

PENILAIAN KINERJA DAN REKOMENDASI REKSA DANA PASAR UANG MENGGUNAKAN RANDOM FOREST-EDAS

Alfandi Kusuma¹, Latifah²

^{1,2}Sistem Informasi, Ilmu Komputer, Universitas Narotama, Indonesia

¹kusumaalfandi494@gmail.com, ²latifah.rifani@narotama.ac.id

Abstrak

Perkembangan industri reksa dana di Indonesia mendorong kebutuhan akan metode evaluasi kinerja dan rekomendasi investasi yang objektif dan berbasis data. Penelitian bertujuan untuk mengintegrasikan metode *machine learning Random Forest* dan sistem pendukung keputusan *Evaluation Based on Distance from Average Solution* (EDAS) dalam menilai kinerja serta memberikan rekomendasi investasi reksa dana pasar uang. Data yang digunakan berupa data historis 29 produk reksa dana pasar uang yang diperoleh dari platform investasi Bibit. Random Forest digunakan untuk mengklasifikasikan kinerja reksa dana ke dalam tiga kategori, yaitu rendah, sedang, dan tinggi, berdasarkan indikator return, risiko, dan dana kelolaan. Selanjutnya, hasil klasifikasi tersebut, diintegrasikan dengan metode EDAS untuk menentukan peringkat dan tingkat rekomendasi investasi berdasarkan enam kriteria utama. Hasil penelitian menunjukkan bahwa model Random Forest memiliki performa klasifikasi yang sangat baik dengan nilai akurasi, *precision*, *recall*, dan *F1-score* sebesar 1,00 serta rata-rata akurasi *5-fold cross validation* sebesar 93,33%. Metode EDAS berhasil menghasilkan rekomendasi investasi yang konsisten dengan hasil penilaian kinerja. Dengan demikian, integrasi Random Forest dan EDAS terbukti efektif sebagai pendekatan terpadu dalam penilaian kinerja dan rekomendasi investasi reksa dana pasar uang berbasis data.

Kata kunci: *random forest*, EDAS, reksa dana pasar uang, penilaian kinerja, sistem pendukung keputusan

1. Pendahuluan

Perkembangan dunia investasi di Indonesia menunjukkan peningkatan yang signifikan dalam beberapa tahun terakhir, khususnya pada instrumen reksa dana. Berdasarkan hasil Survei Nasional Literasi dan Inklusi Keuangan (SNLIK) yang dirilis oleh Otoritas Jasa Keuangan (OJK) tahun 2022, indeks literasi keuangan masyarakat Indonesia mencapai 49,68%, meningkat dibandingkan tahun 2019 yang sebesar 38,03%. Sementara itu, indeks inklusi keuangan pada tahun 2022 tercatat sebesar 85,10%, naik dari 76,19% pada tahun 2019. Data tersebut menunjukkan adanya penurunan kesenjangan antara literasi dan inklusi keuangan, dari 38,16% pada tahun 2019 menjadi 35,42% pada tahun 2022 (Otoritas Jasa Keuangan, 2022).

Peningkatan indeks literasi dan inklusi keuangan mengindikasikan meningkatnya kesadaran dan pemahaman masyarakat terhadap produk dan layanan keuangan, serta semakin luasnya akses terhadap kesenjangan antara tingkat literasi dan inklusi keuangan, yang mengisyaratkan bahwa sebagian masyarakat telah menggunakan produk keuangan tanpa pemahaman yang memadai. Kondisi ini menegaskan bahwa upaya peningkatan literasi keuangan perlu terus diperkuat agar pertumbuhan inklusi keuangan dapat diiringi dengan kemampuan masyarakat dalam mengelola produk keuangan secara bijak dan bertanggung jawab (Otoritas Jasa Keuangan, 2022).

Reksa dana merupakan salah satu produk keuangan yang banyak diminati karena memberikan kemudahan bagi investor dalam mengelola dana tanpa memerlukan keahlian mendalam dalam analisis pasar modal. Data menunjukkan bahwa jumlah produk reksa dana di Indonesia mengalami fluktuasi dari tahun 2017 hingga 2022. Pada tahun 2017, jumlah reksa dana tercatat sebanyak 1.777 produk dan meningkat menjadi 2.184 produk pada tahun 2022. Nilai Aktiva Bersih (NAB) juga mengalami peningkatan dari Rp 457.506 miliar pada tahun 2017 menjadi Rp 505.372 miliar pada tahun 2022 (Pradini, 2023). Peningkatan jumlah produk memberikan lebih banyak pilihan bagi investor, namun di sisi lain menimbulkan tantangan dalam menentukan produk reksa dana yang sesuai dengan tujuan investasi dan profil risiko masing-masing investor.

Pada praktiknya, banyak investor masih mengandalkan faktor subjektif seperti prospektus, heuristik, perilaku herding, dan kondisi pasar dalam pengambilan keputusan investasi, yang berpotensi meningkatkan risiko kerugian (Usman et al., 2023). Oleh karena itu, pemanfaatan teknologi berbasis data menjadi kebutuhan yang semakin penting dalam mendukung pengambilan keputusan investasi.

Integrasi metode *machine learning* dan sistem penunjang keputusan (SPK) menjadi pendekatan yang relevan untuk menjawab permasalahan tersebut. Metode *Random Forest* dipilih karena memiliki kemampuan yang baik dalam memprediksi kinerja reksa dana, khususnya pada data yang memiliki pola kompleks dan hubungan non-linear antar variabel.

Random Forest bekerja dengan membangun sejumlah pohon keputusan secara acak dan menggabungkan hasil prediksi melalui mekanisme voting mayoritas, sehingga mampu mengurangi risiko *overfitting* dan menghasilkan prediksi yang lebih stabil (Rangga Aditya Tarigan & Dahlan, 2024). Sementara itu, keunggulan metode *Evaluation Based on Distance from Average Solution* (EDAS) adalah stabil ketika berbagai kriteria bobot digunakan, perhitungan yang lebih cepat, dan konsisten dengan metode lain (Sabila & Alasi, 2023). EDAS digunakan untuk memberikan rekomendasi pemilihan reksa dana terbaik dengan mempertimbangkan berbagai kriteria, seperti tingkat risiko, return historis, dan stabilitas kinerja.

