



Klasifikasi Jenis Madu Akasia dan Madu Hutan Berdasarkan Warna RGB Menggunakan Metode Multilayer Perceptron

Ridwan Halim^{1,*}, Adityo Permana Wibowo²

¹Fakultas Sains & Teknologi, Informatika, Universitas Teknologi Yogyakarta, Sleman
Jl. Siliwangi, Jombor Lor, Sendangadi, Kec. Mlati, Kabupaten Sleman, Daerah Istimewa Yogyakarta, Indonesia

²Fakultas Sains & Teknologi, Sistem Informasi, Universitas Teknologi Yogyakarta, Sleman
Jl. Siliwangi, Jombor Lor, Sendangadi, Kec. Mlati, Kabupaten Sleman, Daerah Istimewa Yogyakarta, Indonesia

Email: ^{1,*}ridwaanhall.dev@email.com, ²adityopw@uty.ac.id

Email Penulis Korespondensi: ridwaanhall.dev@gmail.com

Submitted: 29/11/2024; Accepted: 28/12/2024; Published: 01/01/2025

Abstrak—Berkembangnya teknologi menjadikan industri pertanian semakin maju dan modern. Membedakan madu dengan warna hampir sama sangatlah sulit. Namun, kemampuan untuk membedakan warna madu akasia dan hutan adalah pendekatan paling sederhana untuk memastikan keaslian dan kualitas produk madu. Penelitian ini bertujuan mengembangkan model klasifikasi warna madu menggunakan Multilayer Perceptron (MLP). Data gambar dikumpulkan dari berbagai sudut dengan pencahayaan alami, diikuti oleh sembilan puluh eksperimen dengan kombinasi parameter, termasuk metode penanganan ketidakseimbangan data, struktur lapisan dense, dan pengaturan pelatihan. Hasil menunjukkan bahwa model MLP dengan konfigurasi optimal, menggunakan metode Adaptive Synthetic Sampling (ADASYN) untuk ketidakseimbangan data, berhasil mencapai akurasi validasi sebesar 90.63%. Akurasi ini menunjukkan potensi model untuk mendukung proses otomatisasi industri dalam membedakan warna madu secara andal.

Kata Kunci: Multilayer Perceptron; ADASYN; Madu Akasia; Madu Hutan; Klasifikasi Warna.

Abstract—The advancement of technology has driven the agricultural industry to become more advanced and modern. Distinguishing honey with nearly identical colors is a challenging task. However, The ability to differentiate the color of acacia and forest honey is the simplest approach to ensuring the authenticity and quality of honey products. This study aims to develop a honey color classification model using Multilayer Perceptron (MLP). Image data were collected from various angles under natural lighting, followed by ninety experiments using parameter combinations, including data imbalance handling methods, dense layer structures, and training settings. The results showed that the MLP model with an optimal configuration, utilizing the Adaptive Synthetic Sampling (ADASYN) method for data imbalance, achieved a validation accuracy of 90.63%. This accuracy highlights the potential of the model to support industrial automation processes in reliably distinguishing honey colors.

Keywords: Multilayer Perceptron; ADASYN; Acacia Honey; Forest Honey; Color Classification.

1. PENDAHULUAN

Madu merupakan cairan kental dengan rasa manis yang dihasilkan oleh lebah madu (*Apis mellifera*). Madu Memiliki cita rasa manis yang unik dan kaya akan nutrisi, seperti gula, air, vitamin, mineral, serta antioksidan [1]. Madu sering disebut sebagai “Makanan Anugerah dari Tuhan” karena memiliki manfaat yang luar biasa [2] [3] dan bermacam-macam [4]. Madu berasal dari nektar, yaitu cairan manis yang terdapat pada bunga, yang dikumpulkan oleh lebah pekerja. Lebah kemudian menyimpan madu di dalam sarangnya sebagai persediaan makanan [5].

Warna madu jenis akasia dan hutan memiliki kesamaan yang hampir serupa, sehingga sulit untuk dibedakan hanya dengan pengamatan visual. Perbedaan yang halus dalam warna ini menimbulkan tantangan dalam mengklasifikasikan jenis madu secara akurat. Berkembangnya teknologi memungkinkan pengenalan dan klasifikasi madu menggunakan metode berbasis machine learning [6][7][8]. Kombinasi madu dengan teknologi seperti klasifikasi lainnya dapat memberikan solusi yang lebih efektif dalam membedakan madu jenis akasia dan hutan [1]. Oleh karena itu, klasifikasi madu jenis akasia dan hutan menjadi topik menarik untuk dibahas dan dikembangkan.

Madu hutan adalah jenis madu yang diperoleh langsung dari sarang lebah liar di pohon-pohon hutan, tanpa melalui proses penangkaran atau pemeliharaan lebah secara khusus. Produksi madu dari lebah hutan memiliki beberapa keunggulan dibandingkan madu dari lebah ternak. Salah satunya adalah rasa nektarnya yang lebih manis dengan aroma yang kuat dan khas. Selain itu, madu hutan memiliki kandungan gas yang relatif tinggi serta kaya akan glukosa dan fruktosa dalam jumlah signifikan [9]. Warna madu hutan memiliki warna yang cokelat gelap jika tidak terkena sinar matahari dan warna merah gelap ketika terkena sinar matahari. Madu lebah *Apis mellifera* dari hutan Akasia memiliki berbagai senyawa metabolit sekunder. Senyawa tersebut meliputi alkaloid, fenolik, flavonoid, terpenoid, saponin, dan tanin, yang berkontribusi pada manfaat kesehatan dan kualitas madu tersebut [10]. Warna madu akasia cenderung cokelat gelap jika tidak terkena sinar matahari langsung. Jika terkena matahari langsung maka warna akan terlihat seperti merah gelap hingga terang sama halnya madu hutan.


