



نقش الگوریتم‌های متاهوریستیک در بهینه‌سازی تصمیم‌گیری‌های صنعتی و مالی: تحلیل تطبیقی روش‌های مبتنی بر جمعیت و فیزیک در حل مسائل آزمون

علیرضا باغبان کهنه روز^۱

عباس طلوعی اشلقی^{*۲}

علیرضا پور ابراهیمی^۳

احمد ابراهیمی^۴

تاریخ دریافت: ۱۴۰۳/۰۵/۱۴ تاریخ پذیرش: ۱۴۰۳/۰۷/۰۸

چکیده

بهینه‌سازی در یافتن بهترین راه‌حل‌ها برای مسائل پیچیده در حوزه‌های مختلف، به‌ویژه تحلیل مسائل مالی و صنعتی و بهبود تصمیم‌گیری‌های مرتبط، نقش اساسی دارد. این پژوهش به مقایسه عملکرد سه الگوریتم ژنتیک، بهینه‌سازی اجتماع ذرات و شبیه‌سازی تبرید در حل مسائل صنعتی و مالی پرداخته است. هدف پژوهش، تحلیل تطبیقی این الگوریتم‌ها در بهینه‌سازی و شناسایی ویژگی‌های هر یک در توابع تست صنعتی و مالی مانند بهینه‌سازی تولید، مالی، کنترل موجودی و مسیریابی وسایل نقلیه است. معیارهای کلیدی از جمله میانگین، انحراف معیار، نرخ موفقیت، زمان همگرایی، دقت و تنوع جمعیت برای ارزیابی عملکرد استفاده شده و نقاط قوت و ضعف هر الگوریتم شناسایی شده است. نتایج نشان می‌دهد که هیچ الگوریتمی به‌طور مطلق بهترین نیست و انتخاب الگوریتم به ویژگی‌های خاص مسئله بستگی دارد. یافته‌ها، هم‌راستا با تئوری مطرح "*No Free Lunch*" در علوم کامپیوتر است که فرض برتری مطلق یک الگوریتم در تمامی مسائل را نقض می‌کند. پژوهش حاضر با هدف شناسایی نقاط قوت و ضعف الگوریتم‌ها در مواجهه با مسائل صنعتی و مالی، به بررسی شکاف‌های عملکردی آنها پرداخته است. این تحلیل به درک عمیق‌تری از چالش‌های مختلف و بهره‌برداری هوشمندانه از قابلیت‌های الگوریتم‌ها در مسائل پیچیده‌تر منجر می‌شود. نوآوری این پژوهش در شناسایی نیازمندی‌های توسعه الگوریتم‌های نوین و تعیین پارامترهای کلیدی برای بهبود عملکرد و فرایند حل مسئله است بویژه اینکه این مقایسه بر روی دو طیف از الگوریتم‌های مبتنی بر جمعیت (الگوریتم‌های ژنتیک و ازدحام ذرات) با انواع مبتنی بر قوانین فیزیکی (شبیه سازی تبرید)، انجام شده است. این نتایج زمینه‌ساز تدوین استراتژی‌های بهینه‌سازی در مسائل تصمیم‌گیری صنعتی و مالی خواهد بود.

کلمات کلیدی: الگوریتم متاهوریستیک - بهینه‌سازی - تحلیل تطبیقی - مسائل صنعتی و مالی

^۱ دانشجوی دکتری مدیریت صنعتی، گروه مدیریت صنعتی، تحقیق در عملیات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران، Alirezabkr@gmail.com

^۲ استاد، گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران، (نویسنده مسئول)، Toloie@srbiau.ac.ir

^۳ استادیار، گروه مدیریت صنعتی، دانشکده مدیریت، واحد کرج، دانشگاه آزاد اسلامی، کرج، ایران، Poorebrahimi@gmail.com

^۴ استادیار، گروه مدیریت صنعتی و تکنولوژی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران، ahmad.ebrahimi@srbiau.ac.ir

مقدمه

در عصر حاضر بهینه‌سازی‌های صنعتی و مالی نقش بسزایی دارد. در همین راستا، الگوریتم‌های متاهیوریستیک به دلیل نقش مهم و قابلیت‌های فراوان در حل مسائل بهینه‌سازی پیچیده، توجه بسیاری از محققان و صنعتگران جهان را به خود جلب کرده است. این الگوریتم‌ها با تقلید از رفتارهای طبیعی و اجتماعی، سعی در یافتن بهترین یا تقریباً بهترین جواب‌ها برای مسائل را دارد. از جمله مهم‌ترین این الگوریتم‌ها می‌توان به الگوریتم ژنتیک^۱، بهینه‌سازی ازدحام ذرات^۲ و شبیه‌سازی تبرید^۳، اشاره نمود. الگوریتم ژنتیک با الهام از تکامل طبیعی، از طریق انتخاب، ترکیب و جهش، به دنبال یافتن بهترین جواب است و در مسائل مختلف مهندسی و علوم کاربرد دارد. (۱، ۲). الگوریتم بهینه‌سازی ازدحام ذرات با الهام از رفتار اجتماعی پرندگان و ماهی‌ها، از طریق تعامل ذرات در فضای جستجو، به بهبود جواب‌ها می‌پردازد. این روش به دلیل سادگی و کارایی بالا، به ویژه در مسائل بهینه‌سازی پیوسته، بسیار پرکاربرد است (۳، ۴). الگوریتم شبیه‌سازی تبرید با الهام از فرآیند سرد کردن مواد تا حالت جامد کریستالی، با کاهش تدریجی دما و جستجو در فضای جواب‌ها، بهبود راه‌حل‌ها را در مسائل بهینه‌سازی ترکیبی هدف قرار می‌دهد (۵). پیشینه پژوهش، کاربرد گسترده الگوریتم‌های متاهیوریستیک، در حل مسائل بهینه‌سازی صنعتی و مالی از قبیل برنامه ریزی تولید^۴، مدیریت زنجیره تأمین، تخصیص بودجه‌های مالی و صنعتی، بهینه‌سازی شاخص‌های مالی^۵، مدیریت ریسک و پیش‌بینی‌های مالی، نشان می‌دهد (۶). بعنوان نمونه، ایجاد یک سبد سرمایه‌گذاری بهینه، با متعادل کردن ریسک و بازده، از الگوریتم‌های GA و PSO برای یافتن بهترین تخصیص دارایی استفاده می‌کند. (۷). پیش‌بینی‌های مالی دقیق برای تصمیم‌گیری در سرمایه