Sejumlah penelitian terdahulu cenderung menggunakan metode tersebut secara terpisah. Penggunaan *Random Forest* umumnya hanya difokuskan pada proses klasifikasi tanpa mempertimbangkan aspek pengambilan keputusan berbasis multikriteria (Hadi et al., 2025). Di sisi lain, metode EDAS lebih banyak digunakan untuk proses perankingan tanpa didukung oleh model klasifikasi yang kuat dalam mengolah data kompleks (Kadori et al., 2025). Penemuan tersebut menunjukkan adanya *research gap*, yaitu belum optimalnya integrasi antara metode klasifikasi berbasis *machine learning* dengan metode pengambilan keputusan multikriteria untuk investasi dalam satu sistem yang terpadu.


Berdasarkan permasalahan, fenomena, dan kesenjangan penelitian tersebut, penelitian ini menjadi penting untuk dilakukan guna mengembangkan pendekatan yang mampu menggabungkan keunggulan kedua metode. Metode *Random Forest* dan EDAS memiliki potensi besar dalam menghasilkan hasil evaluasi dari prediksi kinerja dan rekomendasi investasi reksa dana pasar uang yang lebih akurat dan objektif. Penelitian diharapkan dapat memberikan kontribusi akademik dalam bidang *data mining* dan sistem penunjang keputusan, serta memberikan manfaat praktis bagi investor dalam menentukan pilihan investasi yang sesuai dengan kebutuhan dan profil risiko.

2. Metode

2.1 Tahapan Penelitian

Penelitian dilaksanakan melalui serangkaian tahapan yang disusun secara sistematis untuk memastikan proses analisis berjalan terarah serta menghasilkan keluaran yang valid dan dapat dipertanggungjawabkan secara ilmiah. Setiap tahapan saling berkaitan, dimulai dari pengolahan data hingga evaluasi hasil, guna mendukung tujuan penelitian dalam memprediksi kinerja dan memberikan rekomendasi investasi reksa dana pasar uang.

Tahapan penelitian dirancang seperti ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

- Pengumpulan Data:** Pengambilan data sekunder reksa dana pasar uang yang diperoleh dari platform Bibit. Data mencakup informasi produk dan indikator keuangan utama, seperti *Asset Under Management* (AUM) dan return historis dalam periode tertentu, yang digunakan sebagai dasar analisis penelitian.
- Pra-Pemrosesan Data:** Data yang diperoleh melalui tahap pra-pemrosesan untuk memastikan kualitas dan konsistensi data. Proses meliputi pembersihan data, penanganan nilai hilang, normalisasi, dan transformasi data agar seluruh variabel berada pada skala yang seragam.
- Penerapan Metode *Random Forest*:** Algoritma *Random Forest* diterapkan untuk mengklasifikasikan kinerja reksa dana berdasarkan variabel input yang telah diproses. Dataset dibagi menjadi data latih dan data uji, serta dievaluasi menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil tahap penerapan berupa kategori kinerja reksa dana.
- Integrasi Metode EDAS:** Hasil klasifikasi kinerja selanjutnya dianalisis menggunakan metode *Evaluation Based on Distance from Average Solution* (EDAS). Penilaian dilakukan berdasarkan jarak terhadap nilai rata-rata solusi positif dan negatif dari enam kriteria yang digunakan, dengan pembobotan mengacu pada studi literatur.
- Evaluasi Hasil:** Evaluasi dilakukan untuk menilai kesesuaian dan konsistensi hasil klasifikasi dan rekomendasi yang dihasilkan dari integrasi metode *Random Forest* dan EDAS.

2.2 Pengumpulan Data

Data yang digunakan dalam penelitian diperoleh dari platform investasi Bibit pada tahun 2025, dengan fokus pada produk reksa dana pasar uang yang masih aktif dan memiliki kelengkapan data historis. Berdasarkan proses pengumpulan data tersebut, diperoleh sebanyak 29 produk reksa dana yang digunakan sebagai sampel penelitian.

Tabel 1. Contoh 5x5 Data Produk Reksa Dana

| Reksadana | Jenis | 1D | 1M | 3M |
|-------------------------------|------------|-------|-------|-------|
| Avrist Ada | Pasar Uang | 0.01% | 0.49% | 1.43% |
| Kas Mutiara | Pasar Uang | 0.01% | 0.38% | 1.22% |
| Bahana Dana Likuid Kelas G | Pasar Uang | 0.01% | 0.42% | 1.31% |
| Bahana Likuid Plus | Pasar Uang | 0.01% | 0.45% | 1.27% |
| Bahana Likuid Syariah Kelas G | Pasar Uang | 0.01% | 0.38% | 1.19% |
| Batavia Dana Kas Maxima | Pasar Uang | 0.01% | 0.38% | 1.19% |

Tabel 1 memperlihatkan contoh data yang dikumpulkan, diperlihatkan setiap produk reksa dana memiliki sejumlah variabel yang digunakan dalam proses prediksi kinerja dan rekomendasi investasi. Variabel yang dikumpulkan meliputi informasi produk serta indikator keuangan utama, seperti return historis dalam berbagai periode (1M, 3M, YTD, 1Y, 3Y, dan 5Y), nilai aktiva bersih terakhir (Last NAV), *drawdown* 1Y, dan total dana kelolaan (*Asset Under Management/AUM*). Variabel-variabel tersebut dipilih karena merepresentasikan aspek kinerja, risiko, dan stabilitas produk yang relevan dalam penilaian investasi reksa dana pasar uang.

Dalam proses pemodelan, penelitian menggunakan return historis, AUM, dan *drawdown* 1Y sebagai variabel input utama pada algoritma *Random Forest* dan metode EDAS. Sementara itu, variabel identitas seperti nama produk dan jenis reksa dana digunakan sebagai informasi pendukung dan tidak dilibatkan dalam proses pemodelan. Struktur dataset yang digunakan dinilai cukup representatif dan relevan untuk mendukung tahapan analisis selanjutnya.

2.3 Pra-Pemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk memastikan dataset reksa dana berada dalam kondisi bersih, konsisten, dan siap digunakan dalam proses analisis menggunakan metode *Random Forest* dan EDAS. Dataset awal yang diperoleh dalam format tabular terlebih dahulu diperiksa untuk mengidentifikasi dan menghapus kolom yang tidak relevan atau kosong, seperti kolom hasil ekspor otomatis, guna menghindari gangguan (noise) dalam proses analisis.

Selanjutnya, dilakukan pembersihan dan konversi data pada seluruh variabel numerik. Variabel return historis dikonversi dari format persentase menjadi nilai numerik, sedangkan variabel lainnya, seperti nilai aktiva bersih terakhir dan total dana kelolaan, dibersihkan dari pemisah ribuan agar dapat diproses sebagai data numerik murni. Dataset kemudian diperiksa untuk mendeteksi keberadaan nilai hilang (missing values), yang selanjutnya ditangani menggunakan metode median imputation untuk menjaga kestabilan distribusi data.

