

## Pemanfaatan Model ResNet50 dan SVM untuk Klasifikasi Penyakit Daun Tebu

Sri Fatmawati Yunizar<sup>1</sup>, Anggraini Puspita Sari <sup>\*2</sup>, Firza Prima Aditiawan<sup>3</sup>

<sup>1,2,3</sup>Program Studi Informatika, Fakultas Ilmu Komputer, UPN “Veteran” Jawa Timur

E-mail: <sup>1</sup>[yuyun1356@gmail.com](mailto:yuyun1356@gmail.com), <sup>\*2</sup>[anggraini.puspita.if@upnjatim.ac.id](mailto:anggraini.puspita.if@upnjatim.ac.id),

<sup>3</sup>[firzaprima.if@upnjatim.ac.id](mailto:firzaprima.if@upnjatim.ac.id)

### Abstrak

Indonesia, sebagai negara agraris, menghadapi tantangan signifikan dalam sektor pertanian, khususnya dalam produksi dan konsumsi gula tebu. Ketidakseimbangan antara produksi dan konsumsi gula memicu kebutuhan impor dan dampak ekonomi yang besar. Salah satu tantangan utama dalam perkebunan tebu adalah penyakit daun tebu, yang dapat menyebabkan penurunan produktifitas jika tidak terdeteksi secara dini. Teknologi machine learning menggunakan arsitektur Convolutional Neural Network (CNN) seperti ResNet50 dan Support Vector Machines (SVM), telah menunjukkan potensi dalam meningkatkan akurasi klasifikasi penyakit tanaman. Penelitian ini bertujuan untuk mengeksplorasi performa model ResNet50-SVM dalam klasifikasi penyakit daun tebu dan membandingkannya dengan model ResNet50 tunggal dan SVM tunggal. Hasil eksperimen menunjukkan bahwa model ResNet50-SVM mencapai akurasi tertinggi sebesar 88.69% dengan waktu komputasi 618.47 detik, menandakan keseimbangan optimal antara akurasi dan efisiensi komputasi. Sebaliknya, model ResNet50 tunggal memberikan akurasi 86.51% dengan waktu komputasi 203.95 detik, menunjukkan keunggulan dalam kecepatan komputasi. Model SVM tunggal, dengan akurasi 60.52% dan waktu komputasi 881.06 detik, menunjukkan performa terendah dan kurang efisien dalam menangani data citra yang kompleks. Penelitian ini menyimpulkan bahwa model ResNet50-SVM merupakan metode klasifikasi yang paling efektif untuk mendeteksi penyakit daun tebu, sementara model ResNet50 tunggal menawarkan solusi yang lebih cepat, dan SVM tunggal kurang sesuai untuk tugas klasifikasi.

**Kata Kunci** — Klasifikasi, Tebu, ResNet50, SVM

### Abstract

Indonesia, as an agricultural country, faces significant challenges in the agricultural sector, particularly in the production and consumption of sugarcane. The imbalance between sugar production and consumption triggers the need for imports and a huge economic impact. One of the main challenges in sugarcane plantation is sugarcane leaf disease, which can lead to decreased productivity if not detected early. Machine learning technologies using Convolutional Neural Network (CNN) architectures such as ResNet50 and Support Vector Machines (SVM), have shown potential in improving the accuracy of plant disease classification. This study aims to explore the performance of the ResNet50-SVM model in sugarcane leaf disease classification and compare it with a single ResNet50 model and a single SVM. The experimental results show that the ResNet50-SVM model achieves the highest accuracy of 88.69% with a computation time of 618.47 seconds, signifying an optimal balance between accuracy and computational efficiency. In contrast, the single ResNet50 model provides an accuracy of 86.51% with a computational time of 203.95 seconds, showing an advantage in computational speed. The single SVM model, with an accuracy of 60.52% and a computation time of 881.06 seconds, showed the lowest performance and was less efficient in handling complex image data. This study concludes that the ResNet50-SVM model is the most effective classification method for detecting sugarcane leaf

---

diseases, while the single ResNet50 model offers a faster solution, and the single SVM is less suitable for classification tasks.

**Keywords** — Classification, Sugarcane, ResNet50, SVM

## 1. PENDAHULUAN

Indonesia adalah negara agraris yang sebagian besar penduduknya bergantung pada sektor pertanian dan perkebunan. Salah satu komoditas utama dari sektor tersebut adalah tebu, dengan hasil berupa gula pasir. Menurut Pusat Data dan Sistem Informasi Pertanian, produksi gula di Indonesia telah meningkat lebih dari 3,5% per tahun selama lima tahun terakhir, mencapai total 2,42 juta ton pada tahun 2021 [1]. Namun, kebutuhan konsumsi gula selama periode tersebut mencapai 3,13 juta ton, jauh lebih besar dibandingkan hasil produksi sehingga memaksa negara melakukan impor gula untuk menutupi kekurangan tersebut. Ketidakseimbangan antara produksi dan konsumsi ini tidak hanya mempengaruhi harga gula yang melonjak, tetapi juga menciptakan tantangan besar bagi para pelaku usaha.