Penelitian terdahulu telah menunjukkan keberhasilan dalam berbagai aplikasi klasifikasi menggunakan metode machine learning, seperti Multilayer Perceptron (MLP), Support Vector Machine (SVM), dan Convolutional Neural Networks (CNN). Misalnya, penelitian sebelumnya berhasil memprediksi sesi pada situs jurnal elektronik dengan akurasi Mean Square Error (MSE) sebesar 98.1004% dan RMSE (Root Mean Square Error) sebesar 86.2174% menggunakan Multilayer Perceptron [11], dan mengidentifikasi citra ukiran ornamen

tradisional Bali dengan Specificity sebesar 96.87% [12]. Namun, penelitian-penelitian ini tidak secara khusus menangani klasifikasi madu jenis akasia dan hutan. Selain itu, meskipun metode SVM dan CNN telah digunakan untuk klasifikasi berbagai objek seperti buah pisang dengan akurasi 89.86% [13], buah pinang dengan akurasi 90.90% [14], penyakit tanaman padi dengan akurasi 91.7% [15], penyakit kulit dengan akurasi 85% [16], dan buah tomat dengan akurasi 93.3% [17], belum ada penelitian yang secara khusus mengkaji klasifikasi madu berdasarkan warna. Penelitian menggunakan JST backpropagation mencapai akurasi 90.26% dalam klasifikasi kualitas jenis-jenis madu berdasarkan warna, kecerahan, dan pH [1], dan penelitian menggunakan Metode Naive Bayes berdasarkan warna RGB mendapatkan akurasi 88.88% untuk klasifikasi buah apel [18]. Namun, masih ada celah dalam penelitian yang menggabungkan metode Multilayer Perceptron dengan aplikasi web untuk klasifikasi madu jenis akasia dan hutan berdasarkan warna RGB. Oleh karena itu, penelitian ini bertujuan untuk mengisi kekosongan tersebut dengan mengembangkan model klasifikasi yang akurat dan praktis untuk digunakan.

Berdasarkan permasalahan dan penelitian sebelumnya, kami menggunakan algoritma multilayer perceptron untuk klasifikasi madu jenis akasia dan hutan karena terbukti memiliki akurasi yang sangat tinggi. Selain itu, penelitian sebelumnya banyak menggunakan metode SVM dan CNN, sementara penelitian ini menggunakan Multilayer Perceptron yang memiliki potensi akurasi tinggi dalam menangani data yang lebih kompleks. Kami juga mengembangkan aplikasi web untuk memudahkan klasifikasi madu bagi pengguna. Penelitian ini diharapkan dapat menghasilkan model dengan akurasi sangat tinggi untuk klasifikasi madu jenis akasia dan hutan dan memberikan manfaat bagi penelitian selanjutnya.

2. METODOLOGI PENELITIAN

Klasifikasi menggunakan model Multilayer Perceptron dilakukan dalam beberapa tahap, seperti pada **gambar 1**. Mulanya pengambilan gambar madu akasia dan madu hutan. Setelah itu, pre-processing data agar model dapat mengenali data. Kemudian, eksperimen untuk mendapatkan akurasi yang sangat tinggi dan maksimal. Selanjutnya, pembuatan model MLP berdasarkan nilai akurasi tertinggi pada eksperimen. Kemudian, mengevaluasi model.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Data

Penelitian ini menggunakan data gambar madu akasia dan gambar madu hutan yang diambil langsung dari tempat madu setelah dikirimkan ke Lokasi penelitian di halaman belakang rumah. Pengambilan data dilakukan di luar ruangan (outdoor) pada pagi hingga siang hari, dengan kondisi cuaca cerah dan menggunakan pencahayaan alami tanpa tambahan cahaya buatan. Kamera yang digunakan adalah kamera handphone bermerek Samsung A03s dengan pengaturan resolusi 1:1 karena pemilihan resolusi sangat penting dalam meningkatkan akurasi [19]. Gambar diambil dari berbagai sudut (angle) untuk memastikan keberagaman perspektif sehingga dapat mendukung analisis yang lebih komprehensif. Total data terkumpul adalah 259 gambar, terdiri dari 158 gambar madu akasia dan 101 gambar madu hutan. Gambar digunakan tanpa proses pengolahan tambahan seperti cropping atau pengeditan lainnya, untuk menjaga keaslian data.

2.2 Pre-processing Data

Setelah proses pengambilan data gambar selesai, langkah berikutnya adalah melakukan pre-processing data. Pada tahap ini, gambar dikonversi menjadi nilai RGB agar dapat diolah [18] oleh model Multilayer Perceptron. Hasil konversi kemudian disimpan dalam format CSV untuk mempermudah pengelolaan dan pengenalan data. File CSV tersebut berisi nilai komponen R (merah), G (hijau), dan B (biru), serta label yang merepresentasikan jenis madu. Label diberi nilai 0 untuk madu akasia dan 1 untuk madu hutan. Hasil dataset akan seperti pada **tabel 1**.

Tabel 1. Dataset Madu dalam CSV

R	G	B	label
172.453.673	82.548.765	105.217.409	0
224.689.826	100.457.586	136.459.482	0
...
136.086.648	109.681.155	107.344.776	1
126.463.062	84.674.445	76.602.500	1

Saat pengumpulan data, ditemukan ketidakseimbangan jumlah gambar antara kelas mayoritas dan minoritas, yang dapat menyebabkan model menjadi bias terhadap kelas mayoritas, menurunkan akurasi pada kelas minoritas, dan mengurangi performa secara keseluruhan. Untuk mengatasi masalah ini, digunakan metode ADASYN (Adaptive Synthetic Sampling) [20] untuk menciptakan data sintetik secara adaptif pada sampel

minoritas yang sulit dibedakan, SMOTE (Synthetic Minority Oversampling Technique) [21] untuk menghasilkan data sintetik melalui interpolasi antar sampel minoritas agar distribusinya lebih merata, upsampling mirip seperti SMOTE [22] namun lebih sederhananya untuk menduplikasi data minoritas hingga jumlahnya setara dengan kelas mayoritas, downsampling berbalik dengan upsampling yakni untuk mengurangi jumlah data mayoritas agar seimbang dengan kelas minoritas. Kemudian data pada masing masing output setiap metode akan disimpan kedalam file CSV yang berbeda untuk dipergunakan proses eksperimen, dapat dilihat dalam **tabel 2**. Dengan pendekatan ini, dataset menjadi lebih seimbang sehingga model dapat belajar secara optimal dari semua kelas.