Pada tahap berikutnya, dilakukan seleksi variabel dengan mempertahankan variabel numerik yang relevan untuk proses prediksi dan rekomendasi, sementara variabel identitas yang tidak digunakan dalam pemodelan dihilangkan. Variabel utama yang digunakan meliputi return historis dalam beberapa periode, nilai aktiva bersih, total dana kelolaan, dan *drawdown* satu tahun. Seluruh variabel numerik kemudian dinormalisasi menggunakan min-max normalization untuk memastikan keseragaman skala antar fitur.

Hasil dari rangkaian pra-pemrosesan pada Tabel 2 adalah contoh 4x5 kolom dataset akhir yang telah terstandarisasi, bebas dari kolom tidak relevan,

serta siap digunakan pada tahap penerapan metode *Random Forest* dan integrasi metode EDAS.

Tabel 2. Contoh 4x5 Dataset Hasil Pra-Pemrosesan

| Reksadana | ID | 1M | 3M |
|-------------------------------|----|-----|-----|
| Avrist Ada Kas Mutiara | 0 | 0.5 | 1.4 |
| Bahana Dana Likuid Kelas G | 0 | 0.4 | 1.2 |
| Bahana Likuid Plus | 0 | 0.4 | 1.3 |
| Bahana Likuid Syariah Kelas G | 0 | 0.5 | 1.3 |
| Batavia Dana Kas Maxima | 0 | 0.4 | 1.2 |

2.4 Metode Random Forest

Random Forest merupakan algoritma supervised learning berbasis metode *bagging ensemble learning* yang digunakan untuk tugas prediksi dengan menggabungkan sejumlah pohon keputusan (Isnaini Arumnisaa & Wahyu Wijayanto, 2023). Metode *Random Forest* bekerja dengan membangun banyak pohon keputusan menggunakan teknik *bootstrap sampling*, di mana setiap pohon dilatih pada subset data yang diambil secara acak dari dataset asli (Yaman et al., 2024). Selain itu, pada setiap pemisahan node, hanya sebagian fitur yang dipilih secara acak, sehingga meningkatkan keberagaman model dan mengurangi risiko *overfitting*.

Dalam penelitian, *Random Forest* diterapkan untuk memprediksi kinerja reksa dana pasar uang berdasarkan variabel return historis, total dana kelolaan, dan *drawdown*. Hasil prediksi diperoleh dengan mengagresikan keluaran dari seluruh pohon dalam model, sehingga menghasilkan keluaran dari seluruh pohon dalam model tunggal. Pendekatan memungkinkan model menangkap pola non-linier dalam data keuangan yang bersifat dinamis.

Keunggulan penggunaan *Random Forest* terletak pada kemampuannya dalam menangani data berdimensi banyak, toleransi terhadap outlier, mengurangi risiko *overfitting*, serta kemudahan dalam mengidentifikasi kontribusi relatif setiap variabel terhadap hasil prediksi (Fauzi et al., 2025). Dalam konteks penelitian penulis, diperlukan metode yang mampu melakukan klasifikasi kinerja reksa dana secara akurat berdasarkan data historis yang kompleks. Oleh karena itu, metode *Random Forest* dinilai sesuai untuk digunakan sebagai dasar penilaian kinerja sebelum dilakukan proses rekomendasi menggunakan metode EDAS.

2.5 Metode EDAS

Metode *Evaluation Based on Distance from Average Solution* (EDAS) merupakan salah satu metode dalam Sistem Pendukung Keputusan (SPK) berbasis multikriteria untuk menyelesaikan permasalahan yang kompleks. Metode EDAS menggunakan dua ukuran utama, yaitu: *Positive Distance from Average* (PDA) dan *Negative Distance*

from Average (NDA), di mana alternatif terbaik ditentukan berdasarkan nilai PDA tertinggi dan NDA terendah (Abu Harasi & Faujan Rozi, 2024).

Adapun langkah-langkah perhitungan metode EDAS adalah sebagai berikut:

1. Perhitungan Nilai Rata-Rata Alternatif
Nilai rata-rata (*Average Solution*) setiap kriteria dihitung menggunakan Persamaan (1).

$$AV_j = \frac{\sum_{i=1}^m r_{ij}}{m}; = 1, \dots, n \quad (1)$$

2. Perhitungan Jarak Positif dan Negatif
Jarak positif dan negatif setiap alternatif terhadap nilai rata-rata dihitung dengan Persamaan (2) sampai Persmaan (5).

Untuk kriteria benefit:

$$PDA_{ij} = \max \left(0, \frac{x_{ij} - AV_j}{AV_j} \right) \quad (2)$$

$$NDA_{ij} = \max \left(0, \frac{AV_j - x_{ij}}{AV_j} \right) \quad (3)$$

Untuk kriteria cost:

$$PDA_{ij} = \max \left(0, \frac{AV_j - x_{ij}}{AV_j} \right) \quad (4)$$

$$NDA_{ij} = \max \left(0, \frac{x_{ij} - AV_j}{AV_j} \right) \quad (5)$$

3. Perhitungan Jumlah Jarak Tertimbang
Nilai *Sum of Positive Distance* (SP) dan *Sum of Negative Distance* (SN) dihitung dengan mempertimbangkan bobot kriteria seperti pada Persamaan (6) dan (7).

$$SP_i = \sum_{j=1}^n w_j \cdot PDA_{ij} \quad (6)$$

$$SN_i = \sum_{j=1}^n w_j \cdot NDA_{ij} \quad (7)$$

4. Normalisasi Jarak Positif dan Negatif
Normalisasi dilakukan untuk menyertakan skala nilai, seperti Persamaan (8) dan (9).

$$NSP_i = \frac{SP_i}{\max(SP)} \quad (8)$$

$$NSN_i = 1 - \frac{SN_i}{\max(SN)} \quad (9)$$

5. Penentuan Skor Akhir
Skor preferensi akhir (*Appraisal Score*) dihitung dengan Persamaan (10).

$$AS_i = \frac{1}{2} (NSP_i + NSN_i) \quad (10)$$

Nilai *Appraisal Score* (AS) digunakan sebagai dasar dalam proese perankingan reksa dana, di mana nilai AS tertinggi menunjukkan alternatif yang paling direkomendasikan.

