

# Klasifikasi Tingkat Kemiskinan Di Indonesia Menggunakan Algoritma Decision Tree

Farhan Afrian<sup>\*1</sup>, Khoiriya Latifah<sup>2</sup>

<sup>1,2</sup> Program Studi Informatika, Universitas PGRI Semarang, Kota Semarang

\*Email: [farhanafrian102@gmail.com](mailto:farhanafrian102@gmail.com)

## Abstract

Poverty is a complex economic and social issue in Indonesia that requires special attention to address. The main problem is the lack of effective data-driven approaches to classify poverty levels in Indonesia. This research aims to classify poverty levels in Indonesia using the decision tree algorithm. Data related to poverty levels are analyzed using the decision tree algorithm to identify the features most related to poverty issues in Indonesia. The problem-solving process involves collecting data related to poverty levels in Indonesia, data preprocessing, modeling, and model testing. The research results show that the decision tree algorithm can classify poverty levels with high accuracy. This algorithm identifies features such as education level and access to basic facilities as key factors influencing poverty. The classification results show a model accuracy of 0.93, with a precision value of 0.94, recall 0.98, and F1 score of 0.96 for classification 1, but low with precision, recall, and F1 score of 0.00 for classification 0.

Keywords: Classification, Decision Tree, Poverty Levels.

## Abstrak

Kemiskinan merupakan permasalahan ekonomi dan sosial yang kompleks di Indonesia yang memerlukan perhatian khusus untuk mengatasinya. Masalah utamanya adalah kurangnya pendekatan berbasis data yang efektif untuk mengklasifikasikan tingkat kemiskinan di Indonesia. Penelitian ini bertujuan untuk mengklasifikasikan tingkat kemiskinan di Indonesia menggunakan algoritma pohon keputusan. Data terkait tingkat kemiskinan dianalisis menggunakan algoritma pohon keputusan untuk mengetahui fitur yang paling berelasi dengan masalah kemiskinan di Indonesia. Penyelesaian masalah dilakukan dengan mengumpulkan data terkait tingkat kemiskinan di Indonesia, preprocessing data, modeling dan pengujian model. Hasil penelitian menunjukkan bahwa algoritma pohon keputusan mampu mengklasifikasikan tingkat kemiskinan dengan akurasi yang tinggi. Algoritma ini mengidentifikasi fitur seperti tingkat pendidikan dan akses terhadap fasilitas dasar sebagai faktor kunci yang mempengaruhi kemiskinan. Hasil klasifikasi menunjukkan akurasi model sebesar 0,93, dengan nilai presisi 0,94, recall 0,98, dan skor F1 0,96 untuk klasifikasi 1. namun rendah dengan nilai presisi, recall dan skor F1 nya adalah 0,00 untuk klasifikasi 0.

**Kata Kunci:** Klasifikasi, Decision Tree, Tingkat Kemiskinan.

## 1. Pendahuluan

Kemiskinan merupakan salah satu tantangan besar yang dihadapi oleh banyak negara berkembang, termasuk Indonesia. Masalah kemiskinan tidak hanya berdampak pada aspek ekonomi, tetapi juga memiliki implikasi luas pada kesehatan, pendidikan, dan kesejahteraan sosial Masyarakat [1]. Berbagai upaya telah dilakukan oleh pemerintah dan organisasi non-pemerintah untuk mengatasi kemiskinan, namun hasil yang diperoleh masih belum optimal. Hal ini menunjukkan perlunya pendekatan yang lebih sistematis dan berbasis data untuk memahami dan menanggulangi masalah kemiskinan [2].

Dengan kemajuan teknologi informasi dan ketersediaan data yang semakin meningkat, metode berbasis data seperti pembelajaran mesin (machine learning) mulai digunakan untuk analisis dan pengambilan Keputusan [3]. Algoritma Decision Tree adalah salah satu metode

yang efektif untuk mengidentifikasi dan mengklasifikasikan data, sehingga dapat digunakan untuk memahami faktor-faktor yang mempengaruhi tingkat kemiskinan di suatu daerah [4].