Tabel 2. Hasil file CSV setelah dilakukan balance

Nama File	Metode	Keterangan
honey_dataset.csv	-	Murni tanpa proses handling imbalance data
honey_dataset_adasyn.csv	ADASYN	Menggunakan metode ADASYN
honey_dataset_balanced_adasyn.csv	ADASYN + Downsampling	Menggunakan metode ADASYN kemudian Downsampling
honey_dataset_balanced_smote.csv	SMOTE	Menggunakan Metode SMOTE
honey_dataset_balanced_downs.csv	Downsampling	Menggunakan Metode Doensampling
honey_dataset_balanced_ups.csv	Upsampling	Menggunakan Metode Upsampling

2.3 Eksperimen

Setelah proses pre-processing data, di mana gambar dikonversi menjadi nilai numerik berupa komponen RGB [18], diberikan label yang sesuai, serta dilakukan penanganan ketidakseimbangan data (handling imbalance) dan menyimpan file CSV berdasarkan metode-metode handling imbalance [20], langkah berikutnya adalah melakukan serangkaian eksperimen pada file-file CSV yang telah dan belum dilakukan handling imbalance dengan berbagai kombinasi parameter pada dataset yang telah seimbang maupun yang tidak seimbang. Penanganan ketidakseimbangan data bertujuan untuk memastikan bahwa model dapat belajar secara adil dari semua kelas tanpa bias terhadap kelas tertentu[21].

Eksperimen dilakukan untuk mengevaluasi pengaruh berbagai parameter dan kombinasi pada kinerja model, dengan tujuan utama menemukan konfigurasi yang menghasilkan akurasi tertinggi. Parameter yang diuji meliputi jenis dataset hasil balancing, proporsi data latih dan data uji (test size), nilai random state untuk memastikan reproduktifitas hasil, jumlah lapisan dense (dense layers) pada model, jenis optimizer yang digunakan, nilai learning rate untuk pengaturan kecepatan pembelajaran, jumlah epoch untuk menentukan berapa kali model akan dilatih pada seluruh dataset, serta ukuran batch (batch size) yang mengatur jumlah sampel data yang diproses dalam satu iterasi [22]. Semua eksperimen ini dapat dilihat pada **Tabel 3** di bawah ini, yang menyajikan kombinasi parameter yang diuji dalam eksperimen yang dilakukan.

Tabel 3. Kombinasi eksperimen yang dilakukan

Test Size	Random State	Dense Layers	Optimizer	Learning Rate	Epoch	Batch Size
0.3	2	[64, 32]	adam	0.001	150	32
0.25	3	[128, 64]	adagrad	0.001	150	32
0.2	42	[64, 32]	adam	0.001	150	32
0.2	42	[128, 64, 32]	sgd	0.01	150	32
0.2	25	[64, 32, 16]	sgd	0.003	150	64
0.2	10	[256, 128, 64, 32, 16]	adamax	0.0005	150	32
0.15	12	[256, 128, 64]	adam	0.001	150	32
0.15	3	[128, 64, 32, 16]	adagrad	0.0008	150	16
0.15	1	[128, 64, 32]	rmsprop	0.0001	150	64
0.1	42	[128, 64]	adadelta	0.01	150	16
0.1	8	[64, 32, 16]	sgd	0.005	150	16
0.1	15	[128, 64, 32]	rmsprop	0.002	150	32
0.1	5	[64, 32, 16]	adam	0.0003	150	64
0.1	7	[256, 128, 64, 32]	adam	0.0005	150	32
0.1	10	[256, 128, 64]	adamax	0.0007	150	32

Setelah dilakukan proses dan menjalankan semua kombinasi yang tertera pada **Tabel 2** dan **Tabel 3**, maka didapat detail hasil seperti pada **Tabel 4**.

Tabel 4. Hasil eksperimen berdasarkan urutan validasi akurasi tertinggi

Dataset	Test Size	Random State	Dense Layers	Optimizer	Learning Rate	Epoch	Batch Size
honey_dataset_balanced_adasyn.csv	0.1	7	[256, 128, 64, 32]	adam	0.0005	150	32

Dataset	Test Size	Random State	Dense Layers	Optimizer	Learning Rate	Epoch	Batch Size
honey_dataset_balanced_ups.csv	0.1	7	[256, 128, 64, 32]	adam	0.0005	150	32
honey_dataset_adasyn.csv	0.1	7	[256, 128, 64, 32]	adam	0.0005	150	32
...
honey_dataset_adasyn.csv	0.1	8	[64, 32, 16]	sgd	0.005	150	16
honey_dataset_balanced_downs.csv	0.2	25	[256, 128, 64, 32]	sgd	0.003	150	64
honey_dataset_balanced_smote.csv	0.2	25	[256, 128, 64]	sgd	0.003	150	64

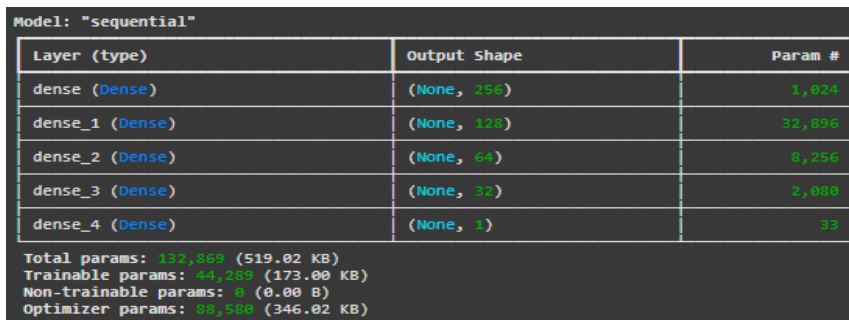
Pada **tabel 4**, dataset yang mendapatkan akurasi tertinggi ialah honey_dataset_balanced_adasyn.csv dengan test size 0.1, random state 7, dense layers [256, 128, 64, 32], optimizer adam, learning rate 0.0005, dan batch size 32.

2.3 Model MLP

Multilayer Perceptron (MLP) adalah jenis jaringan saraf tiruan yang memiliki tiga lapisan neuron: lapisan input, lapisan tersembunyi, dan lapisan output. Neuron-neuron pada lapisan tersembunyi dan output terhubung dengan neuron-neuron pada lapisan sebelumnya melalui bobot (weight) yang dapat disesuaikan selama proses pembelajaran. MLP menggunakan algoritma backpropagation untuk mengoptimalkan bobot-bobot ini, sehingga dapat menghasilkan output yang sesuai dengan target yang diinginkan [23]. Model yang digunakan pada penelitian ini ialah Multilayer Perceptron sebagaimana pada judul. Metode MLP pada penelitian sebelumnya memiliki akurasi yang sangat bagus dan tinggi [1] [18] sehingga memungkinkan memberikan dampak secara tidak langsung bahwa menggunakan metode Multilayer Perceptron memiliki akurasi yang sangat bagus.