Metode EDAS digunakan untuk mengevaluasi alternatif berdasarkan jaraknya dari solusi rata-rata (Sitompul et al., 2025). EDAS memiliki keunggulan dalam menangani atribut yang bersifat kontradiktif serta memberikan hasil perankingan yang stabil, mudah diinterpretasikan, dan tidak mempengaruhi akurasi perhitungan (Ariadi & Zuliarso, 2024).

Dalam penelitian, metode EDAS diintegrasikan setelah tahap prediksi kinerja reksa dana

menggunakan algoritma *Random Forest*. Hasil klasifikasi kinerja serta nilai variabel kuantitatif selanjutnya digunakan sebagai input dalam proses perhitungan EDAS untuk menentukan rekomendasi investasi. Penggunaan EDAS dalam penelitian penulis didasarkan pada kebutuhan untuk melakukan pengambilan keputusan berbasis multikriteria secara objektif, sehingga dapat menghasilkan rekomendasi investasi yang lebih komprehensif dan terstruktur.

2.6 Evaluasi Hasil

Tahap evaluasi dilakukan untuk menilai kesesuaian dan konsistensi hasil yang diperoleh dari penerapan metode *Random Forest* dan EDAS. Evaluasi bertujuan untuk memastikan bahwa hasil klasifikasi kinerja reksa dana yang dihasilkan oleh *Random Forest* selaras dengan peringkat rekomendasi investasi yang diperoleh melalui metode EDAS.

Pada metode *Random Forest*, evaluasi dilakukan dengan mengamati performa model klasifikasi berdasarkan metrik evaluasi seperti akurasi, *precision*, *recall*, dan *F1-score* (Azmi & Voutama, 2024). Sementara itu, hasil metode EDAS dievaluasi melalui analisis peringkat (ranking) dan skor preferensi (*Appraisal Score*) yang dihasilkan untuk setiap alternatif reksa dana (Helmi Damayanti Daeli, 2024).

Analisis evaluasi difokuskan pada keterkaitan antara kategori kinerja reksa dana hasil klasifikasi dan posisi peringkat rekomendasi investasi. Dengan demikian, tahap evaluasi memberikan gambaran mengenai efektivitas integrasi kedua metode dalam menghasilkan prediksi kinerja dan rekomendasi investasi yang objektif serta apa dipertanggungjawabkan secara ilmiah.

3. Hasil dan Pembahasan

3.1 Hasil Prediksi Random Forest

Pada tahap penerapan *Random Forest* dilakukan proses pengklasifikasian kinerja produk reksa dana pasar uang menggunakan algoritma *Random Forest*. Tujuan dari tahap ini adalah memetakan setiap produk ke dalam kategori kinerja Rendah, Sedang, dan Tinggi berdasarkan indikator finansial yang telah ditentukan, sehingga dapat digunakan sebagai dasar pada tahap rekomendasi investasi selanjutnya.

1. Perhitungan Skor Agregat Kinerja

Penilaian awal kinerja reksa dana dilakukan dengan menghitung Skor Agregat, yang merepresentasikan performa historis produk dalam jangka pendek hingga menengah. Skor agregat diperoleh dari rata-rata tiga indikator return utama, yaitu return 1 bulan (1M), return 3 bulan (3M), dan return 1 tahun (1Y), dengan Persamaan (11).

$$\text{Skor Agregat} = \frac{(1M+3M+1Y)}{3} \quad (11)$$

Melalui perhitungan diatas menghasilkan nilai kinerja dasar untuk masing-masing produk reksa dana. Tabel 3 menyajikan contoh hasil perhitungan skor agregat pada lima produk reksa dana pasar uang.

Tabel 3. Hasil Perhitungan Skor Agregat 5 Produk

| Produk | 1M | 3M | 1Y | Agregat Skor |
|-------------------------------|------|------|------|--------------|
| Avrist Ada Kas Mutiara | 0.49 | 1.43 | 5.68 | 2.533 |
| Bahana Dana Likuid Kelas G | 0.38 | 1.22 | 4.77 | 2.123 |
| Bahana Likuid Plus | 0.42 | 1.31 | 5.21 | 2.313 |
| Bahana Likuid Syariah Kelas G | 0.45 | 1.27 | 5.26 | 2.327 |
| Batavia Dana Kas Maxima | 0.38 | 1.19 | 4.77 | 2.113 |

2. Penentuan Kategori Kinerja Reksa Dana

Berdasarkan nilai skor agregat yang diperoleh, dilakukan pengelompokan kinerja reksa dana menggunakan pendekatan kuantil. Seluruh dataset dibagi ke dalam tiga kelompok dengan proporsi relatif seimbang, yaitu kategori Rendah, Sedang, dan Tinggi.

Pendekatan kuantil digunakan dalam penelitian penulis karena mampu membagi data secara adaptif berdasarkan distribusi nilai skor agregat, sehingga menghasilkan jumlah data yang relatif seimbang pada setiap kategori. Keseimbangan jumlah data ini penting dalam proses klasifikasi menggunakan Random Forest agar model tidak mengalami bias terhadap kelas tertentu.

Selain itu, penggunaan tiga kategori (Rendah, Sedang, dan Tinggi) dipilih untuk memberikan tingkat interpretasi yang lebih informatif dibandingkan klasifikasi biner, sekaligus tetap menjaga kompleksitas model agar tidak terlalu tinggi. Dengan demikian, model dapat menghasilkan prediksi yang lebih stabil dan mudah diinterpretasikan dalam konteks pengambilan keputusan investasi.

Produk dengan skor agregat pada sepertiga nilai terendah dikategorikan sebagai Rendah, sepertiga nilai tengah sebagai Sedang, dan sepertiga nilai tertinggi sebagai Tinggi. Rentang skor agregat untuk masing-masing kategori ditunjukkan pada Tabel 4.

Tabel 4. Kategori Berdasarkan Rentang Skor Agregat

| Kategori | Skor Agregat | Deskripsi |
|----------|------------------------------|---|
| Rendah | Skor Agregat ≤ 1.953 | Produk dengan skor agregat terendah 1/3 dari dataset, menandakan kinerja relatif rendah. |
| Sedang | 1.967 < Skor Agregat < 2.287 | Produk dengan skor agregat di kuantil tengah, menandakan kinerja sedang. |
| Tinggi | ≥ 2.313 | Produk dengan skor agregat tertinggi 1/3 dari dataset, menandakan kinerja relatif tinggi. |

Hasil pengelompokan menghasilkan label kategori kinerja yang selanjutnya digunakan sebagai variabel target dalam proses pemodelan.

