Optimasi Portofolio Saham Pertambangan pada Indeks LQ45 Menggunakan Dream Optimization Algorithm

Syariful Alim[1], Arif Arizal[2], M. Mahaputra Hidayat[3*]
[1,2,3]Program Studi Teknik Informatika, Fakultas Teknik, Universitas Bhayangkara Surabaya, Surabaya, Indonesia
[1]syalihbara@ubhara.ac.id, [2]qariff@ubhara.ac.id, [3]mahaputra@ubhara.ac.id
*Penulis korespondensi

ABSTRAK

Pemilihan bobot aset pada saham pertambangan menghadapi hubungan imbal hasil–risiko yang nonlinier, volatilitas tinggi, dan perubahan kondisi pasar. Penelitian ini bertujuan mengimplementasikan Dream Optimization Algorithm (DOA) untuk membentuk portofolio saham pertambangan yang termasuk dalam indeks LQ45. Harga penutupan harian *Yahoo Finance* diminta untuk periode 1 September 2021 hingga 31 Agustus 2026. Dari 14 emiten awal, 13 emiten memenuhi syarat minimal 504 observasi dan menghasilkan panel bersama sebanyak 752 hari pada 7 Juli 2023 sampai 31 Agustus 2026. Fungsi objektif memaksimalkan *Sharpe ratio* dengan kendala investasi penuh, bobot nonnegatif, dan batas alokasi 20% per saham. DOA dievaluasi melalui tiga jendela walk-forward, masing-masing dengan 504 hari pelatihan dan 63 hari pengujian, serta 10 pengulangan independen. Secara agregat, portofolio DOA menghasilkan imbal hasil tahunan -18,35%, volatilitas 35,37%, *Sharpe ratio* -0,519, *Sortino ratio* -0,634, dan *maximum drawdown* -34,57%. Dua jendela awal menghasilkan *Sharpe ratio* positif, tetapi penurunan tajam pada jendela ketiga menyebabkan kinerja agregat negatif. Simpangan baku *Sharpe ratio* pelatihan antarpengulangan berada pada rentang 0,0036 – 0,0090, yang menunjukkan proses optimasi stabil meskipun kinerja pasar di luar sampel tidak stabil. Temuan ini menunjukkan bahwa DOA berhasil diterapkan secara komputasional, tetapi belum menghasilkan kinerja investasi yang konsisten pada seluruh periode pengujian.

Kata kunci: *Dream Optimization Algorithm (DOA)*, LQ45, optimasi portofolio, saham pertambangan, metaheuristik

ABSTRACT

Portfolio allocation among mining stocks involves nonlinear risk–return relationships, high volatility, and changing market regimes. This study implements the Dream Optimization Algorithm (DOA) to construct a portfolio of mining stocks listed in the LQ45 index. Daily closing prices were requested from Yahoo Finance for 1 September 2021–31 August 2026. Of the 14 initial issuers, 13 met the minimum requirement of 504 observations, producing a common panel of 752 trading days from 7 July 2023 to 31 August 2026. The objective maximizes the Sharpe ratio subject to full-investment, long-only, and a 20% maximum asset-weight constraint. DOA was evaluated through three walk-forward windows, each using 504 training days and 63 testing days, with 10 independent runs. In aggregate, the DOA portfolio produced an annualized return of -18.35%, annualized volatility of 35.37%, a Sharpe ratio of -0.519, a Sortino ratio of -0.634, and a maximum drawdown of -34.57%. The first two windows achieved positive Sharpe ratios, whereas a sharp decline in the third window led to negative aggregate performance. The standard deviation of the training Sharpe ratio across repeated runs ranged from 0.0036 to 0.0090, indicating stable optimization despite unstable out-of-sample market performance. DOA was therefore implemented successfully from a computational perspective but did not deliver consistent investment performance throughout the testing period..

Keywords: *Dream Optimization Algorithm, LQ45, mining stocks, portfolio optimization; metaheuristics*

1. PENDAHULUAN

Indeks LQ45 berisi saham dengan tingkat likuiditas dan kapitalisasi pasar yang relatif tinggi di Bursa Efek Indonesia. Di dalamnya, saham pertambangan dan energi memiliki karakteristik yang dipengaruhi oleh harga komoditas, nilai tukar, kebijakan pemerintah, dan siklus ekonomi. Karakter tersebut dapat menghasilkan peluang imbal hasil, tetapi juga meningkatkan volatilitas dan risiko penurunan nilai portofolio. Oleh karena itu, keputusan investasi tidak cukup didasarkan pada pemilihan saham secara individual, melainkan memerlukan alokasi bobot yang mempertimbangkan hubungan imbal hasil dan kovarians antarsaham.

Teori portofolio modern merumuskan alokasi aset sebagai kompromi antara ekspektasi imbal hasil dan varians portofolio [1]. Model ini menjadi fondasi penting, tetapi asumsi, sensitivitas parameter, serta bentuk kendala praktis dapat membuat ruang pencarian semakin kompleks. Algoritma metaheuristik menawarkan pendekatan tanpa turunan yang fleksibel untuk masalah optimasi berkendala dan nonlinier. Tinjauan Choudhury

et al. menunjukkan bahwa algoritma yang terinspirasi dari alam banyak digunakan pada ruang pencarian kompleks karena mampu menawarkan kompromi antara kualitas solusi dan biaya komputasi [7]. Akan tetapi, metode berbasis populasi juga menghadapi risiko konvergensi prematur sehingga keseimbangan antara eksplorasi dan eksploitasi perlu diuji secara empiris [3, 4].

Dream Optimization Algorithm (DOA) merupakan metaheuristik yang meniru mekanisme retensi memori, pelupaan dan suplementasi, serta berbagi mimpi. Mekanisme tersebut dirancang untuk mempertahankan solusi berkualitas sekaligus meningkatkan peluang keluar dari optimum lokal [6]. Walaupun DOA telah diuji pada fungsi tolok ukur dan permasalahan rekayasa, bukti penerapannya pada pembentukan portofolio saham Indonesia masih terbatas. Selain itu, evaluasi berbasis satu pembagian data berpotensi menghasilkan estimasi kinerja yang terlalu optimistis.

Kajian penelitian terkait

Keseimbangan eksplorasi dan eksploitasi merupakan tema utama dalam pengembangan metaheuristik. Gupta et al. menambahkan panduan berbasis memori pada sine cosine algorithm untuk mengurangi kemungkinan terjebak pada solusi suboptimal [8]. Strategi hibrid juga digunakan oleh Lakshmi dan Mohanaiah dengan menggabungkan whale optimization algorithm dan sine cosine algorithm guna memperkuat pencarian global [9]. Temuan serupa dilaporkan pada pengembangan SChoA [10], SSC [11], dan SCA–FOA [12]; ketiganya menekankan bahwa peningkatan keragaman populasi dan mekanisme pembaruan kandidat dapat memperbaiki konvergensi sekaligus kemampuan keluar dari optimum lokal.

