابل اعتماد در حل مسائل بهینه سازی پیچیده مورد استفاده قرار گیرد و مسیرهای جدیدی را برای توسعه الگوریتم های ترکیبی در آینده فراهم کند.

مراجع

- [1] C. Cotta and P. Moscato, "A memetic-aided approach to hierarchical clustering from distance matrices: application to gene expression clustering and phylogeny," *Biosystems*, vol. 72, no. 1, pp. 75–97, 2003.
- [2] W. Duch, "Memetics and neural models of conspiracy theories," *Patterns*, vol. 2, no. 11, p. 100353, Nov. 2021.
- [3] D. Ermakov and A. Ermakov, "Memetic approach to cultural evolution," *Biosystems*, vol. 204, p. 104378, Jun. 2021.
- [4] K. Sörensen and M. Sevaux, "MA|PM: Memetic Algorithms with Population Management," *Comput Oper Res*, vol. 33, no. 5, pp. 1214–1225, 2006.
- [5] Y. S. Ong and A. J. Keane, "Meta-Lamarckian Learning in Memetic Algorithms," *IEEE Transactions on Evolutionary Computation*, vol. 8, no. 2, pp. 99–110, 2004.
- [6] M. Bereta, "Baldwin Effect and Lamarckian Evolution in a Memetic Algorithm for Euclidean Steiner Tree Problem," *Memet Comput*, vol. 11, no. 1, pp. 35–52, 2019.

- [7] A. Nooraliei, M. R. Meybodi, and B. Masoumi, "Memetic Algorithm Based on Genetic Algorithm and Improved Cuckoo Search Algorithm for Dynamic Environment," 2016 Artificial Intelligence and Robotics, pp. 54–60, 2016.
- [8] M. R. dehganimahmoudabadi N nabavizadeh, "Improving the learning classifier system with the basic memetic algorithm to solve the problem based on the law," The journal of Engineering Management and Soft Computing., Feb. 2023.
- [9] H.-E. Tseng, W.-P. Wang, and H.-Y. Shih, "Using memetic algorithms with guided local search to solve assembly sequence planning," Expert Syst Appl, vol. 33, no. 2, pp. 451–467, 2007.
- [10] Mohammadreza, "A novel aggregation-based distributed search model for optimal design using the memetic algorithm".
- [11] R. J. Ziarani and R. Ravanmehr, "Deep neural network approach for a serendipity-oriented recommendation system," Expert Syst Appl, vol. 185, p. 115660, 2021.
- [12] W. Wardah, M. G. M. Khan, A. Sharma, and M. A. Rashid, "Protein secondary structure prediction using neural networks and deep learning: A review," Comput Biol Chem, vol. 81, pp. 1–8, 2019.
- [13] O. Barukab, F. Ali, W. Alghamdi, Y. Bassam, and S. Afzal Khan, "DBP-CNN: Deep learning-based prediction of DNA-binding proteins by coupling discrete cosine transform with two-dimensional convolutional neural network," Expert Syst Appl, vol. 197, p. 116729, 2022.