Tabel 5. Hasil Kategori 5 Produk

| Produk | Agregat Skor | Kategori Produk |
|-------------------------------|--------------|-----------------|
| Avrist Ada Kas Mutiara | 2.533 | Tinggi |
| Bahana Dana Likuid Kelas G | 2.123 | Sedang |
| Bahana Likuid Plus | 2.313 | Sedang |
| Bahana Likuid Syariah Kelas G | 2.327 | Tinggi |
| Batavia Dana Kas Maxima | 2.113 | Sedang |

3. Penyusunan Fitur dan Variabel Target

Tahap berikutnya adalah penentuan variabel input (fitur) dan variabel output (target) untuk pelatihan model Random Forest. Fitur yang digunakan terdiri dari indikator return historis dan variabel risiko serta skala produk, yaitu return harian (1D), return 1 bulan (1M), return 3 bulan (3M), return Year To Date (YTD), return 1 tahun (1Y), return 3 tahun (3Y), return 5 tahun (5Y), nilai aktiva bersih terakhir (Last NAV), *drawdown* 1 tahun (Drawdown 1Y), dan *Asset Under Management* (AUM). Seluru fitur bersifat numerik dan digunakan untuk merepresentasikan kinerja risiko, dan stabilitas produk reksa dana.

Sementara itu, variabel target berupa kategori kinerja yang dihasilkan dari proses kategorisasi skor agregat ke dalam tiga kelas, yaitu Rendah, Sedang, dan Tinggi.

4. Standarisasi Data

Sebelum dilaukan pelatihan model, seluruh fitur dinormalisasi menggunakan metode standarisasi agar memiliki skala distribusi yang seragam. Proses ini bertujuan untuk meningkatkan stabilitas pembelajaran model dan mencegah dominasi fitur dengan rentang nilai yang lebih besar terhadap hasil klasifikasi.

5. Pelatihan dan Evaluasi Model *Random Forest*

Model *Random Forest* dilatih menggunakan parameter yang disesuaikan dengan karakteristik terbatas, seperti disajikan dalam Tabel 6.

Tabel 6. Parameter Model *Random Forest*

| Parameter | Nilai |
|------------------|-------|
| n_estimators | 50 |
| max_depth | 5 |
| min_samples_leaf | 2 |
| random_state | 42 |

Pengaturan parameter diatas bertujuan untuk menjaga keseimbangan antara akurasi model dan risiko overfitting.

6. Hasil Prediksi Kategori Kinerja

Setelah proses pelatihan dan evaluasi, model Random Forest digunakan untuk memprediksi kategori kinerja seluruh produk reksa dana dalam dataset. Hasil prediksi pada Tabel 7 menunjukkan tingkat kesesuaian yang tinggi antara kategori aktual dan kategori hasil prediksi.

Tabel 7. Perbandingan Kategori Aktual dan Hasil Prediksi 5 Produk

| Produk | Kategori Aktual | Prediksi RF |
|-------------------------------|-----------------|-------------|
| Avrist Ada Kas Mutiara | Tinggi | Tinggi |
| Bahana Dana Likuid Kelas G | Sedang | Sedang |
| Bahana Likuid Plus | Sedang | Sedang |
| Bahana Likuid Syariah Kelas G | Tinggi | Tinggi |
| Batavia Dana Kas Maxima | Sedang | Sedang |

Tingginya kesesuaian sejalan dengan nilai akurasi yang diperoleh pada tahap evaluasi, sehingga dapat disimpulkan bahwa model Random Forest mampu mengklasifikasikan kinerja reksa dana pasar uang secara andal dan layak digunakan sebagai dasar integrasi dengan metode EDAS pada tahap rekomendasi investasi.

3.2 Hasil Rekomendasi EDAS

Pada tahap ini, metode Evaluation Based on Distance from Average Solution (EDAS) diterapkan untuk menghasilkan peringkat dan rekomendasi produk reksa dana pasar uang berdasarkan kriteria kinerja yang relevan. Metode EDAS dipilih karena mampu mengevaluasi alternatif secara proporsional dengan membandingkan jarak setiap produk terhadap nilai rata-rata, sehingga menghasilkan keputusan yang lebih stabil pada kondisi atribut yang bersifat kontradiktif.

1. Penentuan Kriteria dan Bobot

Penentuan kriteria dan bobot pada penelitian penulis tidak dilakukan secara acak, melainkan didasarkan pada kombinasi studi literatur dan pertimbangan karakteristik kinerja reksa dana (Widiantoro et al., 2022), (Gunawan et al., 2023), dan (Tamimi & Prasetyaningrum, 2021).

Tabel 8. Acuan 6 Kriteria dan Bobot

| Kriteria | Jenis | Bobot |
|---------------------|---------|-------|
| Return 1 Bulan (1M) | Benefit | 20% |
| Return 3 Bulan (3M) | Benefit | 20% |
| Return 1 Tahun (1Y) | Benefit | 25% |
| Year-to-Date (YTD) | Benefit | 15% |
| AUM | Benefit | 10% |
| Drawdown 1Y | Cost | 10% |

Enam kriteria digunakan untuk merepresentasikan aspek return, risiko, dan stabilitas dana kelolaan, yaitu return 1 bulan (1M), return 3 bulan (3M), return 1 tahun (1Y), return year-to-date (YTD), *Asset Under Management* (AUM), dan *drawdown* 1 tahun, seperti ditampilkan pada Tabel 8. Kriteria return jangka menengah (1Y) diberikan bobot tertinggi karena dalam berbagai penelitian

dinyatakan lebih stabil dalam merepresentasikan performa investasi dibandingkan return jangka pendek. Sementara itu, return jangka pendek seperti 1M dan 3M tetap dipertimbangkan untuk menangkap dinamika pasar terkini, namun dengan bobot yang lebih rendah.

Kriteria AUM diberikan bobot sebagai indikator stabilitas dan kepercayaan investor terhadap produk, sedangkan *drawdown* 1Y diperlukan sebagai kriteria *cost* karena mencerminkan tingkat risiko kerugian. Dengan demikian, distribusi bobot yang digunakan dalam penelitian ini mencerminkan keseimbangan antara aspek return, risiko, dan stabilitas, sehingga diharapkan dapat menghasilkan rekomendasi yang lebih objektif.

2. Perhitungan Average Solution dan Jarak EDAS

Langkah awal dalam EDAS adalah menghitung *Average Solution* (AS) untuk setiap kriteria sebagai nilai acuan, sebagaimana ditampilkan pada Tabel 9.