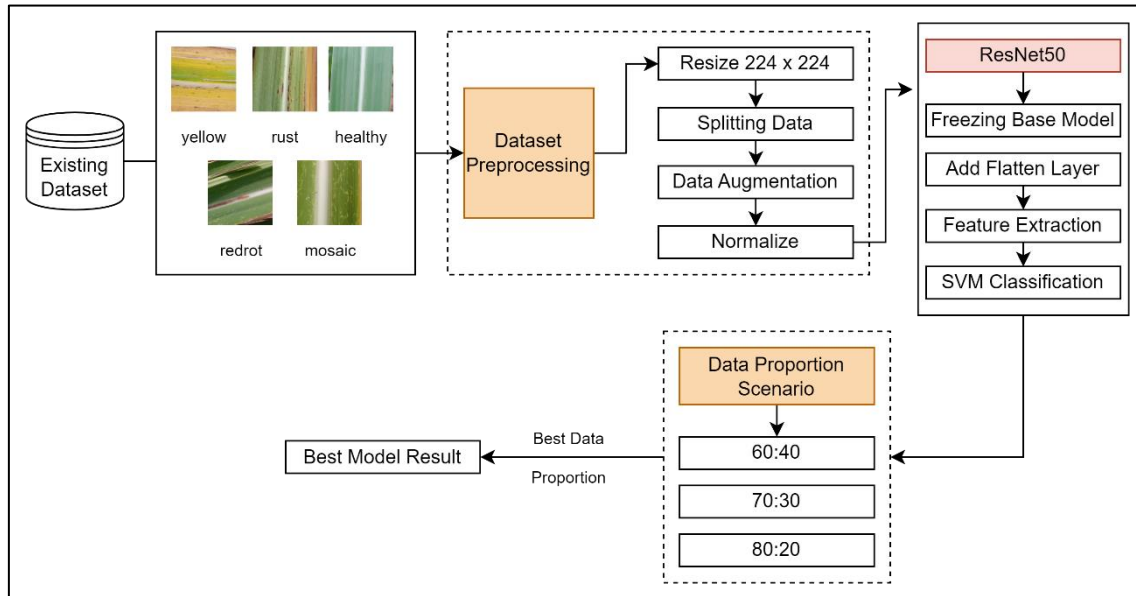
Penyakit daun tebu merupakan salah satu tantangan utama dalam industri perkebunan tebu di Indonesia. Penyakit seperti red rot, mosaic, yellow leaf dan rust dapat mengakibatkan kerugian ekonomi yang signifikan jika tidak dideteksi dan ditangani dengan tepat [2][3][4]. Penyakit tersebut biasanya dipengaruhi oleh beberapa faktor seperti virus, varietas, musim tanam, faktor tanah dan lingkungan [5]. Penyakit ini sering menetap pada tanaman tanpa diketahui oleh petani, sehingga dapat memperburuk keadaan tanaman tebu apabila tidak segera diidentifikasi [6]. Deteksi dini dan klasifikasi yang akurat terhadap penyakit-penyakit ini sangat penting untuk meminimalkan dampak negatif terhadap produktivitas. Teknologi machine learning dan deep learning menawarkan solusi yang efektif pada permasalahan ini. Arsitektur Convolutional Neural Network (CNN) seperti ResNet50 telah terbukti efektif dalam ekstraksi fitur dari citra tanaman, sedangkan Support Vector Machines (SVM) sering digunakan untuk klasifikasi [7][8]. Convolutional Neural Network (CNN) merupakan salah satu jenis algoritma deep learning berbasis pada feed-forward neural network (FFNN) yang biasa digunakan untuk mengekstraksi fitur dan menganalisis informasi dari gambar [9].

Dalam literatur terkait, beberapa penelitian telah menunjukkan keberhasilan kombinasi ResNet50 dan SVM dalam meningkatkan akurasi klasifikasi. Misalnya, penelitian oleh Enireddy et al., menunjukkan bahwa kombinasi ResNet50 dan SVM dapat meningkatkan akurasi dalam mendeteksi virus Corona menggunakan gambar sinar X dibandingkan dengan VGG16 [10]. Penelitian lain oleh Alwan et al., mengeksplorasi penggunaan ResNet sebagai ekstraktor fitur dan SVM sebagai klasifikator untuk klasifikasi penyakit tanaman padi, menunjukkan bahwa model hybrid ini menghasilkan akurasi yang tinggi dalam diagnosis penyakit tanaman padi [11]. Selain itu, Islam et al. melakukan deteksi dini pada penyakit Alzheimer menggunakan beberapa arsitektur dan algoritma konvensional, didapatkan hasil terbaik menggunakan arsitektur ResNet50 dan SVM [12]. Penelitian oleh Macharla et al. juga mendukung penggunaan kombinasi ResNet50 dan SVM dalam klasifikasi penyakit parkinson menggunakan pengucapan vokal, hasilnya menunjukkan bahwa model ini menghasilkan akurasi yang memuaskan [13].