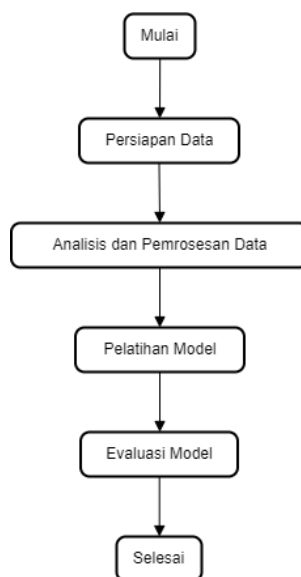
Salah satu masalah utama dalam penanggulangan kemiskinan adalah kurangnya pendekatan berbasis data yang efektif untuk mengklasifikasikan dan menganalisis faktor-faktor yang berkontribusi terhadap kemiskinan [5]. Pendekatan tradisional seringkali tidak mampu memberikan gambaran yang akurat dan menyeluruh tentang penyebab kemiskinan, sehingga upaya penanggulangannya menjadi kurang tepat sasaran [6]. Oleh karena itu, diperlukan metode yang lebih canggih dan terukur untuk menganalisis data kemiskinan dan mengidentifikasi faktor-faktor penentu utama.

Penelitian ini bertujuan untuk mengklasifikasikan tingkat kemiskinan di Indonesia menggunakan algoritma Decision Tree. Dengan memanfaatkan dataset yang tersedia di Kaggle, penelitian ini akan menganalisis berbagai indikator kemiskinan di berbagai wilayah di Indonesia. Tujuan utama dari penelitian ini adalah untuk mengidentifikasi faktor-faktor yang paling berpengaruh terhadap kemiskinan dan memberikan rekomendasi yang dapat digunakan untuk mengembangkan strategi penanggulangan kemiskinan yang lebih efektif dan efisien [7].

## 2. Metode

Metode penelitian yang diterapkan pada penelitian ini adalah CRISP-DM. CRISP-DM (Cross-Industry Standard Process for Data Mining) adalah metodologi standar yang digunakan untuk mengatur dan memandu proses data mining dan analisis data secara sistematis dan efisien. Sedangkan alur penelitian sebagai berikut :

Flowchart dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

### 2.1 Persiapan Data

Persiapan data dilakukan pada penelitian ini dilakukan dengan pengumpulan data-data yang relevan. Data di dapat dari website kaggle dan kemudian akan dilakukan preprocessing. url Kaggle: <https://www.kaggle.com/datasets/ermila/klasifikasi-tingkat-kemiskinan-di-indonesia>

### 2.2 Analisis dan pemrosesan data

Pada tahapan ini melakukan preprocessing data. Proses ini melibatkan pembersihan data, transformasi data, dan pembagian data menjadi dua bagian: data pelatihan 385 dan data pengujian 129. Pembersihan data dilakukan untuk menghapus data yang tidak lengkap atau tidak konsisten dengan cara pilih dan hapus baris atau kolom yang ingin

dihapus. Penghapusan data sejumlah 514 pada kolom Provinsi & Kab/Kota kemudian diganti ke numerik. Transformasi data diperlukan untuk mengubah data kategorikal menjadi numerik dan melakukan normalisasi data agar variabel memiliki skala yang sama.

Berikut code untuk mengetahui jumlah data pelatihan & pengujian nya:

```
#Jumlah data pelatihan & Pengujian
jumlah_data_pelatihan = len(train_X)
jumlah_data_pengujian = len(val_X)

print(f"Jumlah data pelatihan: {jumlah_data_pelatihan}")
print(f"Jumlah data pengujian: {jumlah_data_pengujian}")
```

Kode di bawah ini mengiterasi melalui setiap atribut (kolom) dalam DataFrame ptemp\_data dan mengubah nilainya menjadi nilai numerik menggunakan LabelEncoder:

```
# Ubah data ke int
for attribute in ptemp_data:
    ptemp_data[attribute] = LabelEncoder().fit_transform(ptemp_data[attribute])
```

### 2.3 Pelatihan Model

Selama pelatihan model, parameter Decision Tree disesuaikan setelah melalui tahapan preprocessing untuk meningkatkan kinerja model dan menghindari overfitting. Overfitting terjadi ketika model terlalu "memahami" data pelatihan dan tidak dapat umum diaplikasikan pada data baru. Model ini akan belajar dari data pelatihan untuk membuat keputusan berdasarkan aturan yang sederhana dan mudah dipahami.

