

Klasifikasi profil roasting biji kopi menggunakan neural network

Bima Faturrahman¹, Joko Endrasmono², Mirza Ardiana³, Agus Khumaidi⁴, Zindhu Maulana Ahmad Putra⁵,
Aulia Rahma Annisa⁶

e-mail: bimafaturrahman@student.ppns.ac.id, endrasmono@ppns.ac.id, mirzaardiana@ppns.ac.id,
aguskhumaidi@ppns.ac.id, zindhu@ppns.ac.id, auliaannisa@ppns.ac.id

^{1,2,4,5,6}Jurusan Teknik Kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya, Jl. Teknik Kimia, Kampus ITS Sukolilo, Indonesia

³Jurusan Teknik Bangunan Kapal, Politeknik Perkapalan Negeri Surabaya, Jl. Teknik Kimia, Kampus ITS Sukolilo, Indonesia

Informasi Artikel

Riwayat Artikel

Diterima 13 Mei 2025

Direvisi 7 September 2025

Diterbitkan 30 September 2025

Kata kunci:

Backpropagation
Klasifikasi
Neural Network

Keywords:

Backpropagation
Classification
Neural Network

Penulis Korespondensi:

Bima Faturrahman,
Teknik Otomasi,
Politeknik Perkapalan Negeri Surabaya,
Jl. Teknik Kimia, Kampus ITS Sukolilo.
Email: bimafaturrahman@student.ppns.ac.id
Nomor HP/WA aktif: +6281381766838

ABSTRAK

Penelitian ini bertujuan mengembangkan model untuk mengklasifikasikan tingkat kematangan biji kopi menggunakan jaringan saraf tiruan (*neural network*) dengan algoritma *backpropagation*. Tingkat kematangan dibedakan menjadi tiga kategori, yaitu *light roast*, *medium roast*, dan *dark roast*, dengan masukan berupa suhu maksimum dan lama waktu sangrai. Data primer dikumpulkan dari hasil eksperimen menggunakan mesin sangrai otomatis dengan total 30 data, yang dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Model yang digunakan memiliki dua *hidden layer* dengan masing-masing lima neuron, menggunakan fungsi aktivasi *ReLU* pada lapisan tersembunyi dan *Softmax* pada lapisan output. Proses pelatihan dioptimalkan dengan algoritma *Adam*, sedangkan evaluasi kinerja dilakukan menggunakan *Mean Squared Error* (MSE), *Sum of Squared Error* (SSE), dan *confusion matrix*. Hasil penelitian menunjukkan bahwa model mampu mengklasifikasikan tingkat kematangan biji kopi dengan akurasi tinggi, yaitu 96,67% pada data uji. Uji coba dengan berbagai *learning rate* dan jumlah neuron tersembunyi menunjukkan bahwa kombinasi *learning rate* 0,01 dan 15 neuron memberikan hasil paling stabil serta efisien dalam pelatihan.

ABSTRACT

This study aims to develop a model to classify the maturity level of coffee beans using an artificial neural network with a backpropagation algorithm. The maturity level is divided into three categories, namely light roast, medium roast, and dark roast, with inputs in the form of maximum temperature and roasting time. Primary data was collected from experiments using an automatic roasting machine, with a total of 30 data points, divided into 80% for training and 20% for testing. The model used has two hidden layers, each with five neurons, employing the ReLU activation function in the hidden layers and the Softmax function in the output layer. The training process was optimized using the Adam algorithm, while performance evaluation was conducted using Mean Squared Error (MSE), Sum of Squared Error (SSE), and confusion matrix. The results of the study show that the model is capable of classifying the maturity level of coffee beans with high accuracy, namely 96.67% on the test data. Trials with various learning rates and numbers of hidden neurons show that the combination of a learning rate of 0.01 and 15 neurons provides the most stable and efficient results in training.



1. PENDAHULUAN

Kopi merupakan salah satu komoditas yang sangat penting di Indonesia dan telah menjadi bagian integral dari budaya masyarakat. Salah satu faktor yang memengaruhi kualitas kopi adalah tingkat penyangraian biji kopi, yang dikenal dengan istilah *roasting*. Profil *roasting* biji kopi memainkan peran krusial dalam menciptakan cita rasa kopi yang diinginkan, baik itu ringan (*light roast*), *medium*, maupun gelap (*dark roast*). Oleh karena itu, klasifikasi tingkat penyangraian kopi yang tepat sangat diperlukan untuk memastikan konsistensi kualitas dan cita rasa kopi yang optimal. Namun, proses ini sering kali dilakukan secara manual oleh para ahli kopi, yang memerlukan keahlian dan pengalaman yang cukup tinggi, serta dapat menjadi rentan terhadap ketidaktepatan [1].