و مدیریت ریسک و مخاطرات، ضروری است (۸). راوی و همکاران، در سال ۲۰۱۷، استفاده از شبکه‌های عصبی آموزش دیده با ازدحام ذرات^۶ در پیش‌بینی نوسانات از سری‌های زمانی مالی را پیشنهاد داده‌اند (۹). برنامه‌ریزی تولید برای بهینه‌سازی منابع و دستیابی به اهداف تولیدی بسیار مهم است. رحمان و همکاران (۲۰۱۹) با تأکید بر اهمیت الگوریتم‌های PSO و GA ، از سیستم دوگانه $PSO-GA$ برای پذیرش همزمان سفارش‌ها و تصمیم‌گیری‌های زمان‌بندی استفاده کرده‌اند (۱۰). بهینه‌سازی شبکه‌های زنجیره تأمین شامل تصمیمات پیچیده‌ای در مورد موجودی، حمل و نقل، و توزیع است که الگوریتم‌های متاهیوریستیک راه‌حل‌های مؤثری ارائه می‌دهند. عبدی و همکاران در سال ۲۰۱۹ از مجموعه‌ای از الگوریتم‌های کالبره شده مانند GA ، PSO ، WOA و SA برای حل مدل‌های زنجیره تأمین استفاده کردند. (۱۱). وزیری و همکاران در سال ۲۰۲۳ با استفاده از الگوریتم‌های متاهیوریستیک ژنتیک، ازدحام ذرات، و گرگ خاکستری، ریسک سیستم بانکی را ارزیابی کردند. (۱۲). هیچ الگوریتم متاهیوریستیکی نمی‌تواند در همه شرایط بهترین نتایج را ارائه دهد؛ طبق تئوری "*No Free Lunch*"، هیچ الگوریتمی به‌طور کلی در تمام مسائل بهینه‌سازی برتر نیست. (۱۳). برای هر مسئله خاص، انتخاب الگوریتم بهینه‌سازی باید با توجه به ویژگی‌های آن مسئله انجام شود. بررسی و مقایسه عملکرد الگوریتم‌ها برای شناسایی نقاط قوت و ضعف هر یک ضروری است. درک مزایای نسبی روش‌های مختلف و استفاده از تکنیک‌های ترکیبی در طراحی و بهینه‌سازی الگوریتم‌ها مهم است. (۱۴). نوآوری این پژوهش در تحلیل تطبیقی الگوریتم‌های متاهیوریستیک بر اساس تئوری "*No Free Lunch*" است که به شناسایی نقاط قوت و ضعف الگوریتم‌ها در مسائل صنعتی و مالی کمک می‌کند. سوال اصلی پژوهش نحوه

^۱ Genetic Algorithm (GA)^۲ Particle swarm optimization (PSO)^۳ Simulated Annealing (SA)^۴ Product Schedule^۵ Portfolio^۶ PSOQRNN

Selection (انتخاب): انتخاب افراد بر اساس تابع

برازش برای تولید نسل‌های جدید (رابطه ۳)

$$P_i = \frac{f(x_i)}{\sum f(x_j)}$$

که در آن P_i احتمال انتخاب فرد i و $f(x_i)$ تابع برازش فرد i است.

Crossover (تقاطع): ترکیب ژن‌های دو والد برای

تولید فرزندان جدید (رابطه ۴)

$$C_{ij} = \text{crossover}(P_i, P_j)$$

که در آن C_{ij} نتیجه تقاطع مابین دو والد P_i و P_j است.

Mutation (جهش): تغییر تصادفی برخی از ژن‌ها

برای افزایش تنوع ژنتیکی

$$M_i = \text{Mutation}(C_i)$$

که در آن M_i نتیجه جهش بر روی فرزند C_i است.

الگوریتم شبیه‌سازی تبرید SA: شبیه‌سازی تبرید

الگوریتمی قدرتمند و انعطاف‌پذیر است که فرآیند تبرید را تقلید می‌کند. با پذیرش احتمالی راه‌حل‌های بدتر برای اجتناب از بهینه‌های محلی و کاهش آهسته دما، عملکرد خود را برای حل مسائل پیچیده بهبود می‌بخشد (۱۶). احتمال پذیرش یک راه‌حل بدتر با استفاده از (رابطه ۵) زیر تعیین می‌شود:

$$P(E, E_{\text{new}}, T) = \exp \frac{-(E_{\text{new}} - E)}{T}$$

که در آن E ، انرژی (یا هزینه) فعلی راه‌حل است،

E_{new} ، انرژی راه‌حل جدید است، و T دمای فعلی

سیستم است. دمای T به تدریج بر اساس یک

برنامه‌ریزی خنک‌کننده کاهش می‌یابد که معمولاً به

صورت زیر بیان می‌شود (رابطه ۶):

$$T_{k+1} = \alpha T_k$$

که در آن T_k دما در تکرار k است، و α ($0 < \alpha < 1$) نرخ

خنک‌شدن است. با کاهش تدریجی دما، SA احتمال

پذیرش راه‌حل‌های بدتر را کاهش داده و خطر گیر افتادن

بهره‌برداری از مزایای الگوریتم‌ها و تنظیم پارامترها بر اساس معیارهای ارزیابی است. روند پژوهش شامل معرفی الگوریتم‌ها، راه‌اندازی و اجرای الگوریتم‌ها در بستر مسایل عنوان شده و تحلیل تطبیقی نتایج است.

روش پژوهش: در این بخش، روش‌ها، پارامترها و

معیارهای ارزیابی الگوریتم‌های متاهوریستیک مبتنی بر فیزیک و جمعیت بررسی می‌شود.

الگوریتم بهینه‌سازی ازدحام ذرات PSO: الگوریتم

گروهی از ذرات را شبیه‌سازی می‌کند که هر ذره نمایانگر یک راه‌حل بالقوه است. (۳). ذرات موقعیت خود را بر اساس بهترین تجربه شخصی و جهانی تنظیم می‌کنند و وزن اینرسی سرعت قبلی را کنترل کرده و روند کاوش را متعادل می‌کند.

بروز رسانی سرعت (رابطه ۱):

$$v_i(t+1) = w \cdot v_i(t) + c1 \cdot r1 \cdot (p_i(t) - x_i(t)) + c2 \cdot r2 \cdot (g(t) - x_i(t))$$

بروز رسانی موقعیت (رابطه ۲):

$$x_i(t+1) = x_i(t) + v_i(t+1)$$

در این معادلات، $v_i(t)$ سرعت ذره i در تکرار t ، w به وزن اینرسی که تأثیر سرعت قبلی را کنترل می‌کند، $c1$ و $c2$ ضرایب شناختی و اجتماعی، $r1$ و $r2$ ، اعداد تصادفی بین صفر و یک، $p_i(t)$ ، بهترین موقعیت ذره i ، $g(t)$ بهترین موقعیت جهانی (در ازدحام) و $x_i(t)$ به موقعیت فعلی ذره i اشاره دارد.

الگوریتم ژنتیک GA: این الگوریتم با استفاده از

عملیات‌های ژنتیکی مانند تقاطع، انتخاب، و جهش،

به‌طور مؤثر به یافتن راه‌حل‌های بهینه یا نزدیک به بهینه

برای مسائل پیچیده می‌پردازد. (۱۵). در الگوریتم ژنتیک،

جمعیتی از کاندیداها با استفاده از تابع برازش ارزیابی

شده و فرآیند تکاملی با استفاده از معادلات مشخص انجام

می‌شود.

در بهینه‌های محلی را کم کرده و به حالت حداقل انرژی نزدیک می‌شود.

