

پژوهشی

همگرایی الگوریتم‌های ممیتیک از طریق یکپارچه‌سازی شبکه عصبی

محمدرضا دهقانی محمودآبادی* | ID | الهام دهقان طرزجانی^۲

چکیده:

این پژوهش به تحلیل و بهبود الگوریتم‌های ممیتیک در حل مسائل بهینه‌سازی پیچیده می‌پردازد. الگوریتم‌های ممیتیک با تکیه بر جستجوی مبتنی بر جمعیت و ارزیابی مکرر تابع هدف در شرایطی که محاسبه تابع هدف پرهزینه باشد، عملکرد مناسبی دارند. یکی از چالش‌های اصلی آن‌ها نرخ پایین همگرایی و نیاز به تعداد نسل‌های 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 ممیتیک ارائه شده است. در این روش شبکه عصبی نقش هدایت‌کننده فرایند جستجو را ایفا کرده و با بهبود دینامیک همگرایی سرعت رسیدن به پاسخ بهینه را افزایش می‌دهد. کارایی الگوریتم پیشنهادی با مجموعه‌ای از آزمون‌های معیار مورد ارزیابی قرار گرفته و نتایج نشان می‌دهد که سرعت همگرایی به‌طور چشمگیر افزایش یافته و کیفیت پاسخ‌ها تا ۸۸٪ بهبود یافته است. این یافته‌ها تأیید می‌کنند که الگوریتم ترکیبی نه تنها عملکرد الگوریتم ممیتیک را به‌طور قابل توجهی ارتقا می‌دهد، بلکه قابلیت تعمیم و کاربرد آن در طیف وسیعی از مسائل بهینه‌سازی را فراهم می‌آورد.

کلید واژه‌ها: الگوریتم ممیتیک، شبکه عصبی، بهینه‌سازی، ترکیبی.

^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

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

تاریخ دریافت: ۱۴۰۴/۵/۷

تاریخ پذیرش: ۱۴۰۴/۵/۲۷

<https://doi.org/...>

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]. با وجود 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 مورد توجه پژوهشگران قرار گرفته است. شبکه‌های عصبی الهام گرفته 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].

الگوریتم های ممتیک، که بر پایه اصول انتخاب طبیعی داروینی و جستجوی تصادفی بنا شده اند، فرآیند بهینه سازی را با ایجاد جمعیتی از راه حل های اولیه تصادفی آغاز کرده و سپس با به روز رسانی تدریجی جمعیت به سمت یافتن راه حل های بهینه حرکت می کنند. هدف اصلی این الگوریتم ها بهره برداری از اطلاعات موجود در جمعیت برای انتخاب کارآمدترین افراد و تولید نسل های جدیدی از راه حل ها است. با وجود پیشرفت های متعدد در ساختار و عملکرد آن ها نسخه مورد استفاده در این پژوهش یک فرم ساده و کلاسیک از الگوریتم ممتیک محسوب می شود که بر اصول بنیادین این رویکرد استوار است [۴].

در مقایسه با روش های سنتی بهینه سازی الگوریتم های ممتیک مزایای مهمی از جمله توانایی جستجوی هم زمان چندین نقطه در فضای مسئله، مقابله با بهینه های محلی و قابلیت کار با ترکیب متغیرهای پیوسته و گسسته را دارند. این ویژگی ها امکان ارائه مجموعه ای از راه حل های قابل قبول را فراهم می کنند که به جای تمرکز بر یک پاسخ منفرد امکان انتخاب بهترین گزینه را از میان چندین راه حل فراهم می سازد. با این حال یکی از چالش های رایج این الگوریتم ها کندی همگرایی در مراحل پایانی جستجو است؛ به ویژه هنگامی که ناحیه ای نزدیک به بهینه جهانی شناسایی شده باشد. بهره گیری از استراتژی های نخبه گرایانه نظیر حفظ و انتقال بهترین راه حل ها به نسل های بعدی می تواند کارایی همگرایی را به طور قابل توجهی بهبود بخشد [۵].