Perkembangan tersebut juga memperlihatkan pentingnya evaluasi yang tidak hanya menggunakan satu fungsi atau satu kali eksekusi. Sattar dan Salim menguji algoritma berbasis bunga matahari pada fungsi CEC, identifikasi sistem, dan beberapa masalah rekayasa [13]. Pereira et al. mengevaluasi varian metaheuristik berdasarkan nilai objektif dan waktu eksekusi pada banyak himpunan data [14]. Taramsco et al. menggunakan sejumlah instans masalah untuk menilai ketahanan solusi [15]. Li et al. memisahkan penilaian menjadi kecepatan konvergensi, akurasi, dan stabilitas [16]. Praktik tersebut menjadi dasar bagi penelitian ini untuk mengevaluasi DOA melalui pengulangan eksperimen, analisis konvergensi, dan pengujian out-of-sample tanpa menerapkan algoritma optimasi lain.

Metaheuristik yang terinspirasi perilaku manusia juga berkembang. Human Felicity Algorithm menggunakan populasi, pengalaman individual, dan perubahan drastis untuk menjelajahi ruang solusi serta dievaluasi menggunakan uji nonparametrik [17]. Status-based Optimization memanfaatkan proses belajar dari individu berstatus tinggi dan diuji pada berbagai dimensi, seleksi fitur, serta segmentasi citra [18]. DOA berada dalam rumpun pendekatan ini, tetapi memiliki pembeda berupa retensi memori, pelupaan–suplementasi, dan berbagi mimpi [6]. Belum ditemukannya pengujian DOA pada portofolio saham pertambangan LQ45 di dalam kumpulan literatur yang ditelaah memperkuat posisi kebaruan penelitian ini.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan: (1) memformulasikan optimasi portofolio saham pertambangan LQ45 sebagai masalah optimasi berkendala; (2) mengimplementasikan DOA untuk menentukan bobot aset; dan (3) mengevaluasi kinerja out-of-sample, konvergensi, dan stabilitas DOA menggunakan prosedur walk-forward. Kontribusi penelitian terletak pada adaptasi representasi solusi dan penanganan kendala DOA untuk portofolio long-only, serta penerapannya pada saham pertambangan LQ45 dengan memperhitungkan risiko penurunan dan biaya transaksi..

.

2. METODOLOGI PENELITIAN

Desain penelitian dan data

Penelitian menggunakan desain kuantitatif eksperimental. Data terdiri atas harga penutupan harian yang telah disesuaikan terhadap aksi korporasi dan dividen. Data diunduh dari Yahoo Finance melalui pustaka yfinance atau pengunduh kompatibel yang tersedia di dalam aplikasi untuk periode 1 September 2021–31 Agustus 2026. Tanggal akhir permintaan pada aplikasi ditetapkan 1 September 2026 karena parameter tanggal akhir bersifat eksklusif. Rentang lima tahun dipilih agar tersedia data yang memadai untuk estimasi dan evaluasi pada beberapa kondisi pasar. Emiten diwajibkan memiliki sekurang-kurangnya 504 observasi atau sekitar dua tahun perdagangan; emiten yang tidak memenuhi syarat dikeluarkan dari analisis utama. Tingkat imbal hasil bebas risiko ditetapkan 0% per tahun agar evaluasi konsisten dengan konfigurasi aplikasi dan tidak bergantung pada perubahan proksi suku bunga selama periode pengujian.

Populasi penelitian adalah 45 saham yang tercantum dalam Pengumuman BEI No. Peng-00148/BEI.POP/07-2026 untuk periode efektif 3 Agustus–30 Oktober 2026. Sampel awal dipilih dengan kriteria: (1) emiten merupakan produsen komoditas tambang atau kelompok usaha dengan kegiatan pertambangan yang material; (2) menjadi konstituen LQ45 pada periode efektif tersebut; dan (3) memiliki sedikitnya 504 observasi harga selama periode permintaan. Berdasarkan bidang usaha diperoleh 14 emiten. AADI tidak memenuhi kriteria data karena hanya memiliki 410 observasi sejak 5 Desember 2024, sehingga sampel analitis terdiri atas 13 emiten.

DEWA tidak dimasukkan karena kegiatan utama emiten berupa jasa kontraktor pertambangan. Daftar saham dan status seleksi disajikan pada Tabel 1.

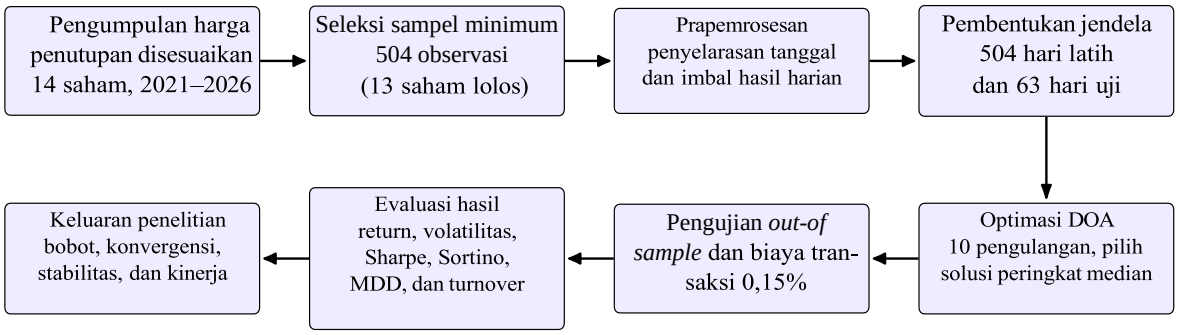
Tabel 1: Sampel awal dan status seleksi data

Kode	Nama emiten	Kelompok	Status
AADI	Adaro Andalan Indonesia Tbk	Batu bara	Tidak lolos data
ADMR	Alamtri Minerals Indonesia Tbk	Batu bara/mineral	Utama
ADRO	Alamtri Resources Indonesia Tbk	Kelompok tambang	Utama
AMMN	Amman Mineral Internasional Tbk	Tembaga/emas	Utama
ANTM	Aneka Tambang Tbk	Logam/mineral	Utama
BUMI	Bumi Resources Tbk	Batu bara	Utama
CUAN	Petrindo Jaya Kreasi Tbk	Batu bara/emas	Utama
INCO	Vale Indonesia Tbk	Nikel	Utama
INDY	Indika Energy Tbk	Kelompok tambang	Utama
ITMG	Indo Tambangraya Megah Tbk	Batu bara	Utama
MBMA	Merdeka Battery Materials Tbk	Nikel/mineral	Utama
MDKA	Merdeka Copper Gold Tbk	Tembaga/emas	Utama
NCKL	Trimegah Bangun Persada Tbk	Nikel	Utama
PTBA	Bukit Asam Tbk	Batu bara	Utama
DEWA	Darma Henwa Tbk	Jasa pertambangan	Tidak dianalisis