بهینه سازی تولید: برای بررسی بهینه‌سازی تولید، هزینه‌های یک سیستم تولیدی با استفاده از تابع مشخص محاسبه شده است.

$$f = \sum_{i=1}^3 (Production_i * Cost_i)$$

این تابع به منظور محاسبه مجموع هزینه‌های تولید در سه دوره مختلف طراحی شده است. در این تابع، $Production_i$ نمایانگر مقدار تولید در دوره i و $Cost_i$ نمایانگر هزینه مرتبط با تولید در همان دوره است. با استفاده از علامت جمع $\sum$ ، هزینه‌های تولید در هر سه دوره محاسبه و سپس با هم جمع می‌شود تا هزینه کل تولید به دست آید (۱۷).

بهینه سازی مالی: برای بهینه‌سازی مالی، مدل‌هایی برای مدیریت تعادل بین بازده و ریسک در سرمایه‌گذاری‌ها ضروری است. هدف معمولاً یافتن بهترین ترکیب دارایی‌هاست که بازده را حداکثر و ریسک را حداقل کند. (۱۷، ۱۸). برای این منظور از تابع بهینه سازی مالی زیر استفاده شد:

$$f = - \sum_{i=1}^4 Returns_i + \sum_{i=1}^4 Risks_i$$

این تابع برای ارزیابی و بهینه‌سازی ترکیبی از بازده و ریسک در چهار دوره یا سناریو مختلف طراحی شده است. در این تابع $Returns_i$ نمایانگر بازده یا سود حاصل از سرمایه‌گذاری در دوره i و $Risks_i$ نمایانگر ریسک یا عدم اطمینان مرتبط با هر دوره است. علامت منفی نشان‌دهنده این است که تابع به کاهش بازده‌ها توجه دارد و علامت $\sum$ به جمع‌آوری و ارزیابی مجموع ریسک‌ها می‌پردازد. هدف این تابع بهینه‌سازی، دستیابی به تعادل مطلوب در تصمیمات سرمایه‌گذاری با کاهش بازده‌ها و کنترل ریسک‌ها است و می‌تواند در مدل‌های بهینه‌سازی مالی برای پیدا کردن ترکیبی بهینه از دارایی‌ها به کار رود.

کنترل موجودی: تابع $f = \sum_{i=1}^4 (Demands_i * Inventory_Costs_i)$ محاسبه مجموع

هزینه‌های موجودی در چهار دوره مختلف می‌پردازد. در این تابع، $Demands_i$ نمایانگر مقدار تقاضا برای کالا یا خدمات در دوره i و $Inventory_Costs_i$ نمایانگر هزینه‌های مرتبط با نگهداری موجودی در همان دوره است. این تابع هزینه‌های موجودی را برای هر دوره محاسبه کرده و جمع می‌کند تا هزینه کل موجودی در تمام دوره‌ها به دست آید. این تابع به تحلیل و بهینه‌سازی مدیریت موجودی کمک کرده و می‌تواند در کاهش هزینه‌ها مفید باشد. (۱۷، ۱۹).

مسیریابی وسیله نقلیه: برای محاسبه مجموعه هزینه های حمل و نقل و جا به جایی از تابع $f = \sum_{i=1}^3 (Distance_i * Cost_i)$ استفاده شده است. این تابع، نقش کلیدی در مسیریابی وسایل نقلیه ایفا می‌کند (۱۷، ۲۰). این تابع هزینه‌های جابه‌جایی در مسائل مسیریابی وسایل نقلیه را بر اساس مسافت‌ها و هزینه‌های هر واحد مسافت محاسبه کرده و به تعیین مسیرهای بهینه برای کاهش هزینه‌ها و افزایش کارایی حمل و نقل کمک می‌کند.

اجرا و پیاده سازی الگوریتم‌ها: برای پیاده‌سازی و مقایسه الگوریتم‌های مذکور، از پارامترها و معیارهای یکسانی استفاده شد. هر الگوریتم در ۳۰ آزمایش و ارزیابی با حداکثر ۱۰۰۰ تکرار و ۸ متغیر بررسی شد. همچنین، محدودیت‌های بالا و پایین به ترتیب بر روی ۱۰ و ۰ تنظیم شد. توابع و معیارهای ارزیابی عملکرد الگوریتم‌ها به ترتیب در جدول‌های (۱) و (۲)، تبیین شده است. برای پیاده‌سازی و اجرای الگوریتم‌ها از نرم‌افزار متلب نسخه $R2020a$ استفاده خواهد شد (۲۱). این نرم‌افزار به دلیل امکانات گسترده در زمینه محاسبات عددی و تحلیل داده‌ها، ابزار مناسبی برای این نوع پژوهش‌ها می‌باشد.

جدول ۱ توابع آزمون	
توابع (فرمولها)	شرح توابع
$f = \sum_{i=1}^3 (Production_i * Cost_i)$	بهینه سازی تولید
$f = - \sum_{i=1}^4 Returns_i + \sum_{i=1}^4 Risks_i$	بهینه سازی مالی
$f = \sum_{i=1}^4 (Demands_i * Inventory_Costs_i)$	کنترل موجودی
$f = \sum_{i=1}^3 (Distance_i * Cost_i)$	مسیریابی وسیله نقلیه

جدول ۲ معیارهای ارزیابی	
معیارها	ویژگی معیارها
میانگین تابع هدف	میانگین مقادیر تابع هدف که نشان‌دهنده کارایی الگوریتم در یافتن جواب‌های بهینه است.
انحراف معیار تابع هدف	نشان‌دهنده پایداری الگوریتم در ارائه جواب‌های بهینه.
نرخ موفقیت	درصد مواردی که الگوریتم توانسته به جواب بهینه برسد.
میانگین زمان همگرایی	میانگین زمانی که الگوریتم برای رسیدن به جواب بهینه نیاز دارد.
دقت	نسبت جواب‌های به دست آمده که به جواب بهینه نزدیک هستند.
تنوع جمعیت	میزان تنوع در جواب‌های به دست آمده توسط الگوریتم.
پایداری	میزان پایداری الگوریتم در ارائه جواب‌های مشابه.
کیفیت جواب	کیفیت نهایی جواب‌های به دست آمده توسط الگوریتم.
تعداد جواب‌های بهینه	تعداد جواب‌های بهینه پیدا شده توسط الگوریتم.


مقایسه می نماید. مقایسه بر اساس چندین معیار انجام گردیده است که در شکل (۱)، وجوه بصری آن به تصویر درآمده است. در این شکل، مقایسه‌ای از الگوریتم‌های ژنتیک (GA)، بهینه‌سازی ازدحام ذرات (PSO)، و شبیه‌سازی تبرید (SA) برای مسئله بهینه‌سازی تولید ارائه شده است.

بحث و بررسی: این مطالعه عملکرد سه الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و شبیه‌سازی تبرید را در چهار مسئله بهینه‌سازی بررسی کرده و از جنبه‌های دقت، زمان همگرایی، کیفیت راه‌حل و نرخ موفقیت مقایسه و ارزیابی و تحلیل کرده است.