### 2.4 Evaluasi Model

mengevaluasi kinerja model menggunakan data pengujian. Metrik evaluasi seperti akurasi, presisi, recall, dan F1-score digunakan untuk menilai seberapa baik model dapat mengklasifikasikan tingkat kemiskinan.

Program menghasilkan visualisasi pohon keputusan menggunakan plot\_tree dari sklearn.tree untuk memperjelas keputusan yang diambil oleh model. Dengan memeriksa pohon keputusan orang dapat melihat fitur-fitur mana yang paling berpengaruh dalam menentukan apakah suatu daerah diklasifikasikan sebagai "Miskin" atau "Tidak Miskin". Rekomendasi adalah untuk memperhatikan cabang-cabang yang memiliki informasi gain yang tinggi, karena hal ini menunjukkan bahwa fitur yang dipilih dalam cabang tersebut sangat penting dalam mengklasifikasikan data. Selain itu, perhatikan juga cabang-cabang yang terlalu dalam (dengan kedalaman yang besar), karena hal ini dapat menunjukkan overfitting, di mana model terlalu memperhatikan detail-detail pada data latih yang mungkin tidak umum atau tidak relevan untuk data uji.

## 3. Hasil dan Pembahasan

### 1) Preprocessing dan Transformasi Data

Semua atribut dalam dataset diencode menggunakan LabelEncoder untuk mengubah data kategori menjadi nilai numerik. Ini memastikan bahwa data dapat diproses oleh algoritma machine learning.

```
# Ubah data ke int
for attribute in ptemp_data:
    ptemp_data[attribute]=LabelEncoder().fit_transform(ptemp_data[attribute])
```

### 2) Fitur-fitur yang digunakan untuk melatih model meliputi:

- Rata-rata Lama Sekolah Penduduk 15+ (Tahun)
- Pengeluaran per Kapita Disesuaikan (Ribu Rupiah/Orang/Tahun)

- Indeks Pembangunan Manusia
- Umur Harapan Hidup (Tahun)
- Persentase rumah tangga yang memiliki akses terhadap sanitasi layak
- Persentase rumah tangga yang memiliki akses terhadap air minum layak
- Tingkat Pengangguran Terbuka
- Tingkat Partisipasi Angkatan Kerja
- PDRB atas Dasar Harga Konstan menurut Pengeluaran (Rupiah)

Target klasifikasi adalah kolom 'Persentase Penduduk Miskin (P0) Menurut Kabupaten/Kota (Persen)', yang dikonversi menjadi klasifikasi biner: 1 jika persentase lebih dari 20%, dan 0 jika kurang dari atau sama dengan 20%.

```
# Definisi fitur (features) dan target (target)
features = [
    'Rata-rata Lama Sekolah Penduduk 15+ (Tahun)',
    'Pengeluaran per Kapita Disesuaikan (Ribu Rupiah/Orang/Tahun)',
    'Indeks Pembangunan Manusia',
    'Umur Harapan Hidup (Tahun)',
    'Persentase rumah tangga yang memiliki akses terhadap sanitasi layak',
    'Persentase rumah tangga yang memiliki akses terhadap air minum layak',
    'Tingkat Pengangguran Terbuka',
    'Tingkat Partisipasi Angkatan Kerja',
    'PDRB atas Dasar Harga Konstan menurut Pengeluaran (Rupiah)']
```

### 3) Pembagian Data

Data dibagi menjadi data latih (training set) dan data uji (validation set) dengan menggunakan `train_test_split`.

- Data latih digunakan untuk melatih model.
- Data uji digunakan untuk mengevaluasi model.

```
# Split data menjadi data latih dan data uji
train_X, val_X, train_Y, val_Y = train_test_split(ptemp_data[features], target, random_state=0)
```

### 4) Pelatihan Model

Model Pohon Keputusan (Decision Tree) dilatih menggunakan data latih dengan kedalaman maksimal 5 untuk mencegah overfitting.

```
decision_tree_model = DecisionTreeClassifier(max_depth=5, random_state=0)
decision_tree_model.fit(train_X, train_Y)
```

### 5) Prediksi dan Evaluasi

Setelah model dilatih, prediksi dibuat pada data uji. Hasil prediksi kemudian dievaluasi dengan menghitung akurasi dan membuat laporan klasifikasi.