Dari pengertian di atas, lapisan input yang digunakan pada penelitian ini adalah dataset honey_dataset_balanced_adasyn.csv, yang telah diolah menggunakan teknik ADASYN untuk menyeimbangkan data [24]. Dataset ini kemudian diproses melalui beberapa lapisan dalam model Multi-Layer Perceptron (MLP). Lapisan pertama adalah lapisan input yang menerima data mentah dari dataset. Selanjutnya, data ini diteruskan ke lapisan tersembunyi (hidden layers), yang terdiri dari empat lapisan dengan jumlah neuron berturut-turut sebanyak 256, 128, 64, dan 32 [25]. Setiap lapisan tersembunyi ini menggunakan fungsi aktivasi ReLU untuk memperkenalkan non-linearitas ke dalam model [26] dapat dilihat pada **Gambar 2**.

Untuk mengoptimalkan proses pembelajaran, penelitian ini menggunakan optimizer Adam dengan nilai learning rate sebesar 0.0005 [27]. Adam dipilih karena kemampuannya dalam menyesuaikan learning rate selama proses training, yang membantu dalam mencapai konvergensi lebih cepat dan stabil. Selain itu, batch size yang digunakan adalah 32, yang merupakan ukuran yang umum digunakan untuk memastikan bahwa model dapat belajar secara efisien tanpa memerlukan terlalu banyak memori komputasi. Lapisan terakhir adalah lapisan output, yang bertugas mengklasifikasikan gambar madu ke dalam jenis akasia atau hutan, serta memberikan nilai persentase untuk masing-masing jenis tersebut.



Layer (type)	Output Shape	Param #
dense (Dense)	(None, 256)	1,024
dense_1 (Dense)	(None, 128)	32,896
dense_2 (Dense)	(None, 64)	8,256
dense_3 (Dense)	(None, 32)	2,048
dense_4 (Dense)	(None, 3)	93

Total params: 133,808 (519.02 KB)
Trainable params: 44,309 (173.00 KB)
Non-trainable params: 0 (0.00 B)
Optimizer params: 89,500 (346.02 KB)

Gambar 2. Arsitektur Model MLP Terbaik

2.4 Evaluasi Model

Setelah membuat dan melatih model Multilayer Perceptron (MLP), evaluasi dilakukan menggunakan data uji dari file honey_dataset_balanced_adasyn.csv dengan proporsi data uji sebesar 10%. Proporsi ini dipilih karena jumlah

data dalam file CSV tersebut relatif sedikit, yaitu kurang dari 500 data. Hasil evaluasi menunjukkan bahwa nilai test loss adalah 0.4769 (47.69%) dan test accuracy adalah 0.9062 (90.62%).

Evaluasi model dilakukan untuk mengukur seberapa baik model yang telah dilatih dapat memprediksi data yang belum pernah dilihat sebelumnya. Test loss mengindikasikan seberapa besar kesalahan prediksi model terhadap data uji, sedangkan test accuracy menunjukkan persentase prediksi yang benar dari total data uji. Nilai test accuracy sebesar 90.62% menunjukkan bahwa model memiliki tingkat akurasi yang tinggi dalam memprediksi data uji [1] [28]

3. HASIL DAN PEMBAHASAN

Hasil penelitian ini dijelaskan secara rinci untuk memberikan pemahaman mendalam mengenai temuan yang diperoleh, merujuk pada metode penelitian yang telah dijelaskan sebelumnya. Data hasil penelitian disajikan dalam bentuk tabel, gambar, dan visualisasi lainnya, disertai penjelasan mendetail untuk memudahkan interpretasi. Pembahasan mencakup analisis kritis terhadap hasil, mengaitkannya dengan hipotesis awal, serta membandingkannya dengan penelitian sebelumnya, dan mengeksplorasi implikasi praktis serta rekomendasi untuk penelitian lebih lanjut. Dengan demikian, pembaca diharapkan memperoleh gambaran yang jelas dan mendalam mengenai hasil penelitian serta relevansi dan kontribusinya dalam bidang studi terkait.

3.1 Pengumpulan Data

Pengumpulan data menggunakan variasi sudut pengambilan gambar memberikan informasi yang lebih kaya dan mendalam mengenai karakteristik visual madu akasia dan madu hutan. Variasi sudut ini digunakan dalam pengambilan dataset untuk mengantisipasi kondisi di lapangan, sehingga dataset dapat mengenali sudut-sudut tersebut. Data ini memungkinkan identifikasi perbedaan dan persamaan antara kedua jenis madu tersebut, yang dapat dilihat dari warna dalam gambar. Selain itu, penggunaan pencahayaan alami membantu dalam menangkap warna asli madu, yang penting untuk analisis visual yang akurat. Dengan demikian, metode pengumpulan data ini terbukti efektif dalam mendukung tujuan penelitian untuk memahami karakteristik visual madu akasia dan madu hutan secara mendalam. Seperti pada gambar 3 menunjukkan hasil pengambilan madu akasia dan madu hutan.



Gambar 3. Madu Akasia dan Madu Hutan

Gambar 3 menunjukkan visualisasi madu akasia dan madu hutan yang mana memiliki warna yang hampir identik dengan pencahayaan yang sama. Gambar 3 jika dilihat tampak sulit untuk dibedakan sehingga mendukung penelitian ini untuk mengangkat dan menyelesaikan masalah ini dengan machine learning. Setelah dilakukan pengambilan gambar madu akasia dan madu hutan dan dilakukan pengumpulan jumlah gambar madu yang didapat, berikut adalah jumlah data pada masing-masing jenis madu yang ditampilkan pada Tabel 6.

Tabel 6. Jumlah data madu jenis akasia dan hutan

Jenis Madu	Jumlah Data
Akasia	158
Hutan	101
Total	259

Tabel 6 menunjukkan jumlah data setiap jenis madu dan jumlah total gambar pada semua jenis madu. Didapat jumlah jenis madu akasia adalah 158 dan jumlah gambar madu hutan adalah 101 sehingga total gambar adalah 259 data gambar.