مقایسه الگوریتم‌ها در تابع بهینه‌سازی تولید^۱:

جدول (۳) عملکرد سه الگوریتم بهینه‌سازی مختلف را

^۱ Product Optimization



شکل ۱ مقایسه جامع عملکرد چهار الگوریتم GA ، PSO و SA در مساله بهینه‌سازی تولید مبتنی بر نمودارهای میانگین و انحراف معیار- نمودار جعبه‌ای (Box Plot)- نمودار پراکندگی (Scatterplot)- ماتریس همبستگی (Correlation matrix).

ژنتیک (GA) به عنوان یک روش بهینه‌سازی، با کسب میانگین هدف نزدیک به صفر ($4.1331e-08$) و انحراف معیار بسیار پایین ($1.0621e-07$)، برتری قابل توجهی از نظر کیفیت راه‌حل‌ها و ثبات دارد. این الگوریتم در تحقق دقت کامل ($Accuracy=1$) و میزان موفقیت کامل ($Success Rate=1$) بسیار موفق عمل کرده و توانسته است با کمترین تنوع جمعیت (1.6554) و پایداری (وضعیت $Stability=1.0621e-07$) راه‌حل‌های بهینه‌ای ارائه دهد. PSO ، علی‌رغم کسب موفقیت کامل در یافتن راه‌حل‌های بهینه ($Success Rate=1$) و دقت کامل ($Accuracy=1$)، از نظر کیفیت راه‌حل‌ها و مقاومت در موقعیت‌های مختلف مشکلاتی دارد. میانگین هدف صفر (۰) و انحراف معیار صفر (۰) در PSO نشان‌دهنده عملکرد ایده‌آل در یافتن نتایج هدف است، اما به دلیل ناپایداری کامل ($Stability=0$) و عدم وجود کیفیت و مقاومت ($Robustness=0$) در نتایج، این الگوریتم نتوانسته به همان میزان موفقیت و پایداری که GA داشته، دست یابد. علاوه بر این، تنوع جمعیت (3.4164) PSO بیشتر از

نمودار انحراف معیار نشان می‌دهد که GA کمترین انحراف معیار را دارد، PSO کمی بیشتر و SA بیشترین انحراف معیار را دارد، که به عملکرد برتر GA و تغییرپذیری بالا در SA اشاره دارد. نمودار جعبه‌ای عملکرد منسجم GA و PSO را با جعبه‌های فشرده نشان می‌دهد، در حالی که SA جعبه بزرگ‌تر و داده‌های دورافتاده دارد که نشان‌دهنده عدم انسجام آن است. نمودار پراکندگی نشان می‌دهد که GA و PSO مقادیر تابع هدف نزدیک به صفر دارند، در حالی که SA تغییرپذیری بیشتری دارد و گاهی مقادیر بالاتری را نشان می‌دهد. ماتریس همبستگی همبستگی متوسط بین GA و PSO و کم‌ترین همبستگی بین SA و دو الگوریتم دیگر را نشان می‌دهد. به‌طور کلی، GA و PSO عملکرد منسجم‌تری دارند، با برتری جزئی GA ، در حالی که SA به دلیل تغییرپذیری بالا کمتر قابل اعتماد است.

بررسی دقیق‌تر نتایج جدول ۳، به‌طور واضح تمایزات قابل توجهی را در عملکرد آن‌ها نشان می‌دهد. الگوریتم

مقایسه الگوریتم‌ها در تابع بهینه‌سازی مالی^۱: جدول (۴) و شکل (۲) عملکرد سه الگوریتم بهینه‌سازی *GA*، *PSO* و *SA* را در یک تابع مالی ارزیابی کرده‌اند. *GA* و *PSO* به کمترین مقدار تابع هدف یعنی ۴۰- با انحراف معیار ناچیز دست یافته‌اند که نشان‌دهنده پایداری عملکرد آن‌هاست. در مقابل، *SA* با میانگین ۳۲٫۵- و انحراف معیار بزرگتر (۳۵- تا ۳۰-) تغییرپذیری بیشتری را نشان می‌دهد. نمودارها نیز این تفاوت‌ها را تأیید می‌کنند. ماتریس همبستگی، همبستگی کامل بین *GA* و *PSO* و همبستگی کم بین این دو الگوریتم و *SA* را نشان می‌دهد. در نتیجه، *GA* و *PSO* برای این مسئله بهینه‌سازی مالی مناسب‌تر و پایدارتر هستند، در حالی که *SA* عملکرد ضعیف‌تر و متغیرتری دارد.

GA است، که ممکن است به بهبود قابلیت اکتشاف فضای جستجو کمک کند، اما در عمل منجر به نتایج کمتر قابل اعتماد شده است. الگوریتم *SA*، تفاوت‌های بیشتری نسبت به دو الگوریتم دیگر دارد. این الگوریتم با وجود داشتن بهینه‌های متعدد (۲۹)، از نظر موفقیت کلی ($Success\ Rate=0$) و مقاومت ($Robustness=0.0079449$) و کیفیت راه‌حل ($Solution\ Quality=0.0049817$) عملکرد ضعیفی را نشان می‌دهد. تنوع جمعیت در *SA* با *PSO* برابری می‌کند، اما به دلیل کم بودن دقت و کیفیت راه‌حل‌ها، نمی‌تواند به عنوان یک گزینه بهینه در مقایسه با *GA* در نظر گرفته شود. در نتیجه، با توجه به کیفیت راه‌حل، دقت و پایداری، *GA* می‌تواند بهترین عملکرد را در میان الگوریتم‌های مورد بررسی ارائه دهد.

جدول ۳ نتایج پیاده‌سازی الگوریتم در تابع بهینه‌سازی تولید


Metric	GA	PSO	SA
Mean Objective	4.13E-08	0	0.0049817
Std Objective	1.06E-07	0	0.0079449
Success Rate	1	1	0
Mean Convergence Time	2.2647	4.4311	4.6111
Accuracy	1	1	0.033333
Population Diversity	1.6554	3.4164	3.4775
Stability	1.06E-07	0	0.0079449
Solution Quality	4.13E-08	0	0.0049817
Robustness	1.06E-07	0	0.0079449
Multiplicity of Optimal Solutions	17	0	29

جدول ۴ نتایج پیاده‌سازی الگوریتم‌ها در تابع بهینه‌سازی مالی

Metric	GA	PSO	SA
Mean Objective	-39.9988	-40	-32.4632
Std Objective	0.0011716	0	2.672
Success Rate	1	1	1
Mean Convergence Time	0.00029871	0	1.1081
Accuracy	0.033333	1	0.033333
Population Diversity	0.00031705	0	1.1627
Stability	0.0011716	0	2.672
Solution Quality	-39.9988	-40	-32.4632

^۱ Financial optimization

Robustness	0.0011716	0	2.672
Multiplicity of Optimal Solutions	29	0	29



شکل ۲ مقایسه جامع عملکرد چهار الگوریتم GA، PSO و SA در مساله بهینه سازی مالی مبتنی بر نمودارهای میانگین و انحراف معیار- نمودار جعبه ای (Box Plot)- نمودار پراکندگی (Scatterplot)- ماتریس همبستگی (Correlation matrix)

(GA) و بهینه‌سازی ازدحام ذرات (PSO) در کنترل موجودی عملکرد بهتری نسبت به شبیه‌سازی تبرید (SA) دارند GA و PSO با میانگین نزدیک به صفر و انحراف معیار کم، نتایج پایدارتری ارائه می‌دهند، در حالی که SA میانگین بالاتر و انحراف معیار بزرگ‌تری دارد. نمودارهای جعبه‌ای و پراکندگی نیز نشان‌دهنده توزیع و عملکرد بهتر GA و PSO هستند. همچنین، همبستگی قوی بین GA و PSO نشان‌دهنده شباهت عملکرد آنها است، در حالی که SA همبستگی کمی با این دو الگوریتم دارد. در نتیجه، GA و PSO برای مسائل کنترل موجودی ترجیح داده می‌شوند.