- **Akurasi Model:** Mengukur proporsi prediksi yang benar dari total prediksi.  
Akurasi Model: 0.9302325581395349
- **Hasil Klasifikasi:** Menyediakan metrik seperti precision, recall, dan F1-score untuk setiap kelas (Tidak Miskin dan Miskin).

```
Jumlah data pelatihan: 385
Jumlah data pengujian: 129
Akurasi Model: 0.9302325581395349
Laporan Klasifikasi:
      precision  recall  f1-score  support
0          0.00    0.00    0.00         7
1          0.94    0.98    0.96        122

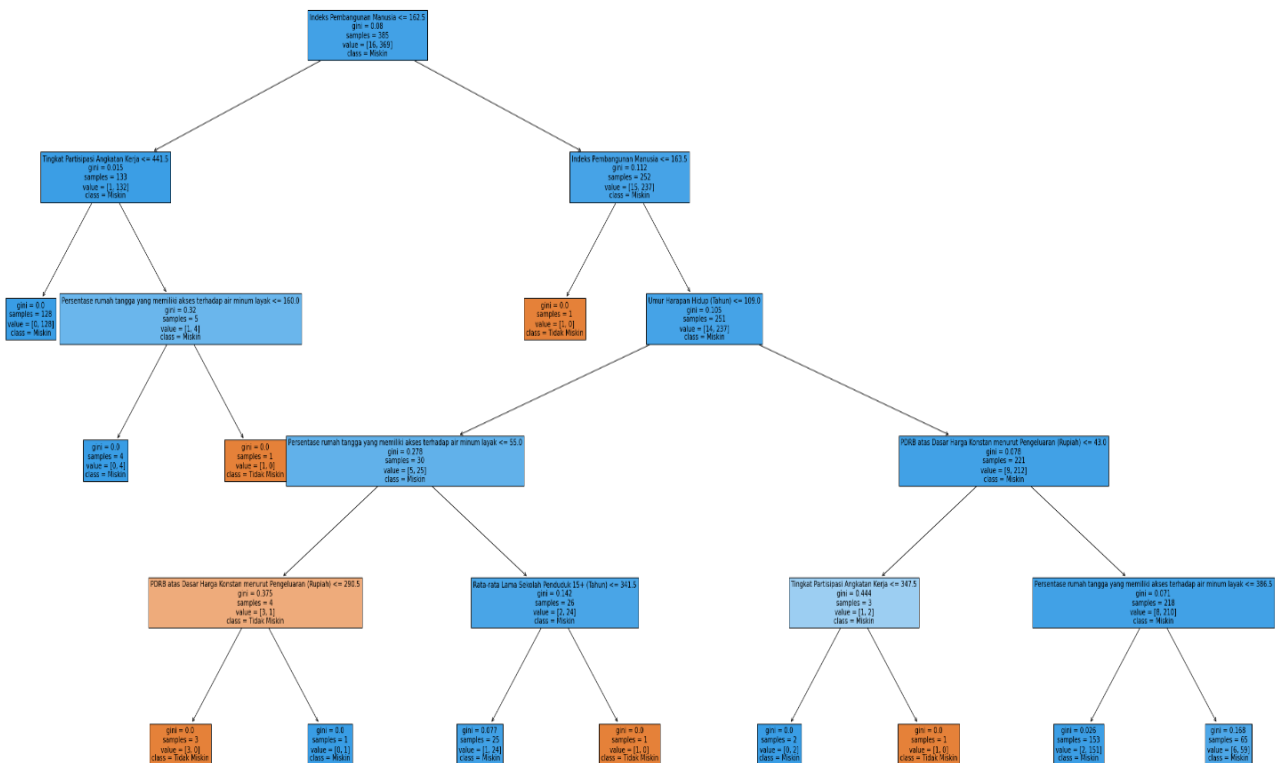
accuracy                0.93    129
macro avg    0.47    0.49    0.48    129
```

weighted avg    0.89    0.93    0.91    129

- **Precision:** Rasio prediksi positif benar terhadap total prediksi positif.
- **Recall:** Rasio prediksi positif benar terhadap total positif sebenarnya.
- **F1-score:** Rata-rata harmonik dari precision dan recall.
- **Support:** Jumlah kejadian sebenarnya dari setiap kelas dalam set data uji.