Harga diubah menjadi imbal hasil sederhana sesuai implementasi aplikasi:

$$r_{i,t} = \frac{p_{i,t} - p_{i,t-1}}{p_{i,t-1}} \quad (1)$$

dengan Pi,t menyatakan harga saham i pada hari t. Perbedaan kalender minor ditangani dengan forward fill maksimum tiga hari, kemudian baris yang masih memiliki nilai hilang dihapus. Pengisian tidak dilakukan melintasi periode suspensi panjang. Setelah penyelarasan, panel bersama mencakup 752 harga harian atau 751 observasi imbal hasil pada 7 Juli 2023–31 Agustus 2026. Data dipisahkan secara kronologis tanpa pengacakan untuk mencegah kebocoran informasi



Gambar 1. Blok diagram metode penelitian. Alur baris kedua dibaca dari kanan ke kiri

Gambar 1 merangkum tahapan penelitian dari pengumpulan data hingga pelaporan hasil. Proses dimulai dengan pengumpulan harga penutupan disesuaikan untuk 14 saham, dilanjutkan dengan seleksi berdasarkan kecukupan observasi sehingga diperoleh 13 saham. Data terpilih kemudian diselaraskan menurut tanggal perdagangan dan diubah menjadi imbal hasil harian. Panel data dibagi secara kronologis menggunakan skema walk-forward, yaitu 504 hari sebagai data latih dan 63 hari berikutnya sebagai data uji. Pada setiap jendela, DOA dijalankan sebanyak 10 kali untuk memperoleh bobot portofolio dan dipilih solusi berperingkat median. Bobot tersebut selanjutnya diterapkan pada periode out-of-sample dengan memperhitungkan biaya transaksi 0,15%. Tahap akhir menghitung metrik kinerja, konvergensi, dan stabilitas untuk menghasilkan keluaran penelitian berupa komposisi bobot serta evaluasi portofolio.

Formulasi optimasi portofolio

Untuk n saham, kandidat solusi dinyatakan sebagai vektor bobot $w = (W_1, \dots W_n)^T$ .Imbal hasil dan volatilitas tahunan portofolio dihitung sebagai :

$$R_p = A\, w^T\, \mu. \quad (2)$$

$$\sigma_p = \sqrt{Aw^T \Sigma w} \tag{3}$$

dengan $\boldsymbol{\mu}$ adalah vektor rerata imbal hasil harian, $\boldsymbol{\Sigma}$ matriks kovarians harian, dan $A = 252$ jumlah hari perdagangan tahunan. Fungsi objektif utama adalah meminimalkan negatif Sharpe ratio [2]:

$$\min_w f(w) = -\frac{R_p - R_f}{\sigma} \tag{4}$$

Dengan kendala

$$\sum_{i=1}^{n} w_i = 1, 0 \leq w_i \leq w_{max} \tag{5}$$

Nilai $w_{\max} = 0{,}20$ digunakan untuk membatasi konsentrasi maksimum 20% pada setiap saham. Setiap kandidat diproyeksikan ke *capped simplex* agar seluruh bobot berada pada interval yang diizinkan dan jumlahnya tepat satu. Biaya transaksi tidak dimasukkan ke fungsi objektif pelatihan, tetapi dikurangkan dari imbal hasil pada setiap penyeimbangan kembali dalam evaluasi *out-of-sample.*

Implementasi Dream Optimization Algorithm

Implementasi DOA mengacu pada mekanisme utama Lang dan Gao [6]. Populasi awal terdiri atas N vektor acak yang dibuat layak terhadap kendala portofolio. Pada fase eksplorasi, strategi memori dasar mempertahankan informasi solusi terbaik, strategi pelupaan dan suplementasi mengganti sebagian informasi untuk memperluas pencarian, dan strategi berbagi mimpi menukar informasi antarkandidat. Pada fase eksploitasi, pembaruan dipusatkan di sekitar solusi terbaik dengan amplitudo yang menurun seiring iterasi.

Prosedur eksperimen adalah sebagai berikut:

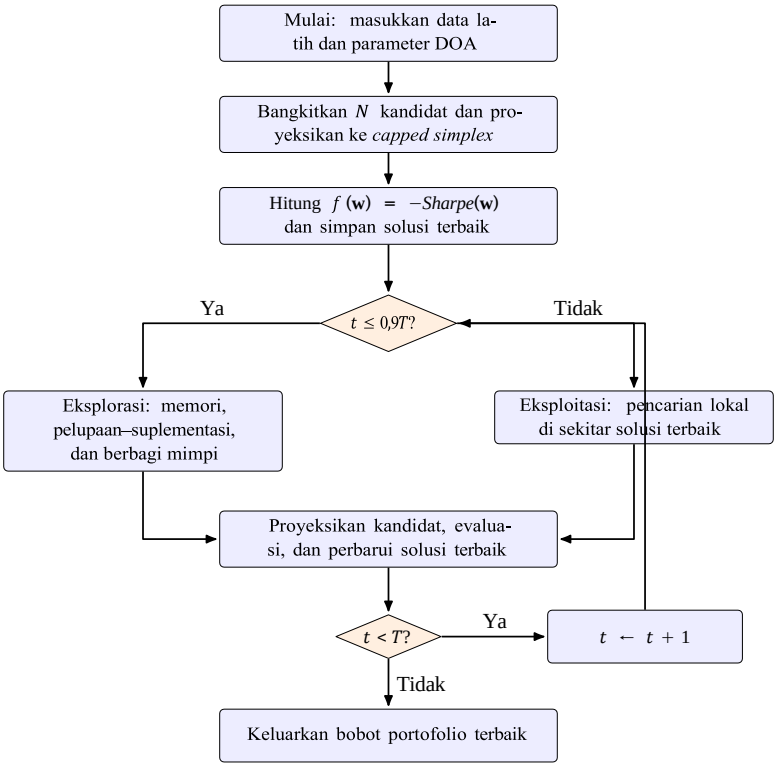
1. Inisialisasi $N = 50$ kandidat, jumlah iterasi maksimum $T = 500$, dan benih acak dasar 42.
2. Perbaiki setiap kandidat agar memenuhi kendala bobot, lalu hitung nilai fungsi objektif.
3. Jalankan fase eksplorasi DOA beserta strategi memori, pelupaan–suplementasi, dan berbagi informasi.
4. Jalankan fase eksploitasi di sekitar solusi terbaik; perbaiki kembali kandidat yang tidak layak.
5. Simpan solusi terbaik dan hentikan proses setelah 500 iterasi.

Ulangi eksperimen sebanyak 10 kali untuk setiap jendela pengujian dan gunakan solusi dengan peringkat median agar hasil tidak bergantung pada satu eksekusi terbaik.