برای ارتقای بیشتر عملکرد الگوریتم ممتیک، به ویژه در مرحله همگرایی نهایی، استفاده از شبکه های عصبی به عنوان مکمل پیشنهاد می شود. در این رویکرد شبکه های عصبی با یادگیری ویژگی های جمعیت و میزان شایستگی هر عضو مسیر جستجو را به سمت نواحی امیدبخش هدایت می کنند. این تلفیق نه تنها کیفیت راه حل های حاصل را بهبود می بخشد، بلکه بهره وری کلی فرایند بهینه سازی را نیز افزایش می دهد. در این پژوهش رویکرد ترکیبی نوآورانه بر پایه تلفیق الگوریتم ممتیک و شبکه عصبی بازگشتی چندلایه ارائه شده است. الگوریتم پیشنهادی با بهره گیری از توانمندی های هر دو روش قادر است مسائل بهینه سازی پیچیده را با سرعت و دقت بالا حل کند. در این چارچوب از نسخه ساده ای از الگوریتم ممتیک با رمزگذاری باینری استفاده از روش انتخاب چرخ رولت، ترکیب یکنواخت، جایگزینی نخبه گرا و جستجوی محلی بهره گرفته شده است که بنیان ساختار پیشنهادی را تشکیل می دهد [۶].

ساختار مقاله به صورت زیر سازمان دهی شده است: در بخش دوم مروری جامع بر الگوریتم های ممتیک ارائه می شود؛ بخش سوم به مرور اجمالی شبکه های عصبی اختصاص دارد؛ در بخش چهارم، الگوریتم ترکیبی پیشنهادی تشریح می گردد؛ در بخش پنجم، نتایج آزمایش های تجربی و تحلیل آن ها ارائه می شود؛ و نهایتاً بخش ششم به جمع بندی یافته ها و نتیجه گیری اختصاص یافته است.

۲- الگوریتم های ممتیک

الگوریتم های ممتیک 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، فرآیند 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 [۵].

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 ممتیک محسوب می شود که بر مبانی بنیادین این روش استوار است. در مقایسه با روش های سنتی بهینه سازی، الگوریتم های ممتیک از مزایای متعددی از جمله قابلیت جستجوی هم زمان در چندین نقطه از فضای مسئله، مقاومت در برابر همگرایی زود هنگام 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 ممتیک، 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 راه‌حل‌ها به نسل‌های بعدی روشی مؤثر به شمار می‌رود. این استراتژی‌ها با تمرکز بر ساده‌ترین و کارآمدترین راه‌حل‌های موجود، موجب تسریع فرایند همگرایی و بهبود بهره‌وری کلی می‌شوند [۸].

برای ارتقای عملکرد به‌ویژه در مرحله همگرایی نهایی ترکیب الگوریتم ممیتیک با شبکه‌های عصبی به‌عنوان یک رویکرد مکمل پیشنهاد می‌شود. در این چارچوب شبکه‌های عصبی با یادگیری الگوهای موجود در جمعیت و ارزیابی شایستگی افراد فرآیند جستجو را به سمت نواحی امیدبخش هدایت می‌کنند. این هم‌افزایی نه تنها کیفیت راه‌حل‌های حاصل را ارتقا می‌دهد، بلکه موجب افزایش سرعت و دقت فرایند بهینه‌سازی نیز می‌گردد [۹].

در این مطالعه رویکرد ترکیبی نوآورانه مبتنی بر تلفیق الگوریتم ممیتیک و شبکه عصبی بازگشتی چندلایه ارائه شده است. الگوریتم پیشنهادی با بهره‌گیری هم‌زمان از نقاط قوت هر دو روش قادر است مسائل بهینه‌سازی پیچیده را با کارایی بالاتری حل کند. در این ساختار از نسخه‌ای ساده از الگوریتم ممیتیک با رمزگذاری باینری، انتخاب به روش چرخ رولت، ترکیب یکنواخت، جایگزینی نخبه‌گرا و جستجوی محلی استفاده شده است که شالوده چارچوب پیشنهادی را تشکیل می‌دهد [۱۰].