Tabel 9. Contoh Hasil PDA dan NDA 5 Produk

| Kriteria | Nilai AS |
|-------------|-----------------------|
| 1M | 0.372 |
| 3M | 1.142 |
| 1Y | 4.730 |
| YTD | 4.155 |
| AUM | 2.731.785.172.413.790 |
| Drawdown 1Y | -0.022 |

Nilai digunakan untuk menentukan jarak positif (*Positive Distance from Average/PDA*) dan jarak negatif (*Negative Distance from Average/NDA*) bagi setiap produk. Tabel 10 memberikan ilustrasi nilai PDA dan NDA.

Tabel 10. Contoh Hasil PDA dan NDA 5 Produk

| Produk | PDA 1M | NDA 1M | PDA 3M | NDA 3M |
|-------------------------------|--------|--------|--------|--------|
| Avrist Ada Kas Mutiara | 0.118 | 0.000 | 0.288 | 0.000 |
| Bahana Dana Likuid Kelas G | 0.008 | 0.000 | 0.078 | 0.000 |
| Bahana Likuid Plus | 0.048 | 0.000 | 0.168 | 0.000 |
| Bahana Likuid Syariah Kelas G | 0.078 | 0.000 | 0.128 | 0.000 |
| Batavia Dana Kas Maxima | 0.008 | 0.000 | 0.048 | 0.000 |

PDA menunjukkan tingkat keunggulan produk dibandingkan rata-rata, sedangkan NDA mencerminkan tingkat kekurangan relatif terhadap rata-rata. Produk dengan nilai PDA yang tinggi dan NDA yang rendah memiliki performa yang lebih baik secara keseluruhan.

3. Normalisasi dan Perhitungan Skor EDAS

Nilai PDA dan NDA kemudian dinormalisasi ke dalam rentang 0-1 untuk menghilangkan perbedaan skala antar kriteria. Selanjutnya dihitung

Sum of Positive Distance (SP) dan Sum of Negative Distance (SN) sebagai jumlah tertimbang dari nilai normalisasi PDA dan NDA. Skor akhir EDAS diperoleh dari rata-rata nilai SP dan SN, yang merepresentasikan performa komprehensif setiap produk reksa dana. Tabel 11 menunjukkan hasil dari perhitungan Sum of Positive Distance (SP) dan Sum of Negative Distance (SN).

Tabel 11. Hasil SP dan SN 5 Produk

| Produk | SP | SN |
|-------------------------------|-------|-------|
| Avrist Ada Kas Mutiara | 0.753 | 0.853 |
| Bahana Dana Likuid Kelas G | 0.084 | 0.900 |
| Bahana Likuid Plus | 0.378 | 0.850 |
| Bahana Likuid Syariah Kelas G | 0.413 | 0.844 |
| Batavia Dana Kas Maxima | 0.158 | 0.900 |

4. Peringkat dan Rekomendasi Produk

Berdasarkan skor EDAS yang dihasilkan, seluruh produk reksa dana kemudian diurutkan untuk menentukan peringkat dan tingkat rekomendasi, sebagaimana ditampilkan pada Tabel 12.

Tabel 12. Aturan Peringkat dan Tingkat Rekomendasi

| Rekomendasi | Ketentuan | Keterangan |
|-------------------------|--------------------------------|---|
| Sangat Direkomendasikan | Skor ≥ 0.80 | Produk memiliki kinerja yang sangat baik pada sebagian besar kriteria; PDA tinggi dan NDA rendah. Cocok sebagai pilihan utama. |
| Direkomendasikan | $0.70 \leq \text{Skor} < 0.85$ | Produk menunjukkan performa stabil dan unggul pada beberapa aspek. Layak dipilih dengan tingkat kepercayaan tinggi. Produk berada pada tingkat kinerja menengah. Beberapa indikator baik, namun tidak dominan di seluruh kriteria. Perlu pertimbangan tambahan. |
| Dipertimbangkan | $0.50 \leq \text{Skor} < 0.70$ | Produk memiliki performa relatif rendah atau kurang konsisten dibanding produk lainnya. Tidak disarankan sebagai pilihan utama. |
| Kurang Direkomendasikan | Skor < 0.50 | |

Produk dengan skor EDAS tertinggi dikategorikan sebagai sangat direkomendasikan, diikuti oleh kategori direkomendasikan, dipertimbangkan, dan kurang direkomendasikan. Hasil menunjukkan bahwa beberapa produk dengan kinerja return yang konsisten serta risiko yang relatif rendah menempati peringkat teratas, sedangkan produk dengan performa kurang stabil atau drawdown yang lebih tinggi berada pada peringkat bawah. Hasil akhir peringkat dan rekomendasi produk ditunjukkan pada Tabel 13.

Secara keseluruhan, penerapan metode EDAS berhasil memberikan rekomendasi investasi yang objektif dan terukur dengan mempertimbangkan berbagai kriteria kinerja secara simultan.

Tabel 13. Hasil Akhir Peringkat dan Rekomendasi 5 Produk

| Produk | EDAS Score | Rank Produk | Rekomendasi Produk |
|-------------------------------|------------|-------------|-------------------------|
| Avrist Ada Kas Mutiara | 0.803 | 1 | Sangat Direkomendasikan |
| Bahana Dana Likuid Kelas G | 0.492 | 18 | Kurang Direkomendasikan |
| Bahana Likuid Plus | 0.614 | 9 | Dipertimbangkan |
| Bahana Likuid Syariah Kelas G | 0.629 | 8 | Dipertimbangkan |
| Batavia Dana Kas Maxima | 0.529 | 15 | Dipertimbangkan |

3.3 Evaluasi Hasil

Evaluasi hasil penelitian dilakukan untuk menilai kinerja metode yang diusulkan, yaitu *Random Forest* dalam melakukan penilaian kinerja reksa dana pasar uang dan metode EDAS dalam memberikan rekomendasi produk investasi. Evaluasi difokuskan pada dua aspek utama, yaitu akurasi klasifikasi kinerja dan konsistensi hasil rekomendasi.

1. Evaluasi Penilaian Kinerja Random Forest

Evaluasi model *Random Forest* dilakukan menggunakan confusion matrix serta metrik evaluasi klasifikasi yang meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Evaluasi bertujuan untuk mengukur kemampuan model dan mempelajari pola data dan mengklasifikasikan kinerja reksa dana ke dalam tiga kategori, yaitu Rendah, Sedang, dan Tinggi.