Parameter DOA ditentukan menggunakan data pelatihan saja agar informasi dari periode uji tidak memengaruhi proses optimasi. Implementasi dibuat dengan Python menggunakan NumPy, pandas, Matplotlib, yfinance, dan antarmuka grafis PyQt5. Antarmuka menampilkan konfigurasi eksperimen, log tahapan, dan bilah kemajuan iterasi, sedangkan optimasi dijalankan pada thread terpisah agar aplikasi tetap responsif. Struktur DOA mempertahankan lima kelompok populasi, fase eksplorasi pada 90% iterasi, serta fase eksploitasi pada 10% iterasi terakhir sesuai kode utama Lang dan Gao [6]. Proyeksi capped simplex ditambahkan untuk menjamin jumlah bobot tepat satu, bobot nonnegatif, dan batas maksimum alokasi. Penilaian mencakup nilai objektif, kecepatan konvergensi, waktu komputasi, dan stabilitas antarpengulangan sebagaimana ditekankan dalam evaluasi metaheuristik komprehensif [16, 18]. Kode tersedia sebagai berkas pendamping portfolio_doa.py dangui_doa.py.

Gambar 2 memperlihatkan alur optimasi bobot portofolio dalam satu kali eksekusi Dream Optimization Algorithm (DOA), sedangkan Algoritma 1 menyajikan pseudocode yang mencakup rincian pelaksanaan, pengulangan eksperimen, dan pemilihan solusi akhir. Proses diawali dengan memasukkan data latih dan parameter DOA, kemudian membangkitkan populasi awal yang terdiri atas sejumlah kandidat kombinasi bobot aset. Setiap kandidat diproyeksikan ke capped simplex agar memenuhi kendala portofolio, yaitu jumlah keseluruhan bobot sebesar satu dan bobot setiap aset berada dalam batas alokasi yang ditetapkan. Setelah itu, seluruh kandidat dievaluasi berdasarkan fungsi tujuan yang berkaitan dengan rasio Sharpe, lalu kandidat dengan hasil evaluasi terbaik disimpan sebagai solusi terbaik sementara. Tahap berikutnya adalah pembaruan kandidat melalui fase eksplorasi atau eksploitasi sesuai dengan posisi iterasi. Pada sekitar 90% iterasi awal, algoritma menjalankan fase eksplorasi melalui mekanisme memori, pelupaan–suplementasi, dan berbagi mimpi untuk menjelajahi berbagai alternatif kombinasi bobot dalam ruang pencarian. Pada sekitar 10% iterasi terakhir, proses beralih ke fase eksploitasi berupa pencarian lokal di sekitar solusi terbaik untuk menyempurnakan hasil yang telah diperoleh. Setiap kandidat hasil pembaruan diproyeksikan kembali ke capped simplex sebelum dievaluasi karena perubahan bobot dapat menyebabkan kandidat keluar dari batas kendala portofolio. Hasil evaluasi kemudian dibandingkan dengan solusi terbaik sementara, dan solusi tersebut diperbarui apabila ditemukan kandidat yang memberikan hasil lebih baik. Selanjutnya, algoritma memeriksa ketercapaian batas iterasi; apabila batas tersebut belum tercapai, penghitung iterasi ditambah dan proses pembaruan kembali dilakukan melalui fase yang sesuai. Siklus ini berlangsung hingga jumlah iterasi maksimum terpenuhi, kem.udian algoritma mengeluarkan bobot portofolio

terbaik dari satu kali eksekusi. Dalam Algoritma 1, keseluruhan proses tersebut diulang sebanyak sepuluh kali pada setiap jendela walk-forward. Solusi terbaik dari masing-masing eksekusi selanjutnya diurutkan berdasarkan kriteria pemeringkatan yang digunakan, lalu solusi berperingkat median dipilih sebagai bobot portofolio akhir untuk jendela tersebut. Dengan demikian, flowchart menjelaskan mekanisme pencarian dalam satu eksekusi, sementara pseudocode melengkapinya dengan prosedur pengulangan dan pemilihan solusi akhir..



Gambar 2. Flowchart optimasi bobot portofolio menggunakan DOA

Flowchart pada Gambar 2 menggambarkan alur satu kali eksekusi DOA, mulai dari pembangkitan populasi hingga diperolehnya bobot terbaik. Percabangan berdasarkan nilai iterasi memisahkan fase eksplorasi pada 90% iterasi awal dan fase eksploitasi pada 10% iterasi terakhir. Setiap hasil pembaruan diproyeksikan kembali ke capped simplex sebelum dievaluasi agar seluruh kandidat tetap memenuhi kendala portofolio. Alur tersebut kemudian diterjemahkan secara lebih terperinci dalam Algoritma 1, dengan penambahan pengulangan sebanyak $K = 10$ dan pemilihan solusi berperingkat median sebagai bobot akhir untuk satu jendela walk-forward.

Algorithm 1 DOA untuk optimasi portofolio pada satu jendela *walk-forward*

Require: Data latih $\mathbf{R}_{\text{train}}$, $N = 50$, $T = 500$, $K = 10$, dan $w_{\max} = 0{,}20$
Ensure: Vektor bobot layak $\mathbf{w}^*$
Hitung $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$ dari $\mathbf{R}_{\text{train}}$
for $k = 1$ sampai K **do**
  Bangkitkan populasi $\{\mathbf{w}_j\}_{j=1}^{N}$ dan proyeksikan setiap kandidat ke *capped simplex*
  Evaluasi $f(\mathbf{w}_j) = -R_p(\mathbf{w}_j) - R_f / \sigma_p(\mathbf{w}_j)$
  $\mathbf{w}_{\text{best}} \leftarrow \arg\min_j f(\mathbf{w}_j)$
  for $t = 1$ sampai T **do**
    if $t \le 0{,}9T$ **then**
      Perbarui kandidat dengan strategi memori, pelupaan–suplementasi, dan berbagi mimpi
    else
      Perbarui kandidat di sekitar $\mathbf{w}_{\text{best}}$ dengan amplitudo menurun
    end if
    Proyeksikan setiap kandidat sehingga $\sum_i w_i = 1$ dan $0 \le w_i \le w_{\max}$
    Evaluasi kandidat dan perbarui $\mathbf{w}_{\text{best}}$ jika diperoleh nilai objektif lebih kecil
  end for
  Simpan $\mathbf{w}_{\text{best}}$, $f(\mathbf{w}_{\text{best}})$ sebagai hasil pengulangan k
end for
Urutkan K hasil berdasarkan nilai objektif dan pilih solusi berperingkat median sebagai $\mathbf{w}^*$
return $\mathbf{w}^*$

Skenario evaluasi DOA

Evaluasi menggunakan skema walk-forward: jendela estimasi sepanjang 504 hari digunakan untuk mengoptimalkan bobot, kemudian bobot diuji pada 63 hari berikutnya. Jendela digeser 63 hari dan portofolio diseimbangkan kembali pada awal setiap periode uji. Biaya transaksi satu arah sebesar 0,15% dari nilai perputaran portofolio dikurangkan dari imbal hasil pada hari pertama setiap jendela.

Evaluasi difokuskan pada keluaran DOA dan tidak melibatkan implementasi algoritma optimasi pembanding. Metrik utama adalah Sharpe ratio; metrik tambahan meliputi imbal hasil tahunan, volatilitas tahunan, Sortino ratio, maximum drawdown, perputaran portofolio, waktu komputasi, dan stabilitas bobot. Karena Sharpe ratio dapat memiliki ketidakpastian sampel, interval kepercayaan 95% dihitung menggunakan moving-block bootstrap dengan panjang blok 10 hari, 5.000 replikasi, dan benih acak 42 [5]. Stabilitas stokastik DOA dinilai dari rerata, median, simpangan baku, nilai terbaik, dan nilai terburuk pada 10 pengulangan independen.