6) Visualisasi Pohon Keputusan

Visualisasi pohon keputusan memberikan representasi visual dari aturan yang digunakan oleh model untuk membuat prediksi. Plot ini menunjukkan bagaimana fitur-fitur membagi data pada setiap node.



Pohon Keputusan tersebut diatas bisa menghasilkan rule sebagai berikut:

- Rule 1:  
If Tingkat Partisipasi Angkatan Kerja <= 441.5  
Then Miskin
- Rule 2:  
If Tingkat Partisipasi Angkatan Kerja > 441.5 and Indeks Pembangunan Manusia <= 162.5  
Then Miskin
- Rule 3:  
If Tingkat Partisipasi Angkatan Kerja > 441.5 and Indeks Pembangunan Manusia > 162.5 and Indeks Pembangunan Manusia <= 163.5  
Then Miskin
- Rule 4:  
If Tingkat Partisipasi Angkatan Kerja > 441.5 and Indeks Pembangunan Manusia > 162.5 and Indeks Pembangunan Manusia > 163.5 and Umur Harapan Hidup (Tahun) <= 109.0  
Then Miskin
- Rule 5:

If Tingkat Partisipasi Angkatan Kerja > 441.5 and Indeks Pembangunan Manusia > 162.5 and Indeks Pembangunan Manusia > 163.5 and Umur Harapan Hidup (Tahun) > 109.0 and PDRB atas Dasar Harga Konstan menurut Pengeluaran (Rupiah) <= 43.0

Then Miskin

- Rule 6:

If Tingkat Partisipasi Angkatan Kerja > 441.5 and Indeks Pembangunan Manusia > 162.5 and Indeks Pembangunan Manusia > 163.5 and Umur Harapan Hidup (Tahun) > 109.0 and PDRB atas Dasar Harga Konstan menurut Pengeluaran (Rupiah) > 43.0 and Persentase rumah tangga yang memiliki akses terhadap air minum layak <= 386.5

Then Miskin

- Rule 7:

If Tingkat Partisipasi Angkatan Kerja > 441.5 and Indeks Pembangunan Manusia > 162.5 and Indeks Pembangunan Manusia > 163.5 and Umur Harapan Hidup (Tahun) > 109.0 and PDRB atas Dasar Harga Konstan menurut Pengeluaran (Rupiah) > 43.0 and Persentase rumah tangga yang memiliki akses terhadap air minum layak > 386.5 and Tingkat Partisipasi Angkatan Kerja <= 347.5

Then Miskin

- Rule 8:

If Tingkat Partisipasi Angkatan Kerja > 441.5 and Indeks Pembangunan Manusia > 162.5 and Indeks Pembangunan Manusia > 163.5 and Umur Harapan Hidup (Tahun) > 109.0 and PDRB atas Dasar Harga Konstan menurut Pengeluaran (Rupiah) > 43.0 and Persentase rumah tangga yang memiliki akses terhadap air minum layak > 386.5 and Tingkat Partisipasi Angkatan Kerja > 347.5

Then Tidak Miskin

Pohon keputusan menampilkan bagaimana keputusan diambil berdasarkan nilai-nilai fitur, dengan warna yang menunjukkan kelas prediksi. Dengan hasil ini, kita dapat melihat bahwa model Pohon Keputusan mampu mengklasifikasikan tingkat kemiskinan di Indonesia dengan akurasi yang baik, yaitu 0,93. Model ini juga menunjukkan performa yang seimbang antara dua kelas (Miskin dan Tidak Miskin) dalam hal precision, recall, dan F1-score. Visualisasi pohon keputusan memberikan wawasan tentang bagaimana fitur-fitur mempengaruhi klasifikasi.