Tabel 14. Classification Report

| Label | Precision | Recall | F1-Score | Support |
|--------|-----------|--------|----------|---------|
| Rendah | 1.00 | 1.00 | 1.00 | 10 |
| Sedang | 1.00 | 1.00 | 1.00 | 9 |
| Tinggi | 1.00 | 1.00 | 1.00 | 10 |

Hasil evaluasi pada data pelatihan menunjukkan bahwa model mampu mengklasifikasikan seluruh data dengan sangat baik, ditunjukkan oleh nilai *accuracy*, *precision*, *recall*, dan *F1-score* sebesar 1.00 untuk seluruh kelas, seperti diilustrasikan pada Tabel 14.

Tabel 15. Confusion Matrix

| Aktual | Prediksi Rendah | Prediksi Sedang | Prediksi Tinggi |
|--------|-----------------|-----------------|-----------------|
| Rendah | 10 | 0 | 0 |
| Sedang | 0 | 9 | 0 |
| Tinggi | 0 | 0 | 10 |

Confusion matrix pada Tabel 15 menunjukkan tidak adanya kesalahan klasifikasi pada setiap kategori kinerja, yang mengindikasikan bahwa model berhasil menangkap pola hubungan antar variabel return, risiko, dan dana kelolaan dengan kategori kinerja yang telah ditentukan. Namun, untuk

menghindari bias evaluasi akibat penggunaan data pelatihan, dilakukan evaluasi tambahan menggunakan *Stratified 5-Fold Cross Validation*, seperti ditunjukkan pada Tabel 16. Metode *Stratified 5-Fold Cross Validation* digunakan untuk menjaga proporsi kelas pada setiap fold sehingga hasil evaluasi lebih representatif.

Tabel 16. Stratified 5-Fold Cross Validation

| Fold | Akurasi |
|------------------|--------------|
| 1 | 0.833 |
| 2 | 1.000 |
| 3 | 1.000 |
| 4 | 0.833 |
| 5 | 1.000 |
| Rata-rata | 0.933 |

Hasil *cross-validation* menunjukkan rata-rata akurasi sebesar 93,33%, yang menandakan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* secara signifikan.

Berdasarkan hasil tersebut, Random Forest dinilai efektif dan stabil dalam melakukan penilaian kinerja reksa dana pasar uang berbasis data historis.

2. Evaluasi Hasil Rekomendasi EDAS

Evaluasi metode EDAS dilakukan dengan menganalisis peringkat dan skor EDAS yang dihasilkan untuk setiap produk reksa dana. Penilaian difokuskan pada konsistensi hasil rekomendasi terhadap indikator kinerja yang digunakan, yaitu return jangka pendek dan menengah, *Year-To-Date* (YTD), *Asset Under Management* (AUM), serta risiko yang direpresentasikan oleh drawdown satu tahun.

Tabel 17. Hasil Peringkat dan Rekomendasi EDAS 5 Produk

| Produk | EDAS Score | Rank Produk | Rekomendasi Produk |
|----------------------------|------------|-------------|-------------------------|
| Avrist | 0.803 | 1 | Sangat Direkomendasikan |
| Ada Kas Mutiara Bahana | | | |
| Dana Likuid Kelas G Bahana | | | |
| Likuid Plus Bahana | 0.492 | 18 | Kurang Direkomendasikan |
| Likuid Kelas G Bahana | | | |
| Likuid Plus Bahana | 0.614 | 9 | Dipertimbangkan |
| Likuid Syariah Kelas G | | | |
| Batavia | 0.629 | 8 | Dipertimbangkan |
| Dana Kas Maxima | | | |
| Dana Kas Maxima | 0.529 | 15 | Dipertimbangkan |
| Maxima | | | |

Hasil perhitungan EDAS pada Tabel 17 menunjukkan bahwa produk dengan nilai return yang relatif tinggi, *drawdown* yang rendah, serta AUM yang besar cenderung memperoleh skor EDAS yang lebih tinggi dan menempati peringkat teratas. Sebaliknya, produk dengan performa return yang lebih rendah atau risiko yang lebih tinggi memperoleh skor EDAS yang lebih kecil dan masuk dalam kategori rekomendasi yang lebih rendah.

Kesesuaian hasil rekomendasi EDAS dengan hasil penilaian kinerja menggunakan Random Forest menunjukkan bahwa metode EDAS mampu memberikan rekomendasi yang rasional dan konsisten berdasarkan kriteria yang telah ditetapkan.

4. Kesimpulan

Penelitian mengintegrasikan metode *Random Forest* untuk klasifikasi kinerja reksa dana pasar uang dan metode EDAS untuk menghasilkan rekomendasi investasi. Hasil pengujian menunjukkan bahwa *Random Forest* mampu mengklasifikasikan data ke dalam kategori Rendah, Sedang, dan Tinggi dengan performa sangat baik, ditunjukkan oleh nilai akurasi, *precision*, *recall*, dan *F1-score* sebesar 1.00 serta rata-rata akurasi 93,33% pada *5-fold cross-validation*, yang mengindikasikan model memiliki kemampuan generalisasi yang baik.

Penerapan metode EDAS menghasilkan peringkat dan rekomendasi investasi berdasarkan enam kriteria utama, di mana produk dengan kinerja tinggi cenderung memperoleh skor EDAS yang lebih besar. Hal ini menunjukkan konsistensi antara hasil klasifikasi berbasis machine learning dan sistem pendukung keputusan. Dengan demikian, integrasi *Random Forest* dan EDAS terbukti efektif dalam memberikan evaluasi kinerja dan rekomendasi investasi yang objektif dan sistematis.

Meskipun penelitian menunjukkan hasil yang baik, terdapat beberapa keterbatasan yang perlu diperhatikan. Pertama, penelitian menggunakan jumlah dan jenis data yang masih terbatas pada reksa dana pasar uang, sehingga hasil yang diperoleh belum tentu dapat digeneralisasikan pada jenis reksa dana lainnya. Kedua, penentuan bobot pada metode pada metode EDAS masih didasarkan pada studi literatur dan asumsi peneliti, sehingga berpotensi mengandung subjektivitas dalam proses pengambilan keputusan. Ketiga, variabel yang digunakan dalam penelitian penulis masih terbatas pada data historis kinerja dan belum mempertimbangkan faktor eksternal seperti kondisi makroekonomi, suku bunga, maupun sentimen pasar yang dapat mempengaruhi kinerja reksa dana.