3. HASIL DAN PEMBAHASAN

Karakteristik data

Seleksi bidang usaha menghasilkan 14 saham awal. AADI dikeluarkan karena hanya memiliki 410 observasi, lebih rendah daripada batas 504 observasi, sehingga analisis menggunakan 13 saham dan 751 observasi imbal hasil harian. Tabel 2 menyajikan statistik deskriptif. CUAN memiliki rerata imbal hasil harian tertinggi sebesar 0,455% sekaligus volatilitas harian tertinggi sebesar 5,756%. Korelasi antarsaham berada pada rentang 0,077–0,540. Korelasi positif yang tidak sempurna tersebut menunjukkan masih terdapat peluang diversifikasi, meskipun seluruh aset berasal dari kelompok industri yang berdekatan

Tabel 2 menunjukkan bahwa karakteristik imbal hasil antarsaham sangat heterogen. CUAN memiliki rerata harian tertinggi sebesar 0,455%, tetapi juga standar deviasi tertinggi sebesar 5,756%; dengan demikian, potensi imbal hasilnya disertai fluktuasi yang paling besar. Sebaliknya, ITMG dan PTBA memiliki volatilitas terendah, masing-masing 1,541% dan 1,692%, sehingga dapat berperan sebagai unsur peredam risiko di dalam portofolio. ADRO mencatat penurunan harian terdalam sebesar -24, 638%, sedangkan BUMI mencatat kenaikan harian tertinggi sebesar 32,000%. Hampir seluruh saham memiliki skewness positif, terutama BUMI, MBMA, dan INDY, yang menunjukkan keberadaan beberapa observasi kenaikan ekstrem. Perbedaan rerata, volatilitas, dan bentuk distribusi tersebut menegaskan bahwa pemilihan saham tidak dapat hanya didasarkan pada rerata imbal hasil, tetapi perlu mempertimbangkan kovarians dan kontribusi risiko setiap saham dalam portofolio.

Tabel 2: Statistik deskriptif imbal hasil harian

Saham	Rerata (%)	Std. deviasi (%)	Minimum (%)	Maksimum (%)	Skewness	ADMR
	0,137	3,410	−12, 222	24,887	0,946	
ADRO	0,175	2,667	−76, 38	19,387	0,206	
AMMN	0,197	3,913	−18, 056	19,905	0,087	
ANTM	0,131	2,965	−14, 373	13,834	0,141	
BUMI	0,152	4,374	−14, 966	32,000	1,390	
CUAN	0,455	5,756	−19, 965	24,860	0,718	
INCO	0,037	3,416	−14, 978	18,844	0,482	
INDY	0,123	3,852	−14, 894	24,889	1,093	
ITMG	0,068	1,541	−6, 914	7,321	−0, 018	
MBMA	0,038	4,182	−15, 000	25,000	1,132	
MDKA	0,056	3,809	−14, 953	24,771	0,492	
NCKL	0,067	3,058	−14, 493	18,405	0,587	
PTBA	0,045	1,692	−7, 018	8,943	0,601	

Kinerja optimasi dan portofolio

Tabel 3 menunjukkan *kinerja out-of-sample* setelah biaya transaksi. Jendela pertama dan kedua menghasilkan *Sharpe ratio* masing-masing 1,156 dan 2,283. Sebaliknya, jendela ketiga menghasilkan imbal hasil tahunan −76, 43% dan Sharpe ratio −1, 765. Jika seluruh 189 hari pengujian dirangkai secara kronologis, portofolio menghasilkan imbal hasil tahunan −18, 35%, volatilitas 35,37%, *Sharpe ratio* −0, 519, dan maximum drawdown −34, 57%. Interval kepercayaan bootstrap 95% untuk Sharpe ratio adalah [−1, 680; 3, 277], yang menunjukkan ketidakpastian kinerja masih tinggi.

Perbandingan pada Tabel 3 memperlihatkan perubahan kinerja yang tajam antartahap pengujian. Jendela kedua memberikan hasil terbaik dengan imbal hasil tahunan 81,07%, Sharpe ratio 2,283, dan Sortino ratio 2,628, meskipun volatilitasnya lebih tinggi daripada jendela pertama. Nilai Sortino yang lebih besar daripada Sharpe pada dua jendela awal menunjukkan bahwa volatilitas penurunan relatif lebih kecil daripada volatilitas total selama

periode tersebut. Kondisi berbalik pada jendela ketiga: volatilitas meningkat menjadi 43,31%, imbal hasil tahunan turun menjadi -76, 43%, dan maximum drawdown mencapai -33, 18%. Kerugian pada jendela ketiga cukup besar untuk menghapus keuntungan dua jendela sebelumnya sehingga metrik agregat menjadi negatif. Waktu komputasi yang hanya berbeda sekitar 0,71 detik antartiga jendela menunjukkan bahwa perubahan kinerja terutama berasal dari data pasar dan bukan dari perbedaan beban komputasi optimasi.

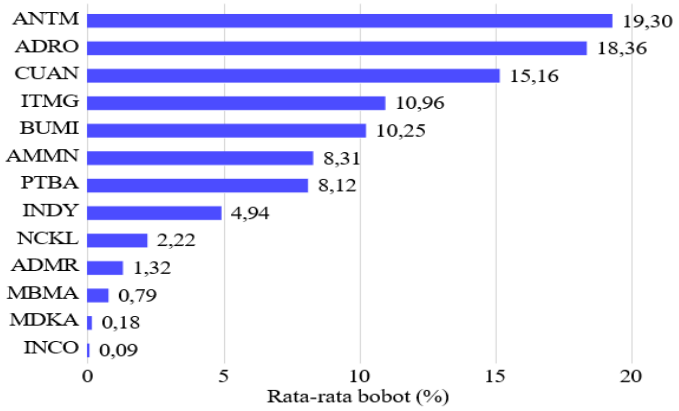
Tabel 3: Kinerja portofolio yang dihasilkan DOA

Skenario	Imbal hasil (%)	Volatilitas (%)	Sharpe	Sortino	MDD (%)	Waktu (detik)
Jendela 1	27,52	23,80	1,156	1,992	−8,04	15,87
Jendela 2	81,07	35,51	2,283	2,628	−14,89	15,52
Jendela 3	−76,43	43,31	−1,765	−2,268	−33,18	16,23
Agregat	−18,35	35,37	−0,519	−0,634	−34,57	–

Komposisi portofolio berubah pada setiap penyeimbangan kembali karena parameter imbal hasil dan kovarians diestimasi ulang menggunakan jendela pelatihan terbaru. Tabel 4 menyajikan bobot terpilih pada setiap jendela dan rata-rata aritmetiknya.