Namun, penelitian spesifik mengenai model ResNet50 dan SVM dalam konteks klasifikasi penyakit daun tebu masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk mengeksplorasi performa model ResNet50-SVM dalam melakukan tugas klasifikasi. Nantinya, diterapkan beberapa skenario pengujian untuk mengetahui proporsi pembagian data yang optimal, serta membandingkannya dengan model ResNet50 dan SVM tunggal untuk memberikan wawasan mendalam mengenai potensi dan kontribusi kombinasi ResNet50 dan SVM dalam meningkatkan akurasi deteksi penyakit daun tebu. Diharapkan, penelitian ini dapat memberikan kontribusi signifikan terhadap pengembangan metode klasifikasi penyakit yang lebih optimal.

## 2. METODE PENELITIAN

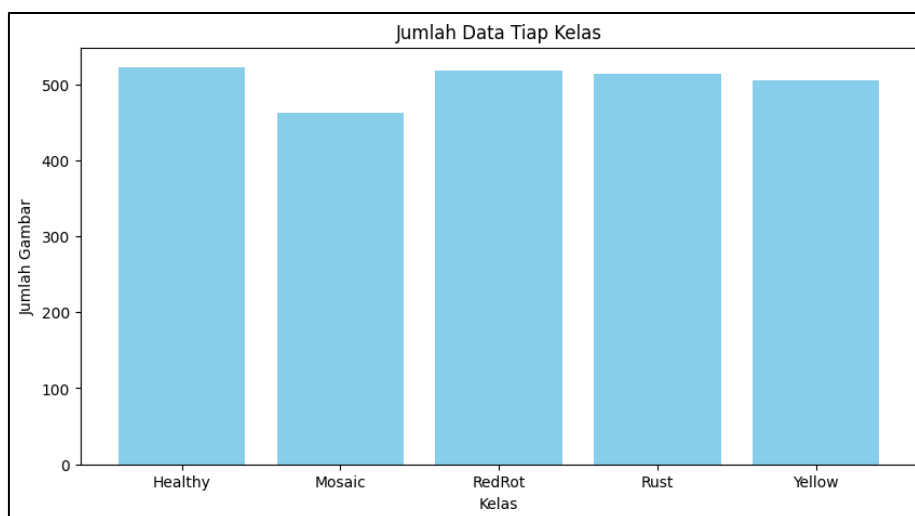
Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun tebu menggunakan kombinasi algoritma ResNet50 sebagai ekstraktor fitur dan SVM sebagai klasifikator. Langkah-langkah metodologi penelitian yang dilakukan dapat dilihat di Gambar 1.



Gambar 1 Waterfall Model

### 2.1 Dataset

Data yang digunakan dalam studi ini diambil dari situs Mendeley Data dengan judul "Sugarcane Leaf Disease Dataset", yang diunggah oleh Swapnil Daphal dan Sanjay Kolidalam [14]. Dataset ini mencakup total 2521 gambar yang terbagi dalam lima kategori, yakni tebu sehat (healthy), tebu dengan penyakit mosaik (mosaic), tebu dengan penyakit kuning (yellow), tebu dengan penyakit karat (rust), dan tebu dengan penyakit busuk merah (redrot). Gambar 2 menampilkan jumlah data di tiap kelas dataset



Gambar 2. Jumlah Data Tiap Kelas

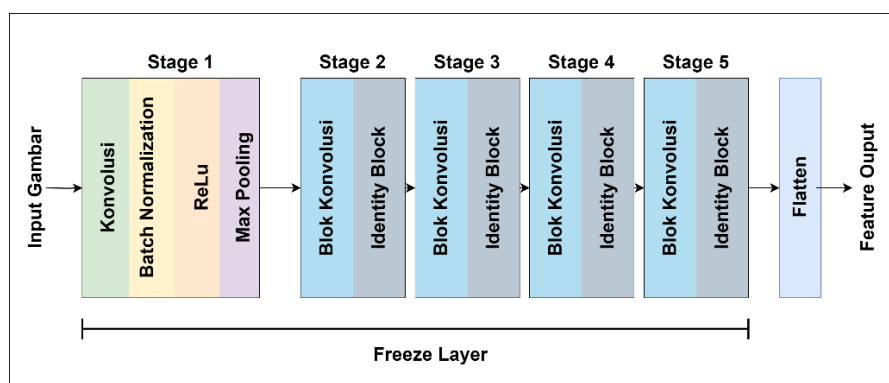
## 2.2 Preprocessing Data

Data gambar yang digunakan dalam penelitian ini awalnya memiliki resolusi yang bervariasi. Untuk memastikan konsistensi dan kompatibilitas dengan model *deep learning* yang digunakan, setiap gambar diubah ukurannya menjadi 224x224 piksel. Proses ini dilakukan dengan mempertahankan rasio aspek gambar untuk menghindari distorsi, menggunakan interpolasi bicubic untuk menjaga kualitas gambar. Ukuran 224x224 piksel dipilih karena merupakan ukuran standar yang sering digunakan dalam berbagai arsitektur model konvolusi, termasuk ResNet50. Kemudian, augmentasi data diterapkan untuk meningkatkan keragaman data pelatihan dan membantu model dalam generalisasi yang lebih baik terhadap data yang tidak terlihat. Teknik augmentasi yang digunakan meliputi rotasi, pergeseran secara horizontal dan vertikal, *shearing*, *zoom*, dan *flipping* horizontal. Teknik-teknik ini diterapkan secara acak selama pelatihan untuk meningkatkan keragaman dataset dan membantu model dalam belajar dari berbagai kondisi.