Berdasarkan keterbatasan tersebut, penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih luas dan beragam, mencakup berbagai jenis reksa dana agar hasil penelitian menjadi lebih generalizable. Selain itu, metode penentuan bobot dapat dikembangkan menggunakan pendekatan yang lebih objektif, seperti metode AHP atau teknik pembobotan berbasis optimasi. Penelitian selanjutnya juga dapat mempertimbangkan penambah variabel eksternal, seperti indikator ekonomi makro dan volatilitas pasar, guna meningkatkan akurasi model serta kualitas rekomendasi yang dihasilkan. Dengan pengembangan tersebut, sistem yang diusulkan diharapkan menjadi lebih adaptif dan mampu memberikan rekomendasi investasi yang lebih komprehensif.

Daftar Pustaka:

- Abu Harasi, A., & Faujan Rozi, A. (2024). Sistem Pendukung Keputusan Penentuan Calon Penerima Bantuan Program Pedagang Menggunakan Metode Evaluation Based On Distance From Average Solution. *Jurnal Information System & Artificial Intellince*, 4(2), 144–152.
- Ariadi, H., & Zuliarso, E. (2024). Sistem Rekomendasi Pemilihan Mobil Menggunakan Metode Edas. *Jurnal Teknik Informatika Unika ST. Thomas*, 09(01), 59–66.
- Azmi, A. F., & Voutama, A. (2024). Prediksi Churn Nasabah Bank Menggunakan Klasifikasi Random Forest Dan Decision Tree Dengan Evaluasi Confusion Matrix. *KOMPUTA : Jurnal Ilmiah Komputer Dan Informatika*, 13(1), 111–119.
- Fauzi, A., Maulidah, N., Supriyadi, R., Nalatissifa, H., & Diantika, S. (2025). Prediksi Harga Properti Di Indonesia Menggunakan Algoritma Random Forest. *Journal of Artificial Intelligence and Digital Business*, 4(1), 43–49.
- Gunawan, R. D., Ariany, F., & Novriyadi. (2023). Implementasi Metode SAW Dalam Sistem Pendukung Keputusan Pemilihan Plano Kertas. *Journal of Artificial Intelligence and Technology Information (JAITI)*, 1(1), 29–38. <https://doi.org/https://doi.org/10.58602/jaiti.v1i1.23>
- Hadi, M. F., Hairani, H., Wijaya, H., & Vidiyari, H. (2025). Penerapan SMOTE dan Random Forest dalam Klasifikasi Tren Harga Saham Harian: Studi Kasus Saham PT Telkom Indonesia Tbk (TLKM). *Seminar Nasional CORISIONDO*, 79–83. <https://doi.org/https://doi.org/10.30812/corisiondo.v1.5267>
- Helmi Damayanti Daeli, N. (2024). Sistem Pendukung Keputusan Pemilihan Perawat Terbaik Menggunakan Kombinasi Metode AHP-EDAS. *Jurnal Ilmu Komputer Dan Teknologi Informasi*, 02(03), 20–29. <https://doi.org/10.70404/jikteks.v2i03.109>
- Isnaini Arumnisaa, R., & Wahyu Wijayanto, A. (2023). Perbandingan Metode Ensemble Learning: Random Forest, Support Vector Machine, AdaBoost pada Klasifikasi Indeks Pembangunan Manusia (IPM). *Jurnal Sistem Informasi*, 12(1), 206–218.
- Kadori, I., Meyasha, I., Virgiyanti, & Anggraeni, N. (2025). Implementasi Metode Edas Dalam Memilih Investasi Di Sektor Pertanian. *INFOKOM: Jurnal Informasi Dan Teknologi*, 18(1), 26–32. https://jurnal.stikompoltekcirebon.ac.id/index.php/file_jurnal/article/view/144
- Otoritas Jasa Keuangan. (2022). *SIARAN PERS Survei Nasional Literasi Dan Inklusi Keuangan Tahun 2022*. Ojk.Go.Id. https://ojk.go.id/id/berita-dan-kegiatan/siaran-pers/Pages/Survei-Nasional-Literasi-dan-Inklusi-Kuangan-Tahun-2022.aspx?utm_source=chatgpt.com
- Pradini, A. Y. (2023). Risk and Return Money Saving di Reksadana dan Bank Digital. *Journal of Indonesian Sharia Economics*, 2(2), 209–222. <https://doi.org/https://doi.org/10.35878/jiose.v2i2.899>
- Rangga Aditya Tarigan, L., & Dahlan. (2024). Optimalisasi Fitur Dengan Forward Selection Pada Estimasi Tingkat Penyakit Paru-Paru Menggunakan Algoritma Klasifikasi Random Forest. *Jurnal Mahasiswa Teknik Informatika*, 8(5), 10341–10348.
- Sabila, P. C., & Alasi, T. S. (2023). Metode EDAS untuk Penerimaan Pegawai Baru berbasis Web dan Real Time. *Media Informasi Analisa Dan Sistem*, 8(1), 133–139.
- Sitompul, S. C., Nadza, R., Sihotang, F., Syahputra, T., & Budiman, A. (2025). Sistem Pendukung Keputusan Pemilihan Hotel Terbaik Di Kota Medan Menggunakan Metode EDAS. *Jurnal Ilmu Komputer Dan Sistem Informasi*, 4(1), 68–77.
- Tamimi, K., & Prasetyaningrum, P. T. (2021). Sistem Pendukung Keputusan Rekomendasi Makanan Bernutrisi Bagi Penderita Gizi Buruk Menggunakan Metode Edas. *Jurnal Information System & Artificial Intellince*, 2(1), 22–30.
- Usman, B., Sari, W., & Amalia, W. (2023). Perilaku Investor Individu Terhadap Pengambilan Keputusan Investasi. *Journal of Management*, 4(2), 224–234. <https://doi.org/https://doi.org/10.37010/jdc.v4i2>
- Widiantoro, R., Astuti, I. P., & Buntoro, G. A. (2022). Sistem Pendukung Keputusan Rekomendasi Reksa Dana Obligasi Menggunakan Metode SAW (Simple Additive Weighting). *Fountain of Informatics Journal*, 7(2), 64–72. <https://doi.org/http://dx.doi.org/10.21111/fij.v7i2.8339>
- Yaman, N. I., Juwita, A. R., Arum, S., Lestari, P., & Faisal, S. (2024). Perbandingan Kinerja Algoritma Decision Tree dan Random Forest untuk Klasifikasi Nutrisi pada Makanan Cepat Saji. *Jurnal Algoritma*, 21(2), 184–195. <https://doi.org/10.33364/algoritma/v.21-2.1649>

Halaman ini sengaja dikosongkan