Tabel 4: Komposisi saham dalam portofolio DOA

Saham	Jendela 1 (%)	Jendela 2 (%)	Jendela 3 (%)	Rata-rata (%)
ADMR	1,83	0,00	2,12	1,32
ADRO	16,27	19,17	19,65	18,36
AMMN	19,16	5,78	0,00	8,31
ANTM	19,06	19,17	19,65	19,30
BUMI	0,00	14,19	16,57	10,25
CUAN	19,16	19,17	7,14	15,16
INCO	0,00	0,04	0,24	0,09
INDY	0,00	0,00	14,83	4,94
ITMG	19,16	13,42	0,30	10,96
MBMA	0,55	0,00	1,83	0,79
MDKA	0,08	0,37	0,08	0,18
NCKL	0,00	0,94	5,71	2,22
PTBA	4,73	7,75	11,87	8,12
Total	100,00	100,00	100,00	100,00

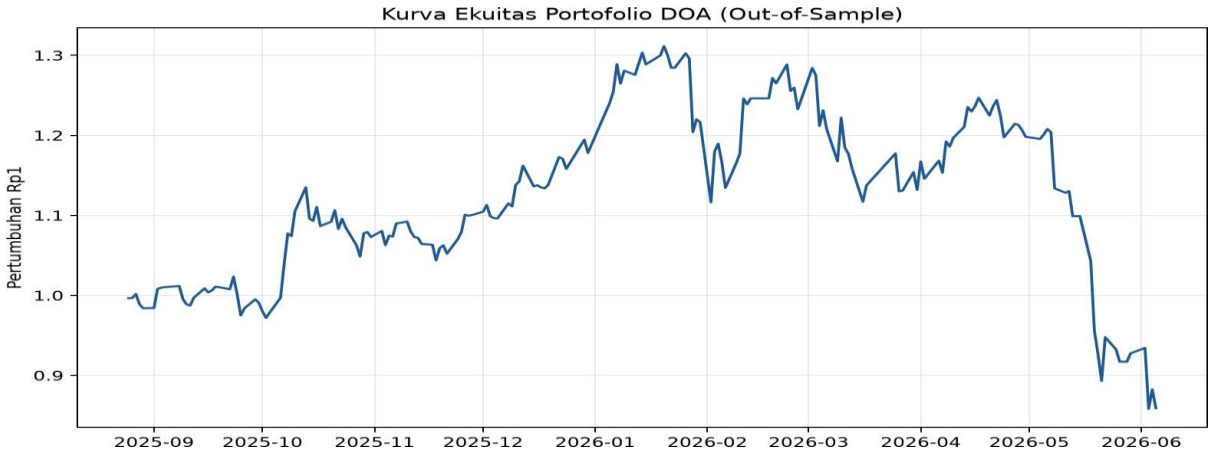


Gambar 3. Rata-rata komposisi portofolio DOA pada tiga jendela pengujian.

Tabel 4 dan Gambar 3 memperlihatkan bahwa ANTM dan ADRO merupakan dua saham yang paling konsisten dipertahankan, dengan rata-rata bobot masing-masing 19,30% dan 18,36%, mendekati batas maksimum 20%. CUAN menempati urutan ketiga dengan rata-rata 15,16%, tetapi bobotnya turun dari sekitar 19,16% pada dua jendela awal menjadi 7,14% pada jendela ketiga. Pergeseran yang lebih besar terlihat pada AMMN dan ITMG, yang memiliki bobot tinggi pada jendela pertama tetapi hampir tidak digunakan pada jendela ketiga. Sebaliknya,

BUMI, INDY, NCKL, dan PTBA memperoleh alokasi lebih besar pada jendela ketiga. Pola ini menunjukkan bahwa DOA merespons perubahan estimasi imbal hasil dan kovarians dengan membentuk portofolio yang relatif terkonsentrasi pada beberapa saham. Grafik rata-rata memudahkan identifikasi saham dominan, tetapi Tabel 4 menegaskan bahwa rata-rata tersebut tidak sepenuhnya menggambarkan perubahan alokasi pada setiap penyeimbangan kembali.

Rata-rata perputaran pada dua penyeimbangan kembali setelah pembentukan awal adalah 52,72%. Besarnya perubahan bobot tersebut konsisten dengan perpindahan alokasi antarsaham pada Tabel 4 dan menegaskan pentingnya memasukkan biaya transaksi. Walaupun setiap bobot memenuhi batas 20%, konsentrasi gabungan pada beberapa saham utama tetap membuat portofolio peka terhadap perubahan kinerja saham-saham tersebut.

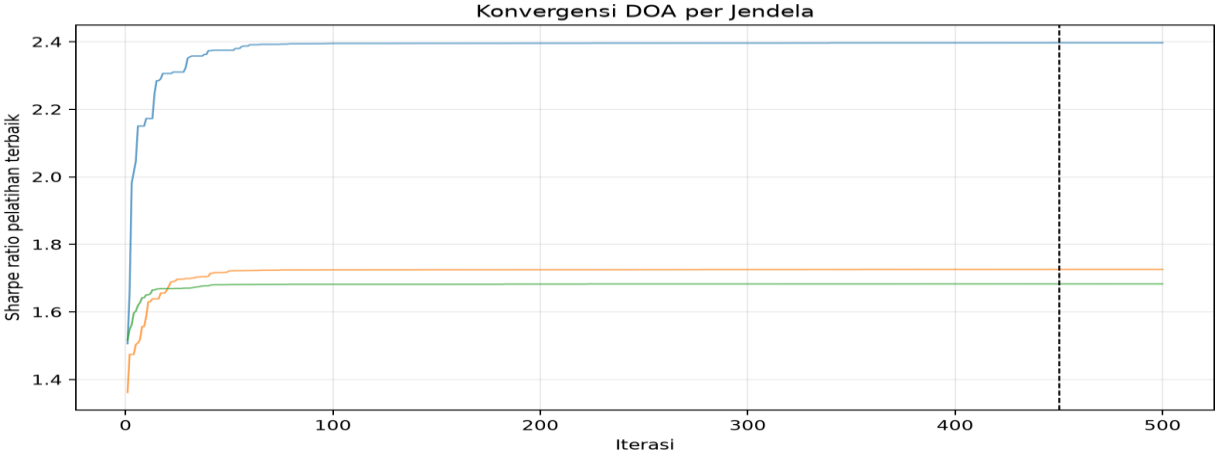


Gambar 4. Kurva ekuitas portofolio DOA pada periode out-of-sample

Gambar 4 memperjelas bagaimana perbedaan kinerja pada Tabel 3 terbentuk secara kronologis. Nilai portofolio meningkat menjadi sekitar 1,063 pada akhir jendela pertama dan 1,233 pada akhir jendela kedua, dengan puncak sekitar 1,312 pada 20 Januari 2026. Setelah memasuki jendela ketiga, kurva berbalik turun secara tajam dan mencapai sekitar 0,858 pada 3 Juni 2026. Titik tersebut sekaligus menghasilkan maximum drawdown agregat sekitar -34, 57%. Bentuk kurva ini menunjukkan bahwa hasil negatif agregat tidak terjadi secara merata sepanjang periode uji, tetapi terutama disebabkan oleh kerugian beruntun pada jendela ketiga yang menghapus akumulasi keuntungan sebelumnya.