Setelah itu, normalisasi data diterapkan untuk mengurangi perbedaan skala antar fitur dan mempercepat konvergensi selama pelatihan model. Semua gambar yang telah di-*resize* kemudian dinormalisasi dengan skala nilai piksel menjadi rentang [0, 1]. Ini dilakukan dengan membagi nilai intensitas piksel yang awalnya berada dalam rentang [0, 255] dengan 255. Normalisasi ini membantu dalam mengurangi bias model yang dapat timbul dari perbedaan skala antara fitur. Secara keseluruhan, proses *preprocessing* ini memastikan bahwa data input ke model memiliki format yang konsisten dan terstandarisasi, serta meningkatkan kualitas pelatihan dengan menyediakan variasi data yang lebih besar dan nilai fitur yang terukur.

## 2.3 Ekstraksi Fitur ResNet50

ResNet50 adalah arsitektur jaringan saraf konvolusional yang dikembangkan oleh Kaiming He et al. dalam artikel yang berjudul “*Deep Residual Learning for Image Recognition*” [15]. ResNet50 merupakan salah satu model dari keluarga ResNet yang memiliki 50 lapisan, menggabungkan lapisan konvolusi, *batch normalization*, aktivasi ReLU, dan *shortcut connections*. *Shortcut connections* memungkinkan informasi untuk melewati satu atau lebih lapisan, sehingga mengurangi masalah degradasi yang biasanya terjadi pada jaringan dengan banyak lapisan. Komponen utama dari ResNet50 adalah *residual blocks*, di mana setiap blok tidak hanya mengakumulasi *output* dari lapisan konvolusi, tetapi juga menambahkan *shortcut connections* yang mentransfer *input* asli ke lapisan berikutnya [16]. Dalam konteks penelitian ini, ResNet50 akan digunakan hingga lapisan *flatten*, karena fungsinya adalah untuk ekstraksi fitur. Struktur arsitektur ResNet50 dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur ResNet50

Ekstraksi fitur merupakan langkah lanjutan dalam penerapan model ResNet50, tahap ini akan memproses *input* hasil vektor dari lapisan *flatten*. Model ResNet50 yang sudah terlatih berfungsi untuk mengubah gambar mentah menjadi representasi fitur yang lebih berguna. Proses

ini melibatkan pembangunan model ekstraktor fitur yang mengambil *input* dari model dasar dan memproduksi *output* dari lapisan yang diinginkan. Model ekstraktor fitur ini kemudian digunakan untuk mengekstrak fitur dari dataset pelatihan, dan pengujian.

#### 2.4 Klasifikasi SVM

Setelah tahap ekstraksi fitur menggunakan ResNet50, model SVM akan diinisialisasi menggunakan parameter default, dengan kernel linear dan nilai C sebesar 0.1. Setelah inisialisasi, model dilatih menggunakan fitur yang telah diekstraksi dari data pelatihan beserta labelnya. Proses pelatihan bertujuan untuk menemukan *hyperplane* terbaik yang memisahkan data sesuai dengan kelas-kelas yang ada. Dalam penelitian ini, untuk mengatasi masalah klasifikasi multi-kelas, digunakan pendekatan one-vs-one (OvO) dimana setiap *classifier* dilatih hanya dengan dua kelas yang berbeda untuk menentukan *hyperplane* yang memisahkan dua kelas tersebut dengan margin maksimum.

Evaluasi model dilakukan dengan menguji performanya pada data uji. Ketika model melakukan prediksi, pendekatan OvO menghasilkan keputusan berdasarkan jumlah suara terbanyak dari semua *classifier*. Setiap *classifier* memberikan satu suara untuk salah satu dari dua kelas yang dibandingkan, dan kelas yang mendapatkan suara terbanyak menjadi prediksi akhir. Proses ini akan diterapkan pada data uji untuk mengukur performa model terhadap data baru, yang menunjukkan seberapa baik model mampu menggeneralisasi pada gambar yang belum pernah dilihat sebelumnya.

#### 2.5 Skenario Pengujian

Dalam penelitian ini, dilakukan tiga skenario pengujian dengan menggunakan proporsi pembagian data yang berbeda untuk melatih dan menguji model. Tujuan dari variasi ini adalah untuk mengevaluasi pengaruh proporsi data terhadap kinerja model klasifikasi dalam mengenali penyakit daun tebu. Proporsi data yang digunakan adalah 70:30 yang merupakan baseline model, 60:40, dan 80:20. Setiap skenario memiliki perbedaan pada jumlah data yang digunakan untuk pelatihan dan pengujian, sehingga memberikan gambaran tentang bagaimana ukuran set data mempengaruhi hasil model.