3.2 Pre-processing Data

Tahap pre-processing dilakukan dengan mengambil data dari gambar madu akasia dan madu hutan yang telah diambil sebelumnya. Gambar tersebut disimpan dalam folder berbeda berdasarkan jenis. Kemudian, data dipanggil dan diekstrak dari yang sebelumnya gambar menjadi angka RGB dengan menggunakan library PIL. Lalu menyimpan kedalam variabel bernama data. Variabel data digunakan untuk menyimpan nilai hasil ekstrak warna



yang kemudian disimpan dalam dataframe yang memiliki kolom R, G, B, dan label yang menghasilkan seperti pada Tabel 1. Kemudian, data disimpan dalam bentuk CSV dengan nama file honey_dataset.csv

Setelah dilakukan konversi dari gambar ke nilai warna RGB, selanjutnya adalah mengecek jumlah data dari masing-masing jenis. Ditemukan bahwa data dari madu akasia yang berlabel angka 0 memiliki data yang lebih besar dengan nilai selisih 57 data, sedangkan data madu hutan yang berlabel angka 1 hanya memiliki jumlah data 101 saja. Sehingga ini menimbulkan masalah jika data digunakan tanpa menyamakan jumlah data sehingga memungkinkan terjadi overfitting atau bahkan underfitting.

3.2.1 Handling Imbalance

Untuk meminimalisir terjadinya overfitting atau underfitting, dilakukan beberapa metode agar data dapat seimbang dan bekerja dengan baik. Berikut adalah metode-metode yang digunakan:

- a. SMOTE: Metode ini menggunakan library SMOTE dan random state bernilai 42. Kemudian dilakukan fit resample terhadap X dan y pada data CSV asli. Setelah itu nilai X dan y yang telah dilakukan resample disimpan kedalam dataframe yang kemudian disimpan dalam file CSV yang bernama honey_dataset_balanced_smote.csv.
b. ADASYN: Metode ini menggunakan library ADASYN dengan random state berjumlah 42. Sama seperti pada SMOTE, data pada variabel X dan y dilakukan fit resample dan kemudian disimpan ke dataframe yang disimpan dengan nama file honey_dataset_adasyn.csv. Namun, setelah dilakukan handling imbalance terdapat ketidak seimbangan jumlah data yang memiliki selisih 2 data saja. Sehingga dilakukan downsampling pada data ADASYN untuk mendapatkan jumlah data yang seimbang, dan data disimpan dalam file baru dengan nama honey_dataset_balanced_adasyn.csv.
c. Upsampling: Upsampling dilakukan agar data menjadi lebih banyak sehingga meningkatkan akurasi. Namun, data yang sedikit dan digunakan upsampling akan memberikan perbedaan yang signifikan.
d. Downsampling: Downsampling dilakukan agar data seimbang dengan data yang paling sedikit. Data yang melebihi data paling sedikit akan dihapus dan disamakan jumlah data sebanyak data minimal. Ini memiliki resiko jika data sedikit dan selisih data sangat banyak. Ini akan memperkecil data yang ada.

3.3 Eksperimen

Banyaknya eksperimen dalam penelitian ini bertujuan untuk mengeksplorasi berbagai kombinasi parameter dan konfigurasi model guna menemukan pengaturan yang paling optimal. Variasi parameter seperti dataset (handling imbalance), test_size, random_state, dense_layers, optimizer, learning_rate, epochs, dan batch_size membantu dalam memahami bagaimana setiap parameter mempengaruhi performa model, serta memastikan robustitas dan generalizability model terhadap perubahan parameter [29]. Proses ini dikenal sebagai tuning hyperparameter, yang merupakan langkah penting dalam machine learning untuk meningkatkan akurasi dan performa model [29]. Dengan melakukan banyak eksperimen, peneliti dapat melakukan analisis komparatif untuk melihat metode atau konfigurasi mana yang paling efektif, memberikan wawasan yang lebih mendalam tentang kekuatan dan kelemahan setiap pendekatan [29].

Tabel 2 dan tabel 3 menjadi kombinasi eksperimen dengan jumlah total 90 eksperimen. Hasil dari eksperimen dapat dilihat pada tabel 4. Namun tabel tersebut belum memiliki isi dari nilai akurasi, berikut beserta nilai akurasi pada tabel 7.

Tabel 7. Hasil eksperimen yang dilakukan

Table with 11 columns: Test Size, Rndm State, Dense Layers, Optimizer, lr, Epoch, Batch Size, Train Acc, Train Loss, Val Acc, Val Loss. It contains experimental results for different parameter combinations.

Test Size	Rndm State	Dense Layers	Optimizer	lr	Epoch	Batch Size	Train Acc	Train Loss	Val Acc	Val Loss
0.2	25	[64, 32, 16]	sgd	0.003	150	64	0.603175	0.665773	0.453125	0.680710

Dari **tabel 7**, terdapat data yang hilang, yakni handle imbalance, data dapat dilihat pada **tabel 4**. Terlihat bahwa berbagai kombinasi parameter dan metode penyeimbangan data memberikan hasil yang berbeda dalam hal akurasi dan loss pada data pelatihan dan validasi. Misalnya, penggunaan metode ADASYN dengan parameter test_size 0.10 dan random_state 7 menghasilkan akurasi pelatihan 91.07% dan akurasi validasi 90.63%, dengan loss validasi 0.4696. Sementara itu, metode upsampling dengan parameter yang sama menghasilkan akurasi pelatihan yang lebih tinggi yaitu 95.77%, namun akurasi validasi tetap sama yaitu 90.63%, dengan loss validasi yang lebih rendah yaitu 0.4005. Hal ini menunjukkan bahwa meskipun akurasi pelatihan lebih tinggi pada metode upsampling, akurasi validasi tidak selalu meningkat secara signifikan, yang bisa mengindikasikan overfitting pada model. Selain itu, metode SMOTE dengan random_state 7 menunjukkan hasil yang cukup baik dengan akurasi pelatihan 92.61% dan akurasi validasi 87.50%, serta loss validasi yang lebih rendah yaitu 0.2498, menunjukkan bahwa metode ini efektif dalam meningkatkan performa model pada data yang seimbang.