Stabilitas dan konvergensi

Pada 10 pengulangan, simpangan baku Sharpe ratio pelatihan adalah 0,0090, 0,0080, dan 0,0036 masing-masing untuk jendela pertama, kedua, dan ketiga. Rentang yang sempit menunjukkan bahwa solusi DOA relatif stabil terhadap perubahan benih acak pada konfigurasi yang digunakan. Rata-rata waktu satu eksekusi adalah 15,91 detik, sedangkan keseluruhan 30 eksekusi memerlukan sekitar 477,27 detik. Ketiga jendela telah mencapai sedikitnya 99% dari nilai objektif akhirnya paling lambat pada iterasi ke-41. Gambar 5 juga memperlihatkan bahwa peningkatan terbesar terjadi pada fase awal eksplorasi, sedangkan iterasi berikutnya terutama mempertahankan solusi terbaik.



Gambar 5. Konvergensi Sharpe ratio pelatihan terbaik pada tiga jendela. Garis putus-putus menandai peralihan dari eksplorasi ke eksploitasi.

Gambar 5 menunjukkan bahwa ketiga kurva mengalami peningkatan paling besar pada puluhan iterasi pertama, kemudian bergerak mendatar hingga akhir proses. Seluruh jendela telah mencapai sekurang-kurangnya 99% dari nilai akhirnya paling lambat pada iterasi ke-41, jauh sebelum peralihan ke fase eksploitasi pada iterasi ke-450. Perbaikan kecil yang masih terjadi setelah kurva mendatar menunjukkan bahwa mekanisme eksplorasi tetap mampu menyempurnakan kandidat, tetapi kontribusinya terhadap nilai akhir relatif terbatas. Kemiripan bentuk kurva dan rendahnya simpangan baku antarpengulangan mendukung kesimpulan bahwa DOA stabil secara komputasional pada konfigurasi ini. Namun, grafik konvergensi hanya menunjukkan pencapaian solusi terbaik pada data pelatihan dan tidak membuktikan bahwa solusi tersebut akan mempertahankan kinerja pada data di luar sampel.

Pembahasan

Statistik pada Tabel 2 memperlihatkan bahwa saham dengan rerata imbal hasil tinggi juga dapat membawa volatilitas dan risiko ekstrem yang tinggi. Kondisi ini terlihat paling jelas pada CUAN, sedangkan ITMG dan PTBA menawarkan volatilitas yang lebih rendah. Oleh karena itu, alokasi yang dihasilkan DOA merupakan hasil kompromi antara imbal hasil estimasian dan kontribusi risiko portofolio, bukan pemeringkatan saham berdasarkan rerata imbal hasil secara individual. Batas bobot 20% mencegah satu saham mendominasi seluruh portofolio, tetapi hasil pada Tabel 4 menunjukkan bahwa beberapa aset tetap ditempatkan dekat batas tersebut. Dengan demikian, kendala bobot mengurangi konsentrasi individual tanpa sepenuhnya menghilangkan konsentrasi pada kelompok saham utama.

Tabel 3 dan Gambar 4 memperlihatkan dua kondisi pasar yang berbeda. Pada dua jendela awal, bobot hasil optimasi mampu menghasilkan imbal hasil positif dengan rasio kinerja terhadap risiko yang baik. Akan tetapi, susunan bobot pada jendela ketiga tidak mampu menghadapi perubahan pola imbal hasil berikutnya. Penambahan alokasi pada BUMI, INDY, NCKL, dan PTBA serta pengurangan pada AMMN, CUAN, dan ITMG merupakan keputusan yang optimal menurut data latih jendela ketiga, tetapi keputusan tersebut tidak menjamin hasil positif ketika diterapkan pada periode uji. Temuan ini memperlihatkan keterbatasan optimasi berbasis rerata dan kovarians historis ketika hubungan antaraset berubah.

Dari sisi komputasi, Gambar 5 memperlihatkan bahwa DOA cepat mencapai nilai objektif yang stabil dan menghasilkan bobot layak pada seluruh pengulangan. Mekanisme memori mempertahankan kandidat berkualitas, sementara pelupaan–suplementasi dan berbagi mimpi memperluas pencarian. Penjelasan ini sejalan dengan temuan bahwa panduan memori dapat memperbaiki keseimbangan pencarian [8] dan bahwa strategi hibrid atau suplementer dapat mengurangi konvergensi prematur [9, 11]. Meskipun demikian, kurva konvergensi yang baik hanya menunjukkan keberhasilan pencarian pada fungsi objektif pelatihan; kurva tersebut tidak menjamin kemampuan generalisasi terhadap kondisi pasar berikutnya.

Perbedaan tajam antartiga jendela menunjukkan bahwa risiko utama bukan ketidakstabilan proses stokastik DOA, melainkan ketidakstabilan estimasi imbal hasil dan kovarians saham. Nilai Sharpe ratio pelatihan terpilih berada pada 1,683–2,397, tetapi kinerja agregat di luar sampel bernilai negatif. Kesenjangan tersebut merupakan indikasi estimation error, perubahan rezim, atau keduanya. Lebarnya interval kepercayaan bootstrap juga menunjukkan bahwa 189 observasi pengujian belum cukup untuk menghasilkan kesimpulan investasi yang presisi. Karena itu, keberhasilan optimasi perlu dibedakan dari keberhasilan investasi: algoritma dapat stabil dalam menemukan solusi fungsi objektif, sementara fungsi objektifnya tetap dibangun dari parameter pasar yang tidak stabil.

Dari sisi praktis, komposisi pada Tabel 4 dapat digunakan sebagai sistem pendukung keputusan, bukan rekomendasi transaksi otomatis. Rata-rata perputaran 52,72% menunjukkan bahwa strategi memerlukan perdagangan yang cukup besar ketika bobot diperbarui. Implementasi riil harus mempertimbangkan likuiditas, fraksi lot, pajak, biaya transaksi, slippage, suspensi perdagangan, dan frekuensi penyeimbangan kembali. Portofolio dengan Sharpe ratio pelatihan tinggi dan konvergensi cepat belum tentu unggul setelah seluruh friksi pasar serta risiko perubahan rezim diperhitungkan.