بررسی دقیق معیارهای هر سه الگوریتم با توجه به جدول (۵)، تفاوت‌های قابل توجهی در کیفیت و ویژگی‌های عملکردی هر یک از الگوریتم‌ها، نشان می‌دهد. الگوریتم ژنتیک با دقت با میانگین و انحراف معیار بسیار کم، دقت قابل قبولی در رسیدن به مقادیر نزدیک به بهینه را دارد.

تحلیل عملکرد الگوریتم‌ها بر روی تابع مالی نشان‌دهنده تفاوت‌های قابل توجهی است. الگوریتم ژنتیک (GA) با میانگین هدف ۳۹,۹۹۸۸- و انحراف معیار کم، در ارائه راه‌حل‌های پایدار موفق بوده، اما دقت پایین و تنوع جمعیت محدودش، اکتشاف فضای جستجو را کاهش داده است. الگوریتم PSO با دقت و کیفیت بالاتر، به میانگین هدف ۴۰- بدون پراکندگی رسیده، اما مشکلاتی در اکتشاف و انطباق در محیط‌های متغیر دارد. در مقابل، SA با میانگین هدف ۳۲,۴۶۳۲- و انحراف معیار بالا، زمان همگرایی طولانی‌تر و دقت پایین‌تر، کیفیت نتایج ضعیف‌تری ارائه داده، هرچند در اکتشاف فضای جستجو برتری دارد. در نهایت، PSO بهینه‌ترین عملکرد را دارد، در حالی که GA در سرعت همگرایی و SA در اکتشاف فضای جستجو برتری‌های خود را نشان می‌دهند.

مقایسه الگوریتم‌ها در تابع کنترل موجودی^۱:

تحلیل نتایج نشان می‌دهد که الگوریتم‌های ژنتیک

^۱ Inventory control

نرخ موفقیت و دقت (۰,۹) به خوبی نشان می‌دهد که *GA* در اکثر موارد به راه‌حل‌های بهینه دست یافته و توانایی حفظ کیفیت نتایج را دارد. با این حال، تنوع جمعیت نسبتاً پایین (۱,۰۹۶۷) ممکن است به محدودیت‌هایی در کشف فضای جستجو منجر شود و سبب همگرایی بهینه‌ها به حداقل‌های محلی گردد. این الگوریتم با زمان همگرایی متوسط (۰,۴۸۸۸۲) ثانیه و ثبات بالا در نتایج، به خوبی عملکرد خود را در شرایط مختلف نشان می‌دهد، هرچند که در مقایسه با *PSO* و *SA* از نظر دقت و کیفیت نتایج به طور نسبی ضعیف‌تر است. الگوریتم *PSO* با میانگین هدف صفر و انحراف معیار صفر، بالاترین دقت را در میان الگوریتم‌های بررسی شده ارائه می‌دهد که نشان‌دهنده توانایی بالای این الگوریتم در یافتن نتایج بهینه است. نرخ موفقیت کامل یک و دقت عالی یک نیز تأکید بر عملکرد برتر *PSO* در دستیابی به بهینه‌ها دارد. تنوع جمعیت بالا (۳,۳۷۹۱) نیز نشان‌دهنده قابلیت *PSO* در جستجوی وسیع‌تر در فضای راه‌حل است، اما عدم ثبات (با مقدار صفر)


نشان‌دهنده ضعف‌های این الگوریتم در کنترل تغییرات و نوسانات در نتایج است. زمان همگرایی *PSO* با مقدار (۱,۶۷۱۶) ثانیه نسبتاً طولانی‌تر است که ممکن است به دلیل جستجوی عمیق‌تر در فضای راه‌حل باشد. الگوریتم *PSO* با دقت و کیفیت بالای نتایج، برتر از *GA* است، اما با چالش‌هایی در زمینه تنوع و ثبات مواجه است. الگوریتم شبیه‌سازی تبرید (*SA*) عملکرد ضعیف‌تری نسبت به *GA* و *PSO* دارد، با میانگین هدف پایین‌تر، انحراف معیار بالا، نرخ موفقیت صفر و زمان همگرایی طولانی‌تر. هرچند *SA* در کشف فضای جستجو تنوع بالایی دارد، اما به دلیل عدم ثبات، نتایج با کیفیتی ارائه نمی‌دهد.

در مجموع، *PSO* و *GA* بهترین عملکرد را در میان الگوریتم‌های بررسی‌شده نشان می‌دهند. بر این اساس الگوریتم *SA*، با وجود تنوع جمعیت بالا، به دلیل کیفیت پایین‌تر نتایج و زمان همگرایی طولانی‌تر، عملکرد ضعیف‌تری را ارائه می‌دهد.

جدول ۵ نتایج پیاده‌سازی الگوریتم‌ها در تابع بهینه‌سازی کنترل موجودی

Metric	GA	PSO	SA
Mean Objective	4.93e-07	0	0.10704
Std Objective	1.70e-06	0	0.15239
Success Rate	0.9	1	0
Mean Convergence Time	0.48882	1.6716	2.0929
Accuracy	0.9	1	0.033333
Population Diversity	1.0967	3.3791	3.4315
Stability	1.70e-06	0	0.15239
Solution Quality	4.93e-07	0	0.10704
Robustness	1.70e-06	0	0.15239
Multiplicity of Optimal Solutions	15	0	29

می‌کنند، در حالی که SA تغییرپذیری زیادی دارد.