۳- شبکه‌های عصبی


در حوزه علوم رایانه شبکه‌های عصبی مصنوعی به‌عنوان یکی از ابزارهای پیشرفته پردازش اطلاعات شناخته می‌شوند که الهام‌گرفته از ساختار سیستم عصبی زیستی به‌ویژه مغز انسان طراحی شده‌اند. این شبکه‌ها از مجموعه‌ای از نورون‌های مصنوعی متصل به یکدیگر تشکیل شده‌اند که در قالب لایه‌های مجزا سازماندهی می‌شوند. هر شبکه شامل یک لایه ورودی یک یا چند لایه پنهان و یک لایه خروجی است که داده‌های ورودی را به‌صورت سلسله‌مراتبی و در مسیر پیشرو پردازش می‌کند. در لایه‌های پنهان نورون‌ها با هدف شناسایی الگوها و روابط پیچیده موجود در داده‌ها فعال می‌شوند و تنها آن دسته از نورون‌هایی که قادر به ایجاد خروجی معنادار باشند در فرایند یادگیری مؤثر واقع می‌شوند [۲].

شبکه‌های عصبی در حل مسائل بهینه‌سازی از مکانیزم‌های یادگیری الهام‌گرفته از فرآیندهای شناختی انسان بهره می‌برند. در این رویکرد وزن اتصالات سیناپسی میان نورون‌ها بر اساس تعامل ورودی‌ها و خروجی‌ها به‌روزرسانی شده و خروجی شبکه متناسب با ترکیب خاصی از ورودی‌ها شکل می‌گیرد. فرآیند تنظیم این وزن‌ها از طریق الگوریتم‌های یادگیری انجام می‌شود و منجر به استخراج الگوهای فعال‌سازی بهینه خواهد شد [۱۱].

فرآیند یادگیری در شبکه‌های عصبی به دو دسته یادگیری نظارت‌شده و یادگیری بدون نظارت تقسیم می‌شود. در یادگیری نظارت‌شده خروجی هدف برای هر ورودی از پیش مشخص است و شبکه با کاهش اختلاف بین خروجی واقعی و خروجی مطلوب آموزش می‌بیند. در مقابل در یادگیری بدون نظارت شبکه بدون استفاده از برچسب‌های خروجی تلاش می‌کند الگوهای پنهان در داده‌ها را به‌صورت خودکار کشف کند [۱۲].

در این پژوهش با توجه به در دسترس بودن خروجی‌های هدف حاصل از اجرای الگوریتم ممیتیک از روش یادگیری نظارت‌شده 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.



شکل ۱. ساختار شبکه عصبی پایه

در چارچوب این شبکه هر نورون در لایه پنهان سیگنال خالص ورودی خود را با مجموع وزن دار داده های دریافتی محاسبه می کند و سپس خروجی آن با تابع فعال سازی غیر خطی مشخص می شود. به صورت ریاضی ورودی خالص نورون j در لایه پنهان به صورت (۱) تعریف می شود:

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

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 می شود:

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

تابع f یک تابع فعال سازی سیگموئید است که به صورت (۳) و (۴) تعریف می گردد:

$$O_j = f(S_j) \quad (3)$$

$$O_j = \frac{1}{(1 + e^{-\frac{S_j + b_j}{\theta_0}})} \quad (4)$$

در رابطه (۴) b_j به عنوان مقدار بایاس و θ به عنوان پارامتر شکل تابع در نظر گرفته شده است. خروجی های حاصل از لایه پنهان به لایه خروجی منتقل شده و محاسبات به همین ترتیب در (۵) و (۶) ادامه می یابد:

$$S_k = \sum_{j=1}^R w_{kj} O_j \quad (5)$$

$$O_k = f(S_k) \quad (6)$$

هدف نهایی شبکه تولید پاسخ دقیق در لایه خروجی است. در صورت وجود خطا میان خروجی مطلوب و خروجی شبکه، طی مراحل یادگیری وزن ها به روز رسانی می شوند تا این خطا به حداقل ممکن برسد. در این تحقیق از شبکه عصبی سه لایه 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 ممیک تسهیل گردد و کیفیت پاسخ های به دست آمده به طور محسوسی بهبود یابد.