3.4 Model MLP

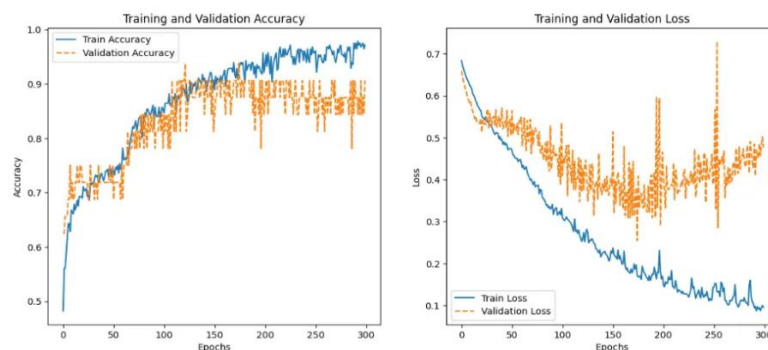
Dari proses dan hasil eksperimen sebelumnya, Pada eksperimen awal, model Multi-Layer Perceptron (MLP) yang dikembangkan menggunakan dataset honey_dataset_balanced_adasyn.csv memberikan hasil terbaik dengan konfigurasi parameter sebagai berikut: proporsi data uji sebesar 10%, random state 7, arsitektur lapisan tersembunyi [256, 128, 64, 32], optimizer Adam, learning rate 0.0005, jumlah epochs 150, dan ukuran batch 32. Model ini menunjukkan kinerja yang sangat baik pada data latih dengan accuracy sebesar 91.07% dan loss sebesar 0.2052. Sementara itu, pada data validasi, model mencapai accuracy sebesar 90.63% dengan loss sebesar 0.4696. Meski akurasi validasi tergolong tinggi, perbedaan antara train loss dan validation loss mengindikasikan adanya kemungkinan overfitting. Berikut detail pengembangan dari eksperimen terbaik pada Tabel 8.

Tabel 8. Pengembangan model dari eksperimen terbaik.

Test Size	Rndm State	Dense Layers	Optimizer	lr	Epoch	Batch Size	Train Acc	Train Loss	Val Acc	Val Loss
0.1	7	[256, 128, 64, 32]	adam	0.0005	300	32	0.971429	0.095594	0.90625	0.476904

Untuk memaksimalkan performa model, dilakukan pengembangan berdasarkan konfigurasi terbaik sebelumnya. Perubahan utama yang diterapkan adalah meningkatkan jumlah epochs dari 150 menjadi 300, dengan harapan model dapat belajar lebih optimal dari data pelatihan. Hasil pengembangan menunjukkan peningkatan performa pada data latih, di mana accuracy mencapai 97.14% dan loss menurun menjadi 0.0956. Namun, pada data validasi, hasil relatif stabil dengan accuracy sebesar 90.63% dan loss sebesar 0.4769. Performa yang konsisten pada data validasi menunjukkan bahwa perubahan konfigurasi memberikan model waktu belajar lebih lama tanpa mengorbankan generalisasi, meskipun belum sepenuhnya mengatasi overfitting.

Visualisasi akurasi dan validasi memainkan peran penting dalam mengevaluasi model yang telah dibuat, karena memungkinkan untuk memahami sejauh mana model tersebut mampu memprediksi dengan benar dan seberapa baik model tersebut dapat diandalkan. Dalam proses ini, visualisasi pada gambar 4 meliputi akurasi pelatihan (training accuracy) dan akurasi validasi (validation accuracy), yang menunjukkan persentase prediksi yang benar selama pelatihan dan validasi model. Selain itu, visualisasi loss pelatihan (training loss) dan loss validasi (validation loss) juga digunakan untuk mengukur seberapa besar kesalahan prediksi yang terjadi selama pelatihan dan validasi.



Gambar 4. Nilai Train dan Validasi pada akurasi dan Loss

Pada Gambar 4, akurasi pelatihan meningkat secara bertahap hingga mendekati 0.9 di akhir pelatihan, sementara akurasi validasi juga menunjukkan peningkatan, meskipun lebih berfluktuasi dibandingkan akurasi

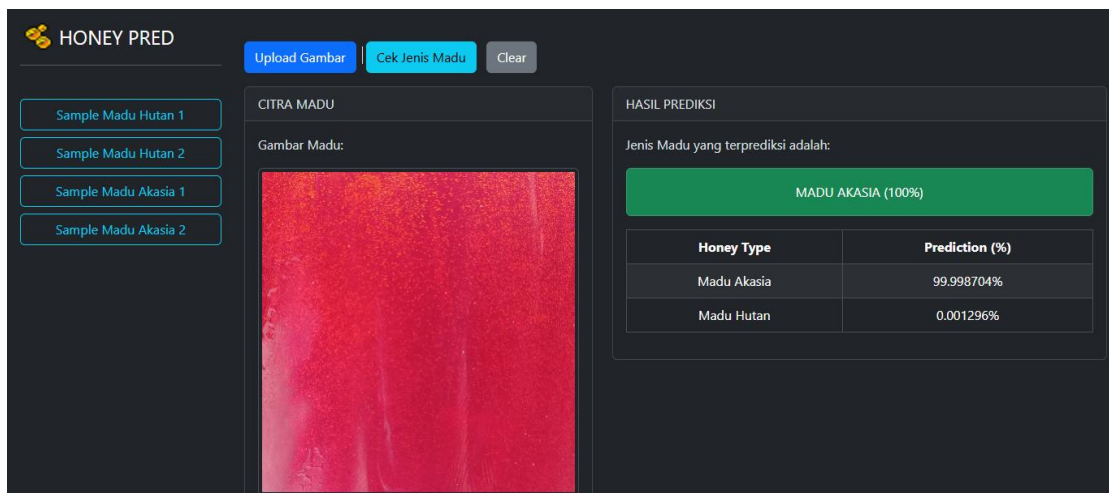
pelatihan. Hal serupa terlihat pada loss, di mana loss pelatihan terus menurun, sedangkan loss validasi cenderung fluktuatif dan mulai meningkat menjelang akhir pelatihan, yang mengindikasikan kemungkinan terjadinya overfitting. Hal ini menunjukkan bahwa meskipun model mampu mencapai akurasi tinggi pada data pelatihan, model mengalami kesulitan dalam melakukan generalisasi pada data validasi. Perbedaan performa antara data pelatihan dan validasi, ditambah dengan peningkatan loss validasi di akhir pelatihan, menekankan perlunya pemantauan performa secara cermat dan penyesuaian proses pelatihan untuk meningkatkan kemampuan generalisasi model.