#### 2.6 Evaluasi Performa Hasil

Tahap evaluasi performa hasil adalah langkah terakhir dalam penelitian ini, di mana model ResNet50-SVM, ResNet50 tunggal, dan SVM tunggal yang telah dilatih akan dibandingkan untuk menilai efektivitas masing-masing dalam mengklasifikasikan data. Evaluasi dilakukan dengan mengukur beberapa metrik utama menggunakan *confusion matrix*, seperti akurasi, *precision*, *recall*, dan *F1-score* seperti pada Tabel 1. Tujuan dari evaluasi ini adalah untuk mendapatkan gambaran yang jelas tentang kinerja setiap model dalam mengklasifikasikan berbagai kategori penyakit daun tebu, serta untuk menentukan model mana yang memberikan hasil terbaik dalam hal akurasi dan kemampuan generalisasi.

Tabel 1. Confusion Matrix

|                           | <i>Actual Positive</i> | <i>Actual Negative</i> |
|---------------------------|------------------------|------------------------|
| <i>Predicted Positive</i> | <i>True Positive</i>   | <i>False Positive</i>  |
| <i>Predicted Negative</i> | <i>False Negative</i>  | <i>True Negative</i>   |

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

$$F1 - Score = 2 \times \frac{recall \times precision}{recall + precision} \tag{4}$$

### 3 HASIL DAN PEMBAHASAN

#### 3.1 Skenario Pengujian

Pada penelitian ini, dilakukan tiga skenario pengujian untuk mengevaluasi performa model ResNet50-SVM. Setiap skenario dirancang untuk memahami bagaimana model menangani proporsi data yang berbeda, serta untuk menentukan proporsi terbaik dalam klasifikasi penyakit daun tebu. Adapun tiga skenario pengujian tersebut adalah sebagai berikut.

Skenario pertama adalah baseline model dengan proporsi data 70:30, yang terbagi menjadi 70% data pelatihan dan 30% data uji. Gambar 4 menunjukkan hasil akurasi skenario pertama sebesar 88.10%, hasil tersebut menunjukkan bahwa model di skenario 1 memiliki performa yang baik, terutama dalam mengklasifikasikan kelas "Healthy", "RedRot", dan "Rust". Namun, model mengalami kesulitan dalam membedakan kelas "Mosaic" dan "Yellow". Kesalahan klasifikasi yang terjadi antara kelas-kelas ini disebabkan oleh kemiripan visual antar penyakit, terutama pada fitur warna dan tekstur daun tebu yang sulit dibedakan. Salah satu kelemahan yang terlihat adalah jumlah kesalahan klasifikasi pada kelas "Yellow", yang dapat mengindikasikan bahwa fitur yang dihasilkan oleh ResNet50 belum sepenuhnya optimal untuk membedakan antara "Yellow" dengan kelas lain.

| Test Accuracy: 88.10%  |           |        |          |         |
|------------------------|-----------|--------|----------|---------|
| Classification Report: |           |        |          |         |
|                        | precision | recall | f1-score | support |
| Healthy                | 0.85      | 0.92   | 0.89     | 146     |
| Mosaic                 | 0.87      | 0.90   | 0.88     | 143     |
| RedRot                 | 0.88      | 0.86   | 0.87     | 160     |
| Rust                   | 0.97      | 0.94   | 0.96     | 149     |
| Yellow                 | 0.83      | 0.79   | 0.81     | 158     |
| accuracy               |           |        | 0.88     | 756     |
| macro avg              | 0.88      | 0.88   | 0.88     | 756     |
| weighted avg           | 0.88      | 0.88   | 0.88     | 756     |

Gambar 4. Hasil Skenario Pertama

Skenario kedua dengan proporsi data 60:40, yang terbagi menjadi 60% data pelatihan dan 40% data uji. Gambar 5 menunjukkan hasil akurasi skenario kedua sebesar 86.71%, hasil tersebut menunjukkan bahwa model di skenario 2 tetap konsisten dalam mengklasifikasikan sebagian besar kelas dengan cukup baik. Namun, model kesulitan dalam membedakan kelas "yellow" dari kelas lainnya. Kesalahan yang relatif tinggi pada kelas "yellow" dan "mosaic" mengindikasikan adanya kesulitan model dalam mengenali ciri-ciri visual unik dari penyakit-penyakit ini yang disebabkan oleh kemiripan tekstur dan warna daun tebu yang terkena penyakit, yang membuat model sulit untuk membedakannya secara akurat. Di sisi lain, model menunjukkan hasil yang

cukup memuaskan pada kelas "Healthy" dan "RedRot", yang menunjukkan bahwa model cukup handal dalam mengenali kondisi daun yang sehat serta penyakit RedRot.

| Test Accuracy: 86.71%  |           |        |          |         |
|------------------------|-----------|--------|----------|---------|
| Classification Report: |           |        |          |         |
|                        | precision | recall | f1-score | support |
| Healthy                | 0.83      | 0.91   | 0.87     | 205     |
| Mosaic                 | 0.87      | 0.86   | 0.86     | 194     |
| RedRot                 | 0.84      | 0.87   | 0.86     | 200     |
| Rust                   | 0.97      | 0.92   | 0.95     | 198     |
| Yellow                 | 0.83      | 0.78   | 0.80     | 211     |
| accuracy               |           |        | 0.87     | 1008    |
| macro avg              | 0.87      | 0.87   | 0.87     | 1008    |
| weighted avg           | 0.87      | 0.87   | 0.87     | 1008    |