نکته ۳ مقایسه جامع عملکرد چهار الگوریتم GA، PSO و SA در مساله کنترل موجودی بر نمودارهای میانگین و انحراف معیار- نمودار جعبه ای (Box Plot)- نمودار پراکندگی (Scatterplot)- ماتریس همبستگی (Correlation matrix)

ماتریس همبستگی نیز حاکی از همبستگی مثبت بالای

بین GA و PSO و همبستگی کم بین SA و دیگر الگوریتم‌ها است. به طور کلی، GA و PSO با عملکرد پایدار و قابل اعتماد، در این مسئله نسبت به SA برتری دارند. آنالیز جزئیات نتایج (جدول ۶)، تفاوت‌های عملکردی جزئی و متمایز کننده‌ای را ارائه می‌دهد. الگوریتم PSO در تابع مسیریابی نقلیه، با میانگین هدف صفر و انحراف معیار صفر، برترین عملکرد را در دقت و کیفیت نتایج ارائه می‌دهد. نرخ موفقیت و دقت کامل (۱)، نشان‌دهنده توانایی فوق‌العاده PSO در یافتن دقیق‌ترین و بهینه‌ترین نتایج است. با این حال، طولانی‌تر بودن زمان همگرایی (۱,۳۷۹۶ ثانیه) نسبت به GA و نبود تنوع جمعیت، که می‌تواند به نقص‌هایی در کشف فضای جستجو منجر شود، از جمله محدودیت‌های این الگوریتم است. الگوریتم ژنتیک با میانگین و انحراف معیار بسیار

مقایسه الگوریتم‌ها در تابع مسیریابی وسیله

نقلیه^۱: در جدول (۶) نتایج چهار الگوریتم بهینه‌سازی بر تابع مسیریابی وسیله نقلیه، ارائه گردیده است. تحلیل میانگین و انحراف معیار نشان می‌دهد که GA کمترین میانگین مقدار تابع هدف نزدیک به صفر و کمترین تغییرپذیری را دارد، در حالی که PSO با میانگین کمی بالاتر اما همچنان نزدیک به صفر قرار دارد. SA بالاترین میانگین و بزرگترین انحراف معیار را نشان می‌دهد که بیانگر تغییرپذیری قابل توجه عملکرد است. نمودار جعبه‌ای نشان می‌دهد که توزیع‌های GA و PSO نزدیک به صفر و متراکم هستند و عملکرد ثابتی را منعکس می‌کنند، در حالی که SA توزیع وسیع‌تری با تغییرپذیری بیشتر و چندین نقطه دورافتاده با مقادیر هدف بسیار بالا دارد. نمودار پراکندگی نشان می‌دهد که GA و PSO مقادیر پایینی را به‌طور مداوم تولید

^۱ Vehicle Routing

نزدیک به صفر، در یافتن راه حل‌های بهینه توانمند است هرچند که در مقایسه با PSO از دقت و کیفیت کمتری برخوردار است. زمان همگرایی پایین‌تر (0.47872) ثانیه و تنوع جمعیت (1.2341)، به GA کمک می‌کند تا به سرعت به نتایج قابل قبولی برسد، اما این تنوع کم ممکن است به محدودیت‌هایی در بررسی کامل فضای جستجو منجر شود.

الگوریتم SA با میانگین هدف 0.089702 و انحراف معیار بالا (0.12164) کیفیت نتایج پایین‌تری نسبت به

PSO و GA دارد. نرخ موفقیت صفر و دقت پایین (0.000000) ضعف‌های این الگوریتم در یافتن نتایج بهینه را نشان می‌دهد. گرچه تنوع جمعیت بالا (3.405) ممکن است به کشف فضای جستجو کمک کند، زمان همگرایی طولانی (3.3688 ثانیه) به عملکرد ضعیف SA نسبت به GA و PSO اشاره دارد. به‌طور کلی، PSO با کیفیت و دقت بالای نتایج، بهترین گزینه است، در حالی که GA و SA در دقت، کیفیت نتایج و سرعت همگرایی تفاوت‌های مشخصی دارند.

جدول ۶ نتایج الگوریتم‌ها در تابع بهینه‌سازی مسیره‌های نقلیه

Metric	GA	PSO	SA
Mean Objective	4.71e-06	0	0.089702
Std Objective	1.72e-05	0	0.12164
Success Rate	0.8	1	0
Mean Convergence Time	0.47872	1.3796	3.3688
Accuracy	0.8	1	0.033333
Population Diversity	1.2341	3.3168	3.405
Stability	1.72e-05	0	0.12164
Solution Quality	4.71e-06	0	0.089702
Robustness	1.72e-05	0	0.12164
Multiplicity of Optimal Solutions	20	0	29

تحلیل مقایسه‌ای نقاط قوت و ضعف الگوریتم‌ها:

برای تحلیل مقایسه‌ای جامع و علمی الگوریتم‌های مبتنی بر فیزیک و جمعیت با تمرکز بر نقاط قوت و ضعف آن‌ها، بدون توجه به نرخ همگرایی و مقیاس‌پذیری، می‌توان از تحلیل زیر جدول (۷) استفاده کرد.


الگوریتم‌های مبتنی بر فیزیک، مانند شبیه‌سازی تبرید (SA)، با الگوبرداری از فرآیندهای فیزیکی مانند خنک‌سازی، به جستجوی گسترده در فضای حل می‌پردازند و قادر به یافتن چندین نقطه بهینه هستند. با این حال، SA معمولاً نتایجی با کیفیت و دقت پایین‌تر و زمان همگرایی طولانی‌تر ارائه می‌دهد، که آن را در مسائل نیازمند سرعت و دقت بالا نامناسب می‌کند. در مقابل، الگوریتم‌های مبتنی بر جمعیت مانند PSO و GA ، به دلیل دقت، کیفیت نتایج و زمان همگرایی سریع‌تر، اغلب

در بهینه‌سازی موفق‌تر هستند PSO ، دقت و کیفیت بالایی دارد اما ممکن است در ثبات نتایج و یافتن چندین راه‌حل بهینه محدودیت داشته باشد GA ، نیز به دلیل عملیات‌های ترکیبی و جهشی خود، نتایج با کیفیت بالا تولید می‌کند، اما ممکن است با کاهش تنوع جمعیت مواجه شود. در مجموع، PSO و GA به دلیل عملکرد بهتر در یافتن نتایج بهینه، انتخاب‌های مناسب‌تری در بسیاری از مسائل بهینه‌سازی هستند

تحلیل مقایسه‌ای نتایج الگوریتم‌های متاهوریستیک مبتنی بر فیزیک و جمعیت: نتایج پژوهش بررسی تطبیقی الگوریتم‌های مبتنی بر فیزیک و جمعیت را بر توابع صنعتی و مالی نشان می‌دهد. شکل (۵).

جدول ۷ مقایسه نتایج بر اساس نقاط قوت و ضعف الگوریتم‌ها

نوع الگوریتم	نقاط قوت	نقاط ضعف
الگوریتم‌های مبتنی بر فیزیک (شبهه سازی تبرید)	✓ تنوع بالا: قابلیت بررسی وسیع‌تر فضای جستجو.	❑ کیفیت نتایج پایین‌تر: نتایج بهینه‌تری نسبت به الگوریتم‌های مبتنی بر جمعیت ارائه نمی‌دهد.
	✓ مقاومت در برابر تغییرات: توانایی کار در شرایط مختلف.	❑ دقت پایین: دقت کمتری در یافتن نتایج بهینه دارد.
	✓ تعدد راه‌حل‌های بهینه: قابلیت یافتن چندین راه‌حل بهینه.	❑ زمان همگرایی طولانی: نیاز به زمان بیشتری برای رسیدن به نتایج بهینه دارد.
	✓ دقت بالا: توانایی بالاتر در یافتن نتایج بهینه دقیق.	
الگوریتم‌های مبتنی بر جمعیت (ژنتیک و بهینه سازی ازدحام ذرات)	✓ کیفیت نتایج بهینه: ارائه نتایج بهینه‌تر و با کیفیت بالاتر.	❑ ثبات کمتر (به ویژه در بهینه سازی ازدحام ذرات): نوسانات ممکن در شرایط متغیر.
	✓ زمان همگرایی سریع‌تر: رسیدن سریع‌تر به نتایج بهینه.	❑ محدودیت در تعداد راه‌حل‌های بهینه (به ویژه در بهینه سازی ازدحام ذرات): به یافتن چندین راه‌حل بهینه نیست.
	✓ تنوع مناسب جمعیت: کشف فضای جستجو به شکل بهتری.	