3.5 Evaluasi

Hasil evaluasi model menunjukkan bahwa pada data uji, model mencapai loss sebesar 0.4769 dan akurasi sebesar 90.62%. Nilai loss yang relatif rendah dan akurasi yang tinggi ini mengindikasikan bahwa model memiliki performa yang baik dalam memprediksi data yang belum pernah dilihat sebelumnya. Namun, nilai loss yang lebih tinggi dibandingkan data pelatihan menunjukkan adanya sedikit tantangan dalam generalisasi.

3.6 Implementasi

Setelah Menyimpan model dengan akurasi evaluasi tertinggi dan terbaik. Selanjutnya adalah menampilkan antarmuka yang sederhana dan minimalis memudahkan pengguna dalam mengoperasikan sistem ini. Sidebar di sebelah kiri menyediakan tombol untuk memilih sampel madu akasia atau hutan, sementara bagian citra madu menampilkan gambar madu yang akan diperiksa. Hasil prediksi klasifikasi beserta persentasenya ditampilkan di bagian hasil prediksi, memberikan informasi yang jelas dan mudah dipahami oleh pengguna. Pada gambar 5 adalah implementasi dari model terbaik yang telah disimpan. Cara penggunaannya pun sangatlah mudah dipahami oleh user karena memiliki tampilan yang minimalis.



Gambar 5. Implementasi pada website

Gambar 5 menunjukkan antarmuka yang disebut "HONEY PRED" yang merupakan situs web yang menyediakan prediksi madu akasia dan madu hutan. Antarmuka ini menampilkan beberapa bagian, termasuk "Upload Gambar" yang memungkinkan pengguna untuk mengunggah gambar sampel madu, "CITRA MADU" yang menampilkan gambar sampel madu yang diunggah, serta "HASIL PREDIKSI" yang menunjukkan hasil prediksi untuk sampel madu. Hasil prediksi ini menunjukkan bahwa jenis madu adalah "Madu Akasia" dengan akurasi prediksi 99,96%, dan juga menunjukkan prediksi untuk jenis madu "Madu Hutan" sebesar 0,01%. Selain itu, terdapat bagian "Sample Madu Hutan 1", "Sample Madu Hutan 2", "Sample Madu Akasia 1", dan "Sample Madu Akasia 2" yang merupakan tombol untuk mencoba klasifikasi dengan cepat.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi jenis madu akasia dan hutan menggunakan algoritma Multilayer Perceptron dengan akurasi yang sangat baik. Model ini menunjukkan akurasi validasi sebesar 90.63% dan akurasi pelatihan sebesar 97.14%, yang menunjukkan kemampuan model dalam mengklasifikasikan jenis madu dengan tepat setelah dilakukan 90 eksperimen dengan kombinasi handling imbalance method, test size, random state, dense layers, optimizer, learning rate, epoch, dan batch size. Implementasi model pada website memberikan kemudahan bagi pengguna untuk mengidentifikasi jenis madu berdasarkan gambar dengan akurasi tinggi. Penelitian ini juga menyoroti pentingnya penanganan ketidakseimbangan data untuk meningkatkan performa model. Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi metode lain dan meningkatkan jumlah data untuk mendapatkan hasil yang lebih baik.



UCAPAN TERIMAKASIH

Penulis menyampaikan terima kasih kepada semua pihak yang telah mendukung terlaksananya penelitian ini. Secara khusus, penulis berterima kasih kepada pengusaha madu yang telah memberikan kesempatan untuk menggunakan dua sampel madu dengan warna hampir sama, atas bantuan dan dukungannya dalam penelitian ini.