Gambar 5. Hasil Skenario Kedua

Skenario ketiga dengan proporsi data 80:20, yang terbagi menjadi 80% data pelatihan dan 20% data uji. Gambar 6 menunjukkan hasil akurasi skenario ketiga sebesar 88.69%, hasil tersebut menunjukkan bahwa model di skenario 3 tetap mempertahankan performa yang konsisten, meskipun dengan proporsi data uji yang lebih kecil. Secara umum, model menunjukkan akurasi yang baik dalam mengklasifikasikan sebagian besar kelas, terutama "RedRot" dan "Rust", yang merupakan dua penyakit daun tebu yang paling jelas dibedakan. Namun, model mengalami kesulitan dalam mengklasifikasikan kelas "Yellow". Kesalahan klasifikasi yang terjadi pada kelas "Yellow" menunjukkan bahwa model mengalami tantangan dalam membedakan fitur visual kelas ini dari "Mosaic" dan "RedRot". Hal ini menjelaskan bahwa ada kemungkinan besar adanya overlap antara fitur visual dari penyakit ini, yang membuat model sulit melakukan klasifikasi yang akurat. Di sisi lain, hasil yang baik pada kelas "RedRot" dan "Rust" menunjukkan bahwa model cukup efektif dalam mengenali pola yang khas dari penyakit-penyakit tersebut. Hal ini disebabkan oleh fitur yang lebih mudah dikenali atau kontras yang lebih jelas dalam gambar, yang membantu model dalam mengidentifikasi kelas-kelas ini dengan lebih akurat.

| Test Accuracy: 88.69%  |           |        |          |         |
|------------------------|-----------|--------|----------|---------|
| Classification Report: |           |        |          |         |
|                        | precision | recall | f1-score | support |
| Healthy                | 0.86      | 0.90   | 0.88     | 90      |
| Mosaic                 | 0.86      | 0.88   | 0.87     | 94      |
| RedRot                 | 0.91      | 0.88   | 0.90     | 108     |
| Rust                   | 0.97      | 0.93   | 0.95     | 103     |
| Yellow                 | 0.84      | 0.84   | 0.84     | 109     |
| accuracy               |           |        | 0.89     | 504     |
| macro avg              | 0.89      | 0.89   | 0.89     | 504     |
| weighted avg           | 0.89      | 0.89   | 0.89     | 504     |

Gambar 6. Hasil Skenario Ketiga

Pada penelitian ini yang dilakukan di SMA Hangtuah 2 Sidoarjo dengan menggunakan dataset nilai siswa kelas 10 dari tahun 2022 sampai dengan 2023 dengan jumlah data sebanyak 166 siswa,

Tahapan perhitungan algoritma C5.0 untuk memperoleh model aturan pohon keputusan sebagai berikut :

Tahap pertama nilai *Gain* menggunakan Persamaan (1)

$$Entropy(S) = -\frac{108}{166} * \log_2\left(\frac{108}{166}\right) + -\frac{58}{166} * \log_2\left(\frac{58}{166}\right)$$

$$Entropy(S) = 0.9335$$

Tahap kedua nilai *Gain* menggunakan Persamaan (2)

$$Gain(S, A) = 0.9335 - \left( \left( \frac{50}{166} * 0 \right) + \left( \frac{58}{166} * 0.9922 \right) + \left( \frac{58}{166} * 0.9922 \right) \right)$$

$$Gain(S, A) = 0.2401$$

Tahap ketiga nilai *Split Information* menggunakan Persamaan (3).

$$Split\ Information\ (S, A)$$

$$= \left( -\frac{50}{166} * \log_2 \left( \frac{50}{166} \right) \right) - \left( -\frac{58}{166} \log_2 \left( \frac{58}{166} \right) \right) - \left( -\frac{58}{166} \log_2 \left( \frac{58}{166} \right) \right)$$

$$Split\ Information(S, A) = 1.5816$$

Tahap empat nilai *Gain Ratio* menggunakan Persamaan (4).

$$Gain\ Ratio = \frac{0.2401}{1.5816}$$

$$Gain\ Ratio = 0.1518$$

Adapun hasil perhitungan nilai entropy, *Gain* dan *Gain Ratio* secara lengkap disajikan pada Tabel 7