شکل ۴ مقایسه نتایج حاصل از تحلیل تطبیقی الگوریتم‌های PSO-GA-SA در چهار تابع بهینه سازی تولید (Product optimization) - بهینه سازی مالی (Financial optimization) - کنترل موجودی (Inventory control) - وسایل نقلیه (Vehicle routing)، با استفاده از نمودار خطی (Line Plot).

نتایج نشان می‌دهند که الگوریتم PSO در مسائل پیچیده مانند بهینه‌سازی تولید، مالی، کنترل موجودی و مسیریابی خودرو، به دلیل تعادل مناسب بین کاوش و بهره‌برداری و ثبات در تنوع، برتری دارد. الگوریتم GA نیز عملکرد خوبی در بهینه‌سازی تولید از نظر کاوش در فضاها پیچیده و مدیریت محدودیت‌ها و اهداف مختلف نشان می‌دهد. با توجه به ثبات پارامترهای ورودی، الگوریتم ژنتیک (GA) به دلیل توانایی بالا در کاوش فضای جستجو و یافتن بهینه‌های جهانی، و مدیریت مؤثر متغیرهای پیوسته و گسسته، مزیت بیشتری در بهینه‌سازی تابع تولید نسبت به سایر الگوریتم‌ها دارد. GA همچنین قادر به در نظر گرفتن محدودیت‌ها و بهینه‌سازی چند هدفه است (۲۲). بهینه‌سازی با PSO معمولاً برای مسائل پیوسته مناسب‌تر است و ممکن است سریع‌تر از GA همگرا شود، اما ممکن است در بهینه‌های محلی گیر کند و نتواند متغیرهای گسسته را به خوبی مدیریت کند، که در مسائل با مقادیر تولید گسسته نقطه ضعف است (۲۳). الگوریتم تبرید شبیه‌سازی (SA) در اجتناب از بهینه‌های محلی عملکرد خوبی دارد، اما ممکن است نسبت به GA کندتر همگرا شود و معمولاً برای مسائل بهینه‌سازی ترکیبی مناسب‌تر است. همچنین SA ممکن است در بهینه‌سازی چندهدفه مشکلات بیشتری نسبت به GA داشته باشد (۲۴). در مقایسه عملکرد PSO نسبت به دو الگوریتم دیگر در توابع مالی، حمل و نقل و کنترل موجودی، با نگاه به ویژگی‌های توابع مالی (واجد متغیرهای پیوسته با چشم انداز پیچیده و چند بهینه محلی -جدول ۱)، کنترل موجودی (شامل متغیرهای پیوسته یا گسسته مرتبط با هزینه و تقاضا و یک مبادله بین عوامل مختلف هزینه-جدول ۱) و حمل و نقل (مسیریابی وسایل نقلیه با حذف کاهش هزینه‌ها که می‌تواند گسسته یا پیوسته باشد-جدول ۱)، می‌توان دلایل عملکرد بهتر PSO را در مقایسه با سایرین در توانمندی این الگوریتم در مدیریت متغیرهای پیوسته و چند بعدی دانست. روند مذکور در مورد دو تابع تولید و حمل و نقل نیز قابل تفسیر است. در حالی که هر دو تابع از نظر ساختار، ماهیت یکسانی دارد، ولی عملکرد PSO در شرایطی که متغیرهای مسأله بیشتر شده (تابع حمل

و نقل) و فضای پیچیده تری ایجاد می‌شود، نسبت به GA بهتر می‌شود. الگوریتم PSO با حفظ تعادل بین جستجوی جهانی و بهره‌برداری محلی از طریق گروهی از ذرات که بهترین موقعیت‌های خود و گروه را دنبال می‌کنند، به خوبی عمل می‌کند و به جلوگیری از گرفتار شدن در بهینه‌های محلی، دستیابی سریع‌تر به راه‌حل‌های خوب و واکنش مناسب به تغییرات کمک می‌کند (۲۵). در مقابل، GA ممکن است نیاز به کدگذاری پیچیده برای متغیرهای پیوسته داشته باشد و SA با مشکلاتی در مدیریت محدودیت‌ها و سرعت همگرایی روبرو شود. به همین دلیل، PSO به دلیل سادگی در مدیریت فضاها پیوسته و استراتژی‌های جستجوی ذاتی‌اش، برای این مسائل بهینه‌سازی مناسب‌تر است. در تحلیل تطبیقی نتایج، الگوریتم‌های PSO ، GA و SA عملکردهای متفاوتی بر اساس نوع مسئله نشان می‌دهند PSO به دلیل توانایی در تعادل بین جستجوی گسترده و بهره‌برداری، به ویژه در مسائل با متغیرهای پیوسته مانند بهینه‌سازی مالی و مسیریابی خودرو، عملکرد بهتری دارد و از گرفتار شدن در بهینه‌های محلی جلوگیری می‌کند GA در کاوش فضاها پیچیده و مدیریت متغیرهای گسسته و پیوسته، به ویژه در مسائل چندهدفه مانند بهینه‌سازی تولید، موفق است، اما ممکن است در مسائل پیوسته نیاز به کدگذاری پیچیده داشته باشد SA با وجود توانایی در اجتناب از بهینه‌های محلی، سرعت همگرایی کمتری دارد و در مسائل چندهدفه و مدیریت محدودیت‌های پیچیده با چالش‌هایی روبرو است. این تفاوت‌ها تئوری *No Free Lunch* را تأیید می‌کنند که هیچ الگوریتمی نمی‌تواند در همه مسائل بهینه‌سازی برتر باشد و موفقیت هر الگوریتم به تطابق آن با نوع و پیچیدگی مسئله بستگی دارد.

نتیجه‌گیری و پیشنهادات:

در دنیای امروز، بهینه‌سازی ابزار کلیدی در مهندسی، اقتصاد و مدیریت است و الگوریتم‌های متاهوریستیک مختلف برای حل مسائل پیچیده به کار می‌روند. این مطالعه چهار تابع بهینه‌سازی واقعی را تعریف کرده و الگوریتم‌های GA ، PSO و SA را با پارامترهای

Rajwar K, Deep K, Das S. An exhaustive review of the metaheuristic algorithms for search and optimization: taxonomy, applications, and open challenges. *Artificial Intelligence Review*. 2023;56(11):13187-257.

Kuo R, Hong C. Integration of genetic algorithm and particle swarm optimization for investment portfolio optimization. *Applied mathematics & information sciences*. 2013;7(6):2397.

Thakkar A, Chaudhari K. A comprehensive survey on portfolio optimization, stock price and trend prediction using particle swarm optimization. *Archives of Computational Methods in Engineering*. 2021;28(4):2133-64.