۴- الگوریتم ترکیبی پیشنهادی

در این پژوهش الگوریتم بهینه سازی ترکیبی نوآورانه ارائه شده است که با ادغام یک شبکه عصبی در چارچوب الگوریتم ممیک کلاسیک بهبود عملکرد این الگوریتم را هدف قرار می دهد. در رویکرد پیشنهادی از قابلیت یادگیری شبکه عصبی برای هدایت فرآیند جستجوی ممیک 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 ممیک-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 ممیک شامل انتخاب، ترکیب و جهش؛

- تکرار فرآیند با استفاده از نسل جدید تا تحقق معیارهای همگرایی.

در الگوریتم ارائه شده شبکه عصبی نقش یک راهنمای تطبیقی را ایفا می‌کند که با تحلیل داده‌های جمعیت، ترکیب‌های امیدوارکننده برای بهبود تابع هدف ارائه می‌دهد. سازوکار جایگزینی آگاهانه افراد با عملکرد ضعیف، حفظ تنوع ژنتیکی در جمعیت و کاهش احتمال همگرایی زود هنگام را امکان‌پذیر می‌سازد. به این ترتیب فرایند جستجو نه تنها سریع‌تر به نواحی بهینه فضای مسئله نزدیک می‌شود، بلکه کیفیت راه‌حل نهایی نیز به‌طور قابل توجهی افزایش می‌یابد. برای ارزیابی اثربخشی الگوریتم پیشنهادی، آن بر روی مجموعه‌ای از توابع معیار استاندارد آزمون شده است. نتایج نشان می‌دهد که الگوریتم ترکیبی ارائه شده، هم در بهبود دقت نهایی پاسخ و هم در افزایش سرعت همگرایی، عملکرد برتری نسبت به الگوریتم ممیتیک سنتی از خود نشان می‌دهد. در بخش‌های بعدی مقاله جزئیات این ارزیابی‌ها و مقایسه کمی با روش‌های پایه ارائه خواهد شد.

۵- آزمایش‌ها و نتایج

در این مطالعه، از نسخه توسعه‌یافته‌ای از الگوریتم ممیتیک با قابلیت یادگیری خودکار و پشتیبانی‌شده 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 ۰.۸۰٪، احتمال جهش ۰.۳٪ 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.

فرآیند 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 مورد بررسی 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 (Y) تابع هدف، به همراه نتایج حاصل از اجرای الگوریتم‌های ممیتیک کلاسیک و ترکیبی پیشنهادی موردبررسی و مقایسه قرار خواهد گرفت.

$$f(x) = 10n + \sum_{i=0}^n (x_i^2 - 10(\cos 2\pi x_i)), n = 2 \quad (7)$$

با محدودیت‌های جانبی زیر:

$$-5/12 \leq x_i \leq 5/12 \quad (8)$$

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 مورد بررسی و حل قرار گرفته است. نتایج به دست آمده از میانگین بیش از ۱۰ اجرای مستقل الگوریتم ها نشان می دهد 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 می رسد، در حالی که الگوریتم ترکیبی این مقدار را تنها پس از ۷ نسل به دست می آورد. افزون بر این، روند همگرایی در نسل های بعدی نیز با شیب به مراتب بیشتری به سمت مقدار بهینه جهانی ادامه می یابد.