Tabel 3 Interasi 1 Algoritma C5.0

| Atribut     | Nilai atribut | Jumlah (S) | Pintar (Si) | Kurang (Si) | Entropy | Gain   | Split  | Gain ratio |
|-------------|---------------|------------|-------------|-------------|---------|--------|--------|------------|
|             | Total         | 166        | 108         | 58          | 0.9335  |        |        |            |
| nilai       | baik          | 50         | 50          | 0           | 0       | 0.2401 | 1.5816 | 0.1518     |
| nilai       | cukup         | 58         | 32          | 26          | 0.9923  |        |        |            |
| nilai       | kurang        | 58         | 26          | 32          | 0.9923  |        |        |            |
| jumlah_alpa | 0             | 27         | 18          | 9           | 0.9183  | 0.0011 | 2.548  | 0.0004     |
| jumlah_alpa | 1             | 38         | 25          | 13          | 0.9268  |        |        |            |
| jumlah_alpa | 2             | 23         | 14          | 9           | 0.9656  |        |        |            |
| jumlah_alpa | 3             | 24         | 16          | 8           | 0.9183  |        |        |            |
| jumlah_alpa | 4             | 20         | 13          | 7           | 0.9341  |        |        |            |
| jumlah_alpa | 5             | 34         | 22          | 12          | 0.9367  |        |        |            |
| jumlah_buku | 0             | 28         | 17          | 11          | 0.9666  | 0.0015 | 2.5702 | 0.0006     |
| jumlah_buku | 1             | 32         | 21          | 11          | 0.9284  |        |        |            |
| jumlah_buku | 2             | 33         | 22          | 11          | 0.9183  |        |        |            |
| jumlah_buku | 3             | 24         | 16          | 8           | 0.9183  |        |        |            |
| jumlah_buku | 4             | 22         | 14          | 8           | 0.9457  |        |        |            |
| jumlah_buku | 5             | 27         | 18          | 9           | 0.9183  |        |        |            |
| tunggakan   | ada           | 102        | 64          | 38          | 0.9526  | 0.0027 | 0.9619 | 0.0028     |
| tunggakan   | tidak ada     | 64         | 44          | 20          | 0.896   |        |        |            |

Tabel 4 *Interasi 2 Algoritma C5.0*

| Atribut     | Nilai atribut | Jumlah (S) | Pintar (Si) | Kurang (Si) | Entropy | Gain   | Split  | Gain ratio |
|-------------|---------------|------------|-------------|-------------|---------|--------|--------|------------|
|             | Total         | 58         | 32          | 26          | 0.9923  |        |        |            |
| jumlah_alpa | 0             | 9          | 6           | 3           | 0.9183  | 0.1627 | 2.5505 | 0.0638     |
| jumlah_alpa | 1             | 13         | 2           | 11          | 0.6194  |        |        |            |
| jumlah_alpa | 2             | 9          | 6           | 3           | 0.9183  |        |        |            |
| jumlah_alpa | 3             | 8          | 5           | 3           | 0.9544  |        |        |            |
| jumlah_alpa | 4             | 7          | 6           | 1           | 0.5917  |        |        |            |
| jumlah_alpa | 5             | 12         | 7           | 5           | 0.9799  |        |        |            |
| jumlah_buku | 0             | 11         | 8           | 3           | 0.8454  | 0.1429 | 2.5702 | 0.0556     |
| jumlah_buku | 1             | 11         | 8           | 3           | 0.8454  |        |        |            |
| jumlah_buku | 2             | 11         | 8           | 3           | 0.8454  |        |        |            |
| jumlah_buku | 3             | 8          | 4           | 4           | 1       |        |        |            |
| jumlah_buku | 4             | 8          | 2           | 6           | 0.8113  |        |        |            |
| jumlah_buku | 5             | 9          | 2           | 7           | 0.7642  |        |        |            |
| tunggakan   | ada           | 38         | 26          | 12          | 0.8997  | 0.0989 | 0.9294 | 0.1064     |
| tunggakan   | tidak ada     | 20         | 6           | 14          | 0.8813  |        |        |            |

Tabel 5 *Interasi 3 Algoritma C5.0*

| Atribut     | Nilai atribut | Jumlah (S) | Pintar (Si) | Kurang (Si) | Entropy | Gain   | Split  | Gain ratio |
|-------------|---------------|------------|-------------|-------------|---------|--------|--------|------------|
|             | Total         | 38         | 26          | 12          | 0.8997  |        |        |            |
| jumlah_alpa | 0             | 6          | 6           | 0           | 0       | 0.18   | 2.4795 | 0.0726     |
| jumlah_alpa | 1             | 2          | 2           | 0           | 0       |        |        |            |
| jumlah_alpa | 2             | 8          | 5           | 3           | 0.9544  |        |        |            |
| jumlah_alpa | 3             | 7          | 4           | 3           | 0.9852  |        |        |            |
| jumlah_alpa | 4             | 6          | 5           | 1           | 0.65    |        |        |            |
| jumlah_alpa | 5             | 9          | 4           | 5           | 0.9911  |        |        |            |
| jumlah_buku | 0             | 8          | 8           | 0           | 0       | 0.2258 | 2.5574 | 0.0883     |
| jumlah_buku | 1             | 8          | 6           | 2           | 0.8113  |        |        |            |
| jumlah_buku | 2             | 6          | 5           | 1           | 0.65    |        |        |            |
| jumlah_buku | 3             | 5          | 3           | 2           | 0.971   |        |        |            |
| jumlah_buku | 4             | 5          | 2           | 3           | 0.971   |        |        |            |
| jumlah_buku | 5             | 6          | 2           | 4           | 0.9183  |        |        |            |