REFERENCES

- [1] M. Habib, J. Alhamdani, D. Syauby, and B. H. Prasetyo, "Sistem Klasifikasi Kualitas Jenis-Jenis Madu berdasarkan Warna, Kecerahan, dan pH menggunakan Metode JST Backpropagation," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 6, pp. 2548–964, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [2] A. Ningsih, I. Darwis, and R. Graharti, "Terapi Madu Pada Penderita Ulkus Diabetikum," *Medula*, vol. 9, no. 1, pp. 192–197, 2019.
- [3] R. Ma and R. Shakhboz, "Honey is a Source of Health," *Int. J. Biol. Eng. Agric.*, vol. 03, no. 02, pp. 53–57, 2024.
- [4] A. Febriyanti, C. K. Jiu, and S. Ariyanti, "Efektivitas Jenis-Jenis Madu (Madu Hutan, Madu Kelulut Dan Madu Ternak) Terhadap Kadar Gula Darah," *J. Keperawatan dan Kesehat.*, vol. 11, no. 1, pp. 12–20, 2020, doi: 10.54630/jk2.v11i1.114.
- [5] C. T. Dewi, D. R. Fajari, K. I. Bilqis, L. F. Ahmad, and N. I. Hayati, "Honey's health benefits according to the qur'an," *J. STIKES Muhammadiyah Ciamis J. Kesehat.*, vol. 9, no. 2, pp. 22–25, 2022, [Online]. Available: <https://ojs.stikesmucis.ac.id/index.php/jurkes/article/download/114/72/406>
- [6] H. E. Putri, L. T. Arlym, and R. Widowati, "Pengaruh Konsumsi Madu Akasia Terhadap Dismenore Pada Remaja," *Menara Med.*, vol. 6, no. 2, pp. 231–239, 2024, doi: 10.31869/mm.v6i2.5190.
- [7] O. R. Nasharuddin, N. A., Sunaryo, dan Puspitarini, "Analisa Kualitas Madu Akasia, Karet dan Randu Produksi PT Kembang Joyo Sriwijaya," *J. Din. Rekasatwa*, vol. 5, no. 2, pp. 169–173, 2022.
- [8] D. I. Wahyuni, S. Suratno, and P. Pujiastuti, "Analysis Analisis Kualitas Kimia Madu Akasia Carpa (Acacia crassicarpa) dari Lebah Madu Apis mellifera di Kabupaten Jember," *BioEksakta J. Ilm. Biol. Unsoed*, vol. 6, no. 2, p. 74, 2024, doi: 10.20884/1.bioe.2024.6.2.8762.
- [9] C. R. Ulfa, "Uji aktivitas antioksidan madu hutan trumon dan madu budidaya bener meriah dengan metode dpqh," 2022.
- [10] R. Ratri Rahayu, R. Widowati, and F. Mutiariami Dahlan, "CITRA DELIMA : Jurnal Ilmiah Institut Citra Internasional Perbedaan Efek Madu Akasia dengan Madu Multiflora terhadap Peningkatan Kadar Hemoglobin Remaja Putri," *Ji*, vol. 7, no. 1, pp. 1–7, 2023, [Online]. Available: <http://jurnalilmiah.ici.ac.id/index.php/>
- [11] A. Prasetya Wibawa, W. Lestar, A. Bella Putra Utama, I. Tri Saputra, and Z. Nabila Izdihar, "Multilayer Perceptron untuk Prediksi Sessions pada Sebuah Website Journal Elektronik," *Indones. J. Data Sci.*, vol. 1, no. 3, pp. 57–67, 2020, doi: 10.33096/ijodas.v1i3.15.
- [12] I. G. R. M. Putra, M. W. A. Kesiman, G. A. Pradnyana, and I. M. D. Maysanjaya, "Identifikasi Citra Ukiran Ornamen Tradisional Bali Dengan Metode Multilayer Perceptron," *SINTECH (Science Inf. Technol. J.)*, vol. 4, no. 1, pp. 29–39, 2021, doi: 10.31598/sintechjournal.v4i1.552.
- [13] Y. Amrozi, D. Yuliaty, A. Susilo, N. Novianto, and R. Ramadhan, "Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 11, no. 3, pp. 394–399, 2022, doi: 10.32736/sisfokom.v11i3.1502.
- [14] R. Maneno, B. Baso, P. G. Manek, and K. Fallo, "Deteksi Tingkat Kematangan Buah Pinang Menggunakan Metode Support Vector Machine Berdasarkan Warna Dan Tekstur," *J. Inf. Technol.*, vol. 3, no. 2, pp. 60–66, 2023, doi: 10.32938/jitu.v3i2.5323.
- [15] A. Jinan, B. H. Hayadi, and U. P. Utama, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Convolutional Neural Network Melalui Citra Daun (Multilayer Perceptron)," *J. Comput. Eng. Sci.*, vol. 1, no. 2, pp. 37–44, 2022.
- [16] S. N. Ria, M. Walid, and B. A. Umam, "Pengolahan Citra Digital Untuk Identifikasi Jenis Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN)," *Energy - J. Ilm. Ilmu-Ilmu Tek.*, vol. 12, no. 2, pp. 9–16, 2022, doi: 10.51747/energy.v12i2.1118.
- [17] A. Ahmad, I. S. K. Idris, and A. Bode, "Klasifikasi Jenis Buah Tomat Menggunakan Covolutional Neural network," *J. Ilm. Ilmu Komput.*, vol. 2, no. 2, pp. 83–89, 2023.
- [18] M. Afriansyah, J. Saputra, Y. Sa'adati, and Valian Yoga Pudya Ardhana, "Optimasi Algoritma Naïve Bayes Untuk Klasifikasi Buah Apel Berdasarkan Fitur Warna RGB," *Bull. Comput. Sci. Res.*, vol. 3, no. 3, pp. 242–249, 2023, doi: 10.47065/bulletincsr.v3i3.251.
- [19] A. Goswami et al., "Change Detection in Remote Sensing Image Data Comparing Algebraic and Machine Learning Methods," *Electron.*, vol. 11, no. 3, pp. 1–26, 2022, doi: 10.3390/electronics11030431.
- [20] G. D. Setyawan, A. Yuswanto, A. M. Ridwan, B. Wibowo, and M. Firmansyah, "Implementasi Metode Adasyn Dalam Deteksi Url Berbahaya Menggunakan Machine Learning: Demi Meningkatkan Keamanan Siber Di Era Digital," *Teknokom*, vol. 6, no. 2, pp. 123–126, 2023, doi: 10.31943/teknokom.v6i2.153.
- [21] A. R. Prananda, E. L. Frannita, E. Pramitaningrum, A. Hidayat, W. B. Setiawan, and N. Purwaningsih, "Klasifikasikan Jenis Cacat Kulit Menggunakan SMOTE-GoogLeNet," *JITU J. Inform. Technol. Commun.*, vol. 8, no. 1, pp. 21–30, 2024, doi: 10.36596/jitu.v8i1.1341.
- [22] F. P. Nursyamsyi and F. N. Hasan, "KLIK: Kajian Ilmiah Informatika dan Komputer Klasifikasi Sentimen Terhadap Aplikasi Identitas Kependudukan Digital Menggunakan Algoritma Naïve Bayes dan SVM," *Media Online*, vol. 4, no. 3, pp. 1788–1798, 2023, doi: 10.30865/klik.v4i3.1517.
- [23] P. A. Nugroho, "Implementasi Jaringan Syaraf Tiruan Multi-Layer Perceptron Untuk Prediksi Penyinaran Matahari Kota Bandung," *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 1, pp. 83–90, 2023, doi: 10.34010/komputa.v12i1.9419.
- [24] I. Tolstikhin et al., "MLP-Mixer: An all-MLP Architecture for Vision," *Adv. Neural Inf. Process. Syst.*, vol. 29, pp. 24261–24272, 2021.
- [25] Y. Nie et al., "MLP Architectures for Vision-and-Language Modeling: An Empirical Study," 2021, [Online]. Available:



<http://arxiv.org/abs/2112.04453>

- [26] A. V. Deviney, J. J. Classen, and J. A. Bruce, “A methodology for using a multilevel perspective framework to analyze complex systems,” *Methodol. Innov.*, vol. 16, no. 2, pp. 123–137, 2023, doi: 10.1177/20597991231160280.
- [27] W. Li, H. Chen, J. Guo, Z. Zhang, and Y. Wang, “Brain-inspired Multilayer Perceptron with Spiking Neurons,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2022-June, pp. 773–783, 2022, doi: 10.1109/CVPR52688.2022.00086.
- [28] S. T. Hidayatullah, D. Syauqy, and H. Fitriyah, “Klasifikasi Sumber Nektar Madu berdasarkan Kecerahan dan Warna dengan Metode Naive Bayes berbasis Embedded System,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 8, pp. 3455–3461, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [29] J. Bergstra and Y. Bengio, “Random Search for Hyper-Parameter Optimization,” *J. Mach. Learn. Res.*, vol. 13, pp. 281–305, 2012.