تحلیل آماری نتایج شامل بهترین، بدترین، میانگین و انحراف معیار مقادیر حاصل از ۱۰ اجرای مختلف الگوریتم ها، در جدول ۱ ارائه شده است. این نتایج به وضوح نشان می دهند 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 بررسی شده، یکی از مدل های متداول در ارزیابی الگوریتم های بهینه سازی است که ساختار تابع آزمون آن در ادامه به صورت ریاضی در (۹) تعریف می شود:

$$\text{Minimize: } f(x) = \sum_{i=1}^n (x_i - 1)^2 \quad (9)$$

با محدودیت های جانبی:

$$-5 \leq x_i \leq 5 \quad (10)$$

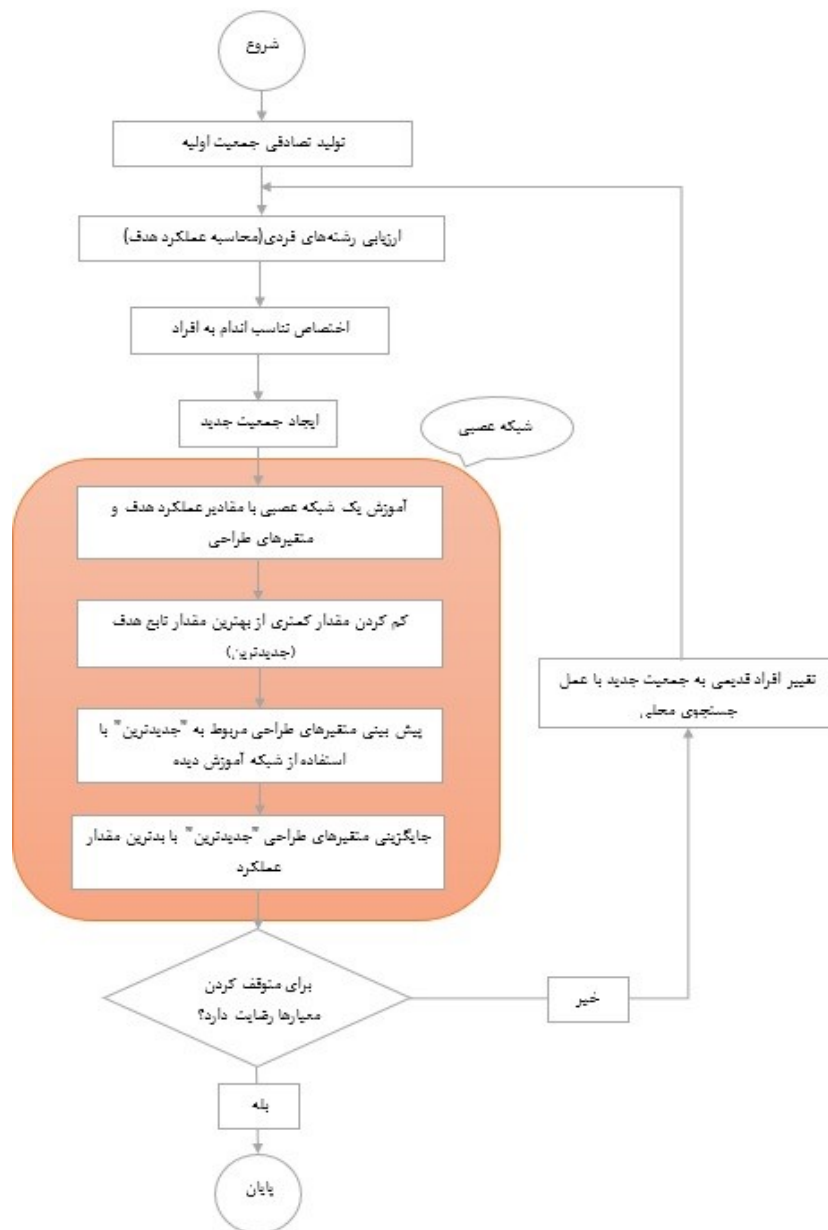
در این بخش، عملکرد الگوریتم ترکیبی ممیتیک - عصبی در حل یک مسئله بهینه سازی با حداقل جهانی شناخته شده مورد بررسی قرار گرفته است. مقدار بهینه تابع هدف در این مسئله برابر با $f(x)=0$ بوده که در نقطه $x_i=1.0$ برای تمام $i=1,2,\dots,n$ حاصل می شود. در این رابطه n نشان دهنده تعداد متغیرهای طراحی و به عبارتی، 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 ۱/۲۶ دست یافته است، در حالی که الگوریتم ترکیبی تنها پس از ۴۳ نسل مقدار تابع هدف را به کمتر از ۰/۱۲ 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 غیر خطی است و ویژگی بارز آن وجود یک ناحیه بهینه جهانی با شکل هندسی تخت، کشیده، باریک و غیر محدب 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 غیر خطی در نظر گرفته شده است.