Penelitian ini dibatasi oleh penggunaan konstituen LQ45 periode 3 Agustus–30 Oktober 2026, panel efektif 7 Juli 2023–31 Agustus 2026, hanya tiga jendela pengujian penuh, dan asumsi tingkat bebas risiko 0%. Pemilihan konstituen berdasarkan daftar tahun 2026 untuk menilai data historis juga berpotensi menimbulkan survivorship bias. Analisis belum mencakup slippage, pajak, pembatasan lot, perubahan konstituen secara dinamis, atau pembanding algoritma. Penelitian lanjutan dapat mengembangkan DOA multiobjektif, menambahkan ukuran risiko Conditional Value at Risk, menggunakan estimasi kovarians yang lebih robust, dan menguji portofolio pada periode serta indeks lain

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan DOA untuk optimasi portofolio 13 saham pertambangan LQ45 dengan kendala investasi penuh, tanpa penjualan pendek, dan batas bobot maksimum 20%. Pada 189 hari pengujian *out-of-sample*, portofolio menghasilkan imbal hasil tahunan -18,35%, volatilitas 35,37%, *Sharpe ratio* -0,519, *Sortino ratio* -0,634, dan maximum drawdown -34,57%. Simpangan baku hasil pelatihan yang rendah dan konvergensi awal menunjukkan DOA stabil secara komputasional. Namun, variasi kinerja yang besar antartiga

jendela menunjukkan bahwa DOA belum dapat dinyatakan menghasilkan portofolio dengan kinerja investasi yang konsisten. Kesimpulan ini berlaku untuk data dan konfigurasi penelitian serta tidak merupakan rekomendasi pembelian atau penjualan saham.

PERNYATAAN PENDANAAN

Penelitian ini tidak menerima pendanaan khusus, hibah, atau bantuan finansial dari lembaga pemerintah, lembaga komersial, maupun organisasi nirlaba.

KONTRIBUSI PENULIS

Syariful Alim: konseptualisasi, kurasi data, metodologi, perangkat lunak, dan penulisan draf awal. Arif Arizal: validasi, analisis formal, dan visualisasi. M. Mahaputra Hidayat: supervisi, penelaahan, penyuntingan, dan administrasi penelitian. Seluruh penulis telah membaca dan menyetujui naskah akhir.

PERNYATAAN KONFLIK KEPENTINGAN

Para penulis menyatakan tidak terdapat konflik kepentingan.

KETERSEDIAAN DATA DAN KODE

Kode analisis tersedia pada berkas pendamping portfolio_doa.py dan gui_doa.py. Data turunan, bobot portofolio, metrik, dan riwayat konvergensi tersedia dalam folder hasil penelitian. Data harga mentah tunduk pada ketentuan penggunaan Yahoo Finance.

DAFTAR PUSTAKA

[1] H. Markowitz, “Portfolio selection,” The Journal of Finance, vol. 7, no. 1, pp. 77–91, 1952, doi: 10.2307/2975974.
[2] W. F. Sharpe, “Mutual fund performance,” The Journal of Business, vol. 39, no. 1, pp. 119–138, 1966.
[3] J. Kennedy and R. Eberhart, “Particle swarm optimization,” in Proceedings of ICNN’95—International Conference on Neural Networks, 1995, pp. 1942–1948, doi: 10.1109/ICNN.1995.488968.
[4] K. Deb, “An efficient constraint handling method for genetic algorithms,” Computer Methods in Applied Mechanics and Engineering, vol. 186, no. 2–4, pp. 311–338, 2000, doi: 10.1016/S0045-7825(99)00389-8.
[5] A. W. Lo, “The statistics of Sharpe ratios,” Financial Analysts Journal, vol. 58, no. 4, pp. 36–52, 2002, doi: 10.2469/faj.v58.n4.2453.
[6] Y. Lang and Y. Gao, “Dream Optimization Algorithm (DOA): A novel metaheuristic optimization algorithm inspired by human dreams and its applications to real-world engineering problems,” Computer Methods in Applied Mechanics and Engineering, vol. 436, art. 117718, 2025, doi: 10.1016/j.cma.2024.117718.
[7] H. A. Choudhury, N. Sinha, and M. Saikia, “Application of nature-inspired algorithms (NIA) for optimization of video compression,” Journal of Intelligent & Fuzzy Systems, vol. 38, no. 3, pp. 3419–3443, 2020, doi: 10.3233/JIFS-190308.
[8] S. Gupta, K. Deep, and A. P. Engelbrecht, “A memory guided sine cosine algorithm for global optimization,” Engineering Applications of Artificial Intelligence, vol. 93, art. 103718, 2020, doi: 10.1016/j.engappai.2020.103718.
[9] A. V. Lakshmi and P. Mohanaiah, “Intelligent facial emotion recognition based on hybrid whale optimization algorithm and sine cosine algorithm,” Microprocessors and Microsystems, vol. 95, art. 104718, 2022, doi: 10.1016/j.micpro.2022.104718.
[10] M. Kaur, R. Kaur, N. Singh, and G. Dhiman, “SChoA: A newly fusion of sine and cosine with chimp optimization algorithm for HLS of datapaths in digital filters and engineering applications,” Engineering with Computers, vol. 38, pp. 975–1003, 2022, doi: 10.1007/s00366-020-01233-2.
[11] G. Dhiman, “SSC: A hybrid nature-inspired meta-heuristic optimization algorithm for engineering applications,” Knowledge-Based Systems, vol. 222, art. 106926, 2021, doi: 10.1016/j.knosys.2021.106926.
[12] Y. Fan, P. Wang, A. A. Heidari, M. Wang, X. Zhao, H. Chen, and C. Li, “Rationalized fruit fly optimization with sine cosine algorithm: A comprehensive analysis,” Expert Systems with Applications, vol. 157, art. 113486, 2020, doi: 10.1016/j.eswa.2020.113486.
[13] D. Sattar and R. Salim, “A smart metaheuristic algorithm for solving engineering problems,” Engineering with Computers, vol. 37, no. 3, pp. 2389–2417, 2021, doi: 10.1007/s00366-020-00951-x.
[14] J. L. J. Pereira, B. J. Ma, M. B. Francisco, R. F. R. Junior, and G. F. Gomes, “A comparison between chaos theory and Lévy flights in sunflower optimization for feature selection,” Expert Systems, vol. 40, no. 8, art. e13330, 2023, doi: 10.1111/exsy.13330.
[15] C. Taramsco, B. Crawford, R. Soto, E. M. Cortés-Toro, and R. Olivares, “A new metaheuristic based on vapor-liquid equilibrium for solving a new patient bed assignment problem,” Expert Systems with Applications, vol. 158, art. 113506, 2020, doi: 10.1016/j.eswa.2020.113506.

[16] M. Li, Z. Liu, and H. Song, "An improved algorithm optimization algorithm based on Runge–Kutta and golden sine strategy," Expert Systems with Applications, vol. 247, art. 123262, 2024, doi: 10.1016/j.eswa.2024.123262.
[17] M. Verij Kazemi and E. Fazeli Veysari, "A new optimization algorithm inspired by the quest for the evolution of human society: Human felicity algorithm," Expert Systems with Applications, vol. 193, art. 116468, 2022, doi: 10.1016/j.eswa.2021.116468.
[18] J. Wang, Y. Chen, C. Lu, A. A. Heidari, Z. Wu, and H. Chen, "The status-based optimization: Algorithm and comprehensive performance analysis," Neurocomputing, vol. 647, art. 130603, 2025, doi: 10.1016/j.neucom.2025.130603.