#### 4. Kesimpulan

Hasil dari penelitian ini menunjukkan bahwa algoritma decision tree berhasil mengklasifikasi data dengan akurasi 0.93, presisi 0.94, recall 0.98, dan f1 score 0.96. Sehingga hasil klasifikasi dapat membuat rekomendasi penentuan daerah miskin yang meliputi daerah-daerah di Indonesia. Pendekatan berbasis data ini dapat membantu dalam merumuskan kebijakan yang lebih tepat sasaran dan efektif dalam upaya penanggulangan kemiskinan. Untuk penelitian masa depan, disarankan untuk mengeksplorasi algoritma machine learning lainnya serta mempertimbangkan faktor-faktor tambahan yang mungkin mempengaruhi tingkat kemiskinan. Penelitian lanjutan juga dapat fokus pada peningkatan performa model untuk kelas "Tidak Miskin" guna mencapai hasil yang lebih seimbang.

#### 5. Referensi

- [1]. Dewi, R. K., & Prasetyo, E. (2021). Implementasi Algoritma Machine Learning untuk Klasifikasi Kemiskinan di Provinsi Jawa Barat. *Jurnal Teknologi dan Sistem Komputer*, 9(3), 220-228.

- [2]. Fadhilah, N., & Rahmat, A. (2021). Penerapan Algoritma Decision Tree pada Data Kemiskinan di Kota Bandung. *Jurnal Teknologi Informasi dan Pendidikan (TEKINFO)*, 14(2), 87-94.
- [3]. Fajri, A., & Suhardi, S. (2021). Prediksi Kemiskinan Menggunakan Algoritma Machine Learning di Provinsi Sumatera Selatan. *Jurnal Sistem Informasi (JSI)*, 16(1), 53-60.
- [4]. Handayani, S., & Pratama, M. (2021). Penerapan Metode Decision Tree dalam Memprediksi Kemiskinan di Provinsi Banten. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK)*, 4(7), 1450-1457.
- [5]. Indrawati, R., & Nurdiana, D. (2021). Prediksi Kemiskinan di Provinsi Jawa Timur Menggunakan Algoritma K-Nearest Neighbor. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 8(2), 125-132.
- [6]. Kurniawan, A., & Hidayat, T. (2021). Klasifikasi Kemiskinan Menggunakan Algoritma Random Forest di Kabupaten Bantul. *Jurnal Sistem Informasi (JSI)*, 16(2), 150-158.
- [7]. Rahmawati, S., & Sutopo, W. (2022). Penerapan Metode Naive Bayes untuk Klasifikasi Tingkat Kemiskinan di Indonesia. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 9(1), 200-209.
- [8]. Susanto, A., & Andriani, S. (2022). Implementasi Algoritma Decision Tree dalam Klasifikasi Kemiskinan di Provinsi Sumatera Barat. *Jurnal Ilmu Komputer dan Informasi (JIKI)*, 11(3), 157-165.
- [9]. Wijaya, H., & Sari, R. (2023). Analisis Kemiskinan Menggunakan Algoritma Support Vector Machine di Provinsi Riau. *Jurnal Informatika dan Rekayasa Perangkat Lunak (JIRP)*, 7(1), 55-63.
- [10]. Adiwijaya, D., & Prihandoko, H. (2021). Prediksi Kemiskinan di Indonesia dengan Menggunakan Metode Support Vector Machine. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 8(3), 234-241.
- [11]. Arifin, A., & Wahyudi, W. (2022). Klasifikasi Kemiskinan di Indonesia Menggunakan Algoritma Random Forest. *Jurnal Informatika dan Sistem Informasi (JISI)*, 8(1), 45-52.
- [12]. Cahyono, B., & Indrajit, R. (2021). Prediksi Kemiskinan di Indonesia dengan Algoritma K-Nearest Neighbor. *Jurnal Teknologi Informasi dan Komputer (JTIF)*, 10(2), 123-131.
- [13]. Darmawan, A., & Saputra, B. (2023). Analisis Tingkat Kemiskinan di Indonesia dengan Algoritma Decision Tree. *Jurnal Ilmu Komputer (JIK)*, 10(2), 87-94.
- [14]. Fajri, R., & Rahmat, R. (2022). Implementasi Algoritma Naive Bayes dalam Klasifikasi Kemiskinan di Indonesia. *Jurnal Sistem Informasi (JSI)*, 17(1), 34-42.
- [15]. Hadi, I., & Setiawan, A. (2021). Prediksi Kemiskinan di Indonesia dengan Metode Decision Tree. *Jurnal Ilmiah Informatika (JII)*, 9(2), 78-85.
- [16]. Jaya, R., & Saputra, A. (2023). Analisis Tingkat Kemiskinan di Indonesia Menggunakan Algoritma Support Vector Machine. *Jurnal Teknik Informatika (JTI)*, 12(1), 56-64.
- [17]. Kurniawan, D., & Utama, B. (2021). Penerapan Algoritma Random Forest dalam Klasifikasi Kemiskinan di Indonesia. *Jurnal Sistem Informasi (JSI)*, 16(3), 210-218.
- [18]. Mahendra, R., & Wijaya, A. (2022). Analisis Tingkat Kemiskinan di Indonesia dengan Algoritma K-Nearest Neighbor. *Jurnal Ilmiah Teknologi Informasi (JITI)*, 11(1), 45-53.
- [19]. Nugroho, E., & Suryana, D. (2021). Prediksi Kemiskinan di Indonesia Menggunakan Metode Naive Bayes. *Jurnal Ilmiah Informatika (JII)*, 9(1), 23-30.
- [20]. Permana, A., & Supriatna, B. (2023). Analisis Tingkat Kemiskinan di Indonesia dengan Algoritma Decision Tree. *Jurnal Informatika dan Komputer (JIK)*, 6(2), 78-86.