شکل ۲. نمودار روش ترکیبی پیشنهادی

در چارچوب این مدل، هدف یافتن بردار طراحی $x^3 \in R$ است به گونه‌ای که مقدار تابع هدف به حداقل برسد. ساختار ریاضی تابع هدف و محدودیت‌های آن در (۱۱) و (۱۲) ارائه خواهد شد.

$$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2] + (1 - x_i)^2, n = 3 \quad (11)$$

با محدودیت‌های زیر:

$$C_1(x) = 1 - \left(\prod_{i=1}^n x_i \right)^2 \leq 0 \quad (12)$$

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

و محدودیت‌های جانبی:

$$-5/12 \leq x_i \leq 5/12 \quad (13)$$

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.

به طور خاص، پس از تنها ۵۰ نسل، میانگین مقدار تابع هدف در الگوریتم ممیتیک کلاسیک برابر با ۱۶/۵۵ بوده در حالی که روش ترکیبی موفق به دستیابی به مقدار پایین تر 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، در حالی 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 نسل های مورد نیاز برای دستیابی به راه حل بهینه، به وضوح نشان می دهد.

در ادامه، یک مسئله بهینه سازی با محدودیت نیز مورد بررسی قرار می گیرد. این مسئله شامل به حداقل رساندن یک تابع هدف تحت دو محدودیت نابرابری غیر خطی است که ساختار ریاضی آن به صورت (۱۴) و (۱۵) تعریف شده است:

$$\text{Minimize: } f(x) = (x_1 - 10)^3 + (x_2 - 20)^3 \quad (14)$$

مشمول محدودیت های غیر خطی:

$$\begin{aligned} (x_1 - 5)^2 + (x_2 - 5)^2 - 100 &\geq 0 \\ -(x_1 - 6)^2 - (x_2 - 5)^2 + 82.81 &\geq 0 \end{aligned} \quad (15)$$

و محدودیت های جانبی:

$$13 \leq x_1 \leq 100, 0 \leq x_2 \leq 100 \quad (16)$$

برای تابع آزمون چند حالتهای که در بخش فوق مورد بررسی قرار گرفته است، راه حل بهینه جهانی برابر با (۰/۸۴۲۹۶، ۱۴/۰۹۵) $x=(x_1, x_2)$ 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 به صورت فعال و در محدوده قابل قبول برقرار هستند. نتایج حاصل از اجرای الگوریتم ها نشان می دهد 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 بهره گیری از مکانیزم های 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 راه حل مشاهده می شود که اهمیت استفاده از روش های ترکیبی در حل مسائل چند قله ای و پیچیده را تأیید می کند. تابع مورد نظر از منظر ریاضی یک مسئله بهینه سازی چند حالته با فرم تابع غیر خطی و محدودیت های فعال است که در ادامه به صورت تحلیلی ارائه می شود:

$$\text{Minimize } 418/9829n + \sum_{i=1}^n (-x_i \sin(\sqrt{|x_i|})) \quad (17)$$

با محدودیت های جانبی:

$$-500 \leq x_i \leq 500 \quad (18)$$

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 می دهد که این روش در مقایسه با الگوریتم ممیتیک کلاسیک، پیشرفت قابل توجهی در کیفیت راه حل و سرعت همگرایی دارد. به طور میانگین، مقدار تابع هدف به دست آمده توسط الگوریتم ممیتیک استاندارد پس از ۲۰۰ نسل برابر با ۴۵/۷۳ گزارش شده است، در حالی 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 به وضوح برتری رویکرد ترکیبی را در کاهش تعداد نسل های مورد نیاز و بهبود دقت نهایی تأیید می کنند.