Pradeepkumar D, Ravi V. Forecasting financial time series volatility using particle swarm optimization trained quantile regression neural network. *Applied Soft Computing*. 2017;58:35-52.

Rahman HF, Janardhanan MN, Nielsen IE. Real-time order acceptance and scheduling problems in a flow shop environment using hybrid GA-PSO algorithm. *IEEE Access*. 2019;7:112742-55.

Abdi A, Abdi A, Fathollahi-Fard AM, Hajiaghahi-Keshteli M. A set of calibrated metaheuristics to address a closed-loop supply chain network design problem under uncertainty. *International Journal of Systems Science: Operations & Logistics*. 2021;8(1):23-40.

Vaziri E, Dehdar F, Abdoli MR. Feasibility study of using metaheuristic algorithms on optimizing of the integrated risk in banking system. *International Journal of Finance &*

تنظیم‌شده بررسی کرده است. نتایج نشان می‌دهند که GA و PSO معمولاً در معیارهایی مانند میانگین، ارزش هدف، و زمان همگرایی عملکرد بهتری دارند، در حالی که SA در یافتن چندین راه‌حل بهینه و حفظ تنوع جمعیت برتری دارد. همچنین، عملکرد الگوریتم‌ها بر اساس پیچیدگی مسئله و ویژگی‌های آن متفاوت است. PSO در مسائل با فضای جستجوی بزرگ‌تر و نیاز به همگرایی سریع‌تر عملکرد بهتری دارد، GA در مسائل با فضای جستجوی محدودتر و نیاز به کاوش عمیق‌تر مؤثرتر است، و SA به طور کلی عملکرد ضعیف‌تری نسبت به GA و PSO دارد. این تحلیل جامع به شناسایی نقاط قوت و ضعف هر الگوریتم و انتخاب بهترین روش برای مسائل صنعتی و مالی کمک می‌کند.

منابع

Goldberg DE. *Genetic Algorithm in Search, Optimization and Machine Learning*, Addison. Wesley Publishing Company, Reading, MA. 1989;1(98):9.

Alhijawi B, Awajan A. Genetic algorithms: Theory, genetic operators, solutions, and applications. *Evolutionary Intelligence*. 2024;17(3):1245-56.

Kennedy J, Eberhart R, editors. *Particle swarm optimization. Proceedings of ICNN'95-international conference on neural networks*; 1995: ieee.

Bazrkar MJ, Hosseini S. Predict stock prices using supervised learning algorithms and particle swarm optimization algorithm. *Computational Economics*. 2023;62(1):165-86.

Kosanoglu F, Atmis M, Turan HH. A deep reinforcement learning assisted simulated annealing algorithm for a maintenance planning problem. *Annals of Operations Research*. 2024;339(1):79-110.

- Cordeau J-F, Laporte G. The dial-a-ride problem: models and algorithms. *Annals of operations research*. 2007;153:29-46.
- Matlab S. Matlab. The MathWorks, Natick, MA. 2012;9.
- Derrac J, García S, Hui S, Suganthan PN, Herrera F. Analyzing convergence performance of evolutionary algorithms: A statistical approach. *Information Sciences*. 2014;289:41-58.
- Clerc M, Kennedy J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space. *IEEE transactions on Evolutionary Computation*. 2002;6(1):58-73.
- Tzuu-Shuh C, Yunshyong C. On the convergence rate of annealing processes. *SIAM Journal on Control and Optimization*. 1988;26(6):1455-70.
- Hussain K, Salleh MNM, Cheng S, Shi Y. On the exploration and exploitation in popular swarm-based metaheuristic algorithms. *Neural Computing and Applications*. 2019;31(11):7665-83.
- Managerial Accounting. 2023;8(28):143-58.
- Yang X-S, He X-S, Fan Q-W. Mathematical framework for algorithm analysis. *Nature-inspired computation and swarm intelligence: Elsevier*; 2020. p. 89-108.
- Dokeroglu T, Sevinc E, Kucukyilmaz T, Cosar A. A survey on new generation metaheuristic algorithms. *Computers & Industrial Engineering*. 2019;137:106040.
- Saraswat M, Sharma AK. Genetic Algorithm for optimization using MATLAB. *Int J Adv Res Comput Sci*. 2013;4(3):155-9.
- Kirkpatrick S, Gelatt Jr CD, Vecchi MP. Optimization by simulated annealing. *science*. 1983;220(4598):671-8.
- Nahmias S, Olsen TL. *Production and operations analysis: Waveland Press*; 2015.
- Jorion P. *Financial risk manager handbook: John Wiley & Sons*; 2009.
- Kalymon BA. Estimation risk in the portfolio selection model. *Journal of Financial and Quantitative Analysis*. 1971;6(1):559-82.

The Role of Metaheuristic Algorithms in Optimizing Industrial and Financial Decision-Making: A Comparative Analysis of Population-Based and Physics-Based Methods in Solving Test Problems

Alireza Baghban Kohne Rouz¹

Abbas Toloie Eshlaghy^{*2}

Alireza Pour Ebrahimi³

Ahmad Ebrahimi⁴

Abstract

Optimization is crucial in finding the best solutions for complex problems in various fields, especially in analysing financial and industrial issues and improving related decision-making. This research compares the performance of three algorithms: Genetic Algorithm, Particle Swarm Optimization, and Simulated Annealing in solving industrial and financial problems. The research aim is to conduct a comparative analysis of these algorithms in optimization and identify the characteristics of each in industrial and financial test functions such as production optimization, finance, inventory control, and vehicle routing. Key criteria including mean, standard deviation, success rate, convergence time, accuracy, and population diversity have been used to evaluate performance, and the strengths and weaknesses of each algorithm have been identified. Results show that no algorithm is the best, and the choice of algorithm depends on the specific characteristics of the problem. The findings align with the prominent "No Free Lunch" theory in computer science, which refutes the assumption of the absolute superiority of one algorithm in all problems. The present research, aiming to identify the strengths and weaknesses of algorithms in dealing with industrial and financial issues, has examined their performance gaps. This analysis leads to a deeper understanding of various challenges and intelligent exploitation of algorithm capabilities in more complex problems. The innovation of this research lies in identifying the requirements for developing novel algorithms and determining key parameters for improving performance and problem-solving processes, especially as this comparison has been made between two spectrums of population-based algorithms (Genetic Algorithms and Particle Swarm Optimization) and those based on physical laws (Simulated Annealing). These results will pave the way for developing optimization strategies in industrial and financial decision-making problems.

Keywords: Comparative analysis - Industrial and financial problems - Optimization

Metaheuristic algorithm

¹ PhD Candidate in Industrial Management, Department of Industrial Management, Operations Research, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran, Alirezabkr@gmail.com

^{*} Professor, Department of Industrial Management, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran (Corresponding Author). Toloie@srbiau.ac.ir

³ PhD, Department of Industrial Management, Faculty of Management, Karaj Branch, Islamic Azad University, Karaj, Iran, Poorebrahimi@gmail.com

⁴ PhD, Department of Industrial Management and Technology, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran, ahmad.ebrahimi@srbiau.ac.ir