Tabel 6 *Interasi 4 Algoritma C5.0*

| Atribut     | Nilai atribut | Jumlah (S) | Pintar (Si) | Kurang (Si) | Entropy | Gain   | Split | Gain ratio |
|-------------|---------------|------------|-------------|-------------|---------|--------|-------|------------|
| Total       | Total         | 8          | 6           | 2           | 0.8113  |        |       |            |
| jumlah_alpa | 0             | 1          | 1           | 0           | 0       | 0.8113 | 2.5   | 0.3245     |
| jumlah_alpa | 1             | 1          | 1           | 0           | 0       |        |       |            |
| jumlah_alpa | 2             | 2          | 2           | 0           | 0       |        |       |            |
| jumlah_alpa | 3             | 2          | 2           | 0           | 0       |        |       |            |

|             |   |   |   |   |   |
|-------------|---|---|---|---|---|
| jumlah_alpa | 4 | 1 | 0 | 1 | 0 |
| jumlah_alpa | 5 | 1 | 0 | 1 | 0 |

#### 4. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan, didapatkan kesimpulan bahwa performa model ResNet50 dan SVM berhasil memberikan hasil yang memuaskan dengan akurasi pada data uji sebesar 88.69%. Sedangkan performa model ResNet50 tunggal dan SVM tunggal menunjukkan performa yang lebih rendah dibandingkan kombinasi ResNet50-SVM, yaitu 86.51% untuk ResNet50 dan 60.51% untuk SVM. Hal ini menunjukkan bahwa penggunaan ResNet50 sebagai *feature extractor* yang dikombinasikan dengan SVM sebagai *classifier* dapat menghasilkan model yang kuat dalam klasifikasi penyakit daun tebu. Sedangkan, kedua model tunggal tersebut kurang efektif dalam menangani kompleksitas fitur gambar penyakit daun tebu.

#### 5. SARAN

Berdasarkan hasil penelitian yang dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk meningkatkan efektivitas dan efisiensi model. Penggunaan teknik *preprocessing* seperti *adaptive histogram equalization* atau teknik *filtering* lainnya dapat dicoba agar dapat menghasilkan data yang lebih berkualitas. Kemudian, mengeksplorasi model arsitektur lain seperti EfficientNet, MobileNetV2, atau menggunakan model *ensemble* yang menggabungkan beberapa arsitektur CNN untuk meningkatkan akurasi klasifikasi dari model yang dibangun.

#### DAFTAR PUSTAKA

- [1] S. Jenderal, "Outlook Komoditas Perkebunan Tebu," Dec. 2022.
- [2] L. E. T. Bertasello et al., "Yellow Leaf Disease Resistance and Melanaphis sacchari Preference in Commercial Sugarcane Cultivars," *Plants*, vol. 12, no. 17, Sep. 2023, doi: 10.3390/plants12173079.
- [3] S. Srivastava, P. Kumar, N. Mohd, A. Singh, and F. Gill, "A Novel Deep Learning Framework Approach for Sugarcane Disease Detection," *SN Comput Sci*, vol. 1, p. 87, Aug. 2020, doi: 10.1007/s42979-020-0094-9.
- [4] R. Selvakumar and R. Viswanathan, "SUGARCANE RUST: CHANGING DISEASE DYNAMICS AND ITS MANAGEMENT," *Journal of Sugarcane Research*, vol. 9, no. 2, p. 97, Dec. 2019, doi: 10.37580/jsr.2019.2.9.97-118.
- [5] S. V Militante and B. D. Gerardo, "Detecting Sugarcane Diseases through Adaptive Deep Learning Models of Convolutional Neural Network," in 2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS), 2019, pp. 1–5. doi: 10.1109/ICETAS48360.2019.9117332.
- [6] A. Budiman, Fabian, R. A. Yupitera, S. Achmad, and A. Kurniawan, "Student attendance with face recognition (LBPH or CNN): Systematic literature review," *Procedia Comput Sci*, vol. 216, pp. 31–38, 2023, doi: <https://doi.org/10.1016/j.procs.2022.12.108>.
- [7] Y. Wu, Y. He, and Y. Wang, "Multi-Class Weed Recognition Using Hybrid CNN-SVM Classifier," *Sensors*, vol. 23, no. 16, Aug. 2023, doi: 10.3390/s23167153.
- [8] S. D. Daphal and S. M. Koli, "Enhancing sugarcane disease classification with ensemble

- deep learning: A comparative study with transfer learning techniques,” *Heliyon*, vol. 9, no. 8, Aug. 2023, doi: 10.1016/j.heliyon.2023.e18261.
- [9] A. P. Sari, H. Suzuki, T. Kitajima, T. Yasuno, D. A. Prasetya, and N. Nachrowie, “Prediction Model of Wind Speed and Direction using Convolutional Neural Network - Long Short Term Memory,” 2020 IEEE International Conference on Power and Energy (PECon), pp. 356–361, 2020, [Online]. Available: <https://api.semanticscholar.org/CorpusID:231616800>
- [10] V. Enireddy, M. J. K. Kumar, B. Donepudi, and C. Karthikeyan, “Detection of COVID- 19 using Hybrid ResNet and SVM,” in *IOP Conference Series: Materials Science and Engineering*, IOP Publishing Ltd, Dec. 2020. doi: 10.1088/1757-899X/993/1/012046.
- [11] D. S. Alwan and M. H. Naji, “Rice Diseases Classification by Residual Network 50 (RESNET50) and Support Vector Machine (SVM) Modeling,” *Journal of Kufa for*