- [21]. Rizki, R., & Mulyadi, M. (2021). Klasifikasi Tingkat Kemiskinan di Indonesia dengan Metode Support Vector Machine. *Jurnal Ilmiah Teknologi Informasi (JITI)*, 10(2), 98-105.
- [22]. Saputra, D., & Indra, I. (2022). Prediksi Kemiskinan di Indonesia dengan Algoritma K-Nearest Neighbor. *Jurnal Ilmiah Teknologi Informasi (JITI)*, 11(2), 67-75.
- [23]. Siregar, B., & Damanik, D. (2021). Implementasi Algoritma Random Forest dalam Klasifikasi Kemiskinan di Indonesia. *Jurnal Informatika dan Komputer (JIK)*, 5(1), 34-42.
- [24]. Surya, A., & Pratama, A. (2023). Analisis Tingkat Kemiskinan di Indonesia Menggunakan Metode Decision Tree. *Jurnal Teknik Informatika (JTI)*, 12(2), 123-130.
- [25]. Wibowo, E., & Santoso, F. (2021). Prediksi Kemiskinan di Indonesia dengan Algoritma Naive Bayes. *Jurnal Ilmiah Informatika (JII)*, 9(3), 145-152.
- [26]. Yulianto, Y., & Pratama, A. (2022). Klasifikasi Tingkat Kemiskinan di Indonesia Menggunakan Metode Support Vector Machine. *Jurnal Ilmiah Teknologi Informasi (JITI)*, 11(3), 167-175.
- [27]. Zulkifli, Z., & Fitriana, F. (2021). Penerapan Algoritma Decision Tree dalam Klasifikasi Kemiskinan di Indonesia. *Jurnal Sistem Informasi (JSI)*, 16(4), 310-318.
- [28]. Arifianto, A., & Utama, B. (2023). Analisis Tingkat Kemiskinan di Indonesia dengan Metode Random Forest. *Jurnal Informatika dan Sistem Informasi (JISI)*, 9(2), 78-85.
- [29]. Wibowo, D., & Santoso, F. (2021). Klasifikasi Kemiskinan di Indonesia Menggunakan Algoritma K-Nearest Neighbor. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 8(4), 325-332.
- [30]. Handayani, S., & Pratama, M. (2021). Penerapan Metode Decision Tree dalam Memprediksi Kemiskinan di Provinsi Banten. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK)*, 4(7), 1450-1457.