همان طور که در جدول ۱ نشان داده شده، مقایسه بهترین، بدترین، میانگین و انحراف معیار راه حل ها در آزمون های 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 گران‌قیمت، می‌تواند نقش کلیدی در کاهش هزینه‌های محاسباتی و افزایش بهره‌وری ایفا کند؛ بنابراین، رویکرد ترکیبی ممیتیک - عصبی می‌تواند به‌عنوان یک چارچوب قدرتمند و قابل‌اعتماد برای حل مسائل بهینه‌سازی پیچیده و زمان‌بر مورد استفاده قرار گیرد.

جدول ۱: نتایج چندین اجرا برای تست همه حالت‌ها

تابع	ارزش بهینه	الگوریتم ممیتیک				الگوریتم ممیتیک-عصبی			
		بدترین	بهترین	میانگین	انحراف معیار	بدترین	بهترین	میانگین	انحراف معیار
محدود کردن	۰	0/739	۰	0/141	0/187	0/01	۰	0/001	0/003
قلمرو	۰	1/564	0/439	1/26	0/69	0/001	0/001	0/012	0/03
عملکرد منحنی	۰	109/95	1/36	16/55	26/4	5/4	1/6	6/9	1/12
نابرابری غیرخطی	۵۹۶۲	۴۴۰۲	۵۸۶۷	۵۲۶۵	۳۷۵	۵۲۸۳	۵۴۸۷	۵۳۳۶	۱۹۸
تست چندحالت	۰	۱۸۱	0/43۶	۴۶	56/1	0/59	0/39	0/42	0/09

۶- نتیجه‌گیری

در این پژوهش الگوریتم ترکیبی هوشمند مبتنی بر ادغام الگوریتم ممیتیک و شبکه عصبی مصنوعی ارائه شده است. هدف اصلی این ترکیب، بهره‌گیری هم‌زمان از قابلیت‌های جستجوی سراسری الگوریتم ممیتیک و توانایی یادگیری تطبیقی شبکه‌های عصبی به منظور ارتقای سرعت همگرایی و کیفیت راه‌حل در مسائل بهینه‌سازی غیرخطی و چندوجهی است. با تلفیق این دو رویکرد الگوریتم نهایی از مزایای ساختاری هر دو بهره‌مند شده و به‌عنوان یک چارچوب بهینه‌سازی توانمند و سریع مطرح می‌شود. در ساختار پیشنهادی، یک شبکه عصبی پیش‌خور با قابلیت یادگیری پس‌انتشار برای هدایت فرآیند جستجوی ممیتیک در مسیر یافتن نقاط بهینه جهانی به‌کار گرفته شده است. نتایج حاصل از آزمون‌های تجربی اولیه نشان می‌دهد که استفاده از این ساختار ترکیبی منجر به بهبود چشمگیر سرعت همگرایی و افزایش کیفیت نهایی راه‌حل‌ها نسبت به الگوریتم ممیتیک کلاسیک شده است. همچنین نسخه خودآموز الگوریتم با قابلیت به‌روزرسانی هوشمند، عملکردی پایدار و دقیق در حل مسائل با مقیاس متوسط ارائه می‌دهد.

الگوریتم پیشنهادی هم‌اکنون در برخی کاربردهای واقعی نیز پیاده‌سازی شده و در حال توسعه برای مسائل با ابعاد بزرگ‌تر 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 آزمایش‌ها تأیید می‌کنند که این چارچوب محاسباتی می‌تواند به‌عنوان یک رویکرد پیشرفته و قابل اعتماد در حل مسائل بهینه‌سازی پیچیده مورد استفاده قرار گیرد و مسیرهای جدیدی را برای توسعه الگوریتم‌های 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. deghanimahmoudabadi 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.

Convergence of memetic Algorithms through Neural Network Integration

Mohammadreza DehghaniMahmoudAbadi ¹  | Elham DehghanTezerjani ²

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

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

Correspondence

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

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.

Keywords: Memetic Algorithm; Neural Network; Optimization; Hybrid.