Untuk mengatasi keterbatasan tersebut, pendekatan berbasis kecerdasan buatan (AI), khususnya jaringan saraf tiruan (*neural network*), menjadi solusi yang menjanjikan. Sejumlah penelitian sebelumnya menunjukkan bahwa penerapan *neural network* pada citra biji kopi mampu mendeteksi tingkat penyangraian dengan akurasi tinggi [2]. Penelitian internasional terbaru bahkan membuktikan bahwa CNN dapat digunakan untuk mengklasifikasikan tingkat kematangan kopi berbasis citra dengan akurasi hingga 96,75% [3]. Hal ini menegaskan potensi *neural network* dalam mempelajari data dan secara otomatis mengklasifikasikan profil *roasting* berdasarkan karakteristik biji kopi.

Selain arsitektur yang digunakan, kinerja *neural network* juga dipengaruhi oleh pemilihan fungsi loss, seperti *Mean Squared Error* (MSE) atau *Sum of Squared Error* (SSE), serta pengaturan parameter *learning rate* dan jumlah hidden unit. Faktor-faktor ini berperan penting dalam mempercepat konvergensi dan meningkatkan akurasi model [3]. Evaluasi hasil klasifikasi umumnya dilakukan menggunakan *confusion matrix* untuk menilai sejauh mana sistem dapat mengenali tingkat penyangraian dengan tepat.

Berbeda dengan sebagian besar penelitian terdahulu yang menggunakan citra visual dan arsitektur kompleks seperti CNN, penelitian ini berfokus pada parameter numerik sederhana berupa suhu maksimum dan durasi penyangraian. Pendekatan ini lebih efisien secara komputasi, mudah diimplementasikan pada perangkat dengan keterbatasan sumber daya, namun tetap mampu menghasilkan akurasi tinggi. Dengan demikian, penelitian ini berkontribusi dalam menunjukkan bahwa jaringan saraf tiruan berbasis data numerik dapat menjadi alternatif yang efektif sekaligus praktis untuk aplikasi industri kopi.

2. METODE PENELITIAN

Penelitian ini mengimplementasikan model jaringan saraf tiruan menggunakan algoritma *backpropagation* untuk mengklasifikasikan tingkat kematangan biji kopi berdasarkan parameter suhu dan waktu penyangraian. Dataset yang digunakan terdiri atas berbagai pengukuran suhu dan durasi proses sangrai, yang dijadikan sebagai fitur untuk melatih model klasifikasi. Tujuan utama dari klasifikasi ini adalah untuk menghasilkan evaluasi yang akurat terhadap tingkat kematangan biji kopi, yaitu *light roast*, *medium roast*, dan *dark roast*. Penelitian ini bertujuan untuk mengidentifikasi model klasifikasi yang efektif dalam menilai tingkat kematangan biji kopi berdasarkan data numerik dari proses sangrai.

2.1 Dataset

Data yang digunakan dalam penelitian ini diperoleh dari hasil eksperimen proses penyangraian biji kopi yang diklasifikasikan ke dalam tiga tingkat kematangan, yaitu *light roast*, *medium roast*, dan *dark roast*. Data hasil eksperimen tersebut kemudian disajikan dalam Tabel 1, 2, dan 3 sebagai representasi hasil pengukuran yang dilakukan dengan menggunakan mesin sangrai otomatis. Dalam penelitian ini, dua variabel utama yang digunakan adalah suhu maksimum saat proses sangrai dan lama waktu penyangraian. Kedua parameter tersebut dipilih karena memiliki pengaruh besar terhadap warna biji kopi yang dihasilkan. Untuk memberikan gambaran yang lebih jelas, tabel-tabel yang memuat informasi suhu dan waktu sangrai hasil eksperimen disajikan kembali sebagai referensi utama dalam penelitian ini.

TABEL I: Suhu dan Waktu Penyangraian Biji Kopi *Light Roast*

No	Suhu Maksimum Penyangraian	Waktu sangrai
1.	180 °C	6 menit
2.	180 °C	7 menit
3.	180 °C	8 menit
4.	190 °C	6 menit
5.	190 °C	7 menit
6.	190 °C	8 menit



No	Suhu Maksimum Penyangraian	Waktu sangrai
7.	200 °C	6 menit
8.	200 °C	7 menit
9.	200 °C	8 menit
10.	180 °C	8 menit

TABEL II: Suhu dan Waktu Penyangraian Biji Kopi *Medium Roast*

No	Suhu Maksimum Penyangraian	Waktu sangrai
1.	200 °C	8 menit
2.	200 °C	9 menit
3.	200 °C	10 menit
4.	205 °C	8 menit
5.	205 °C	9 menit
6.	205 °C	10 menit
7.	205 °C	10 menit
8.	210 °C	8 menit
9.	210 °C	9 menit
10.	210 °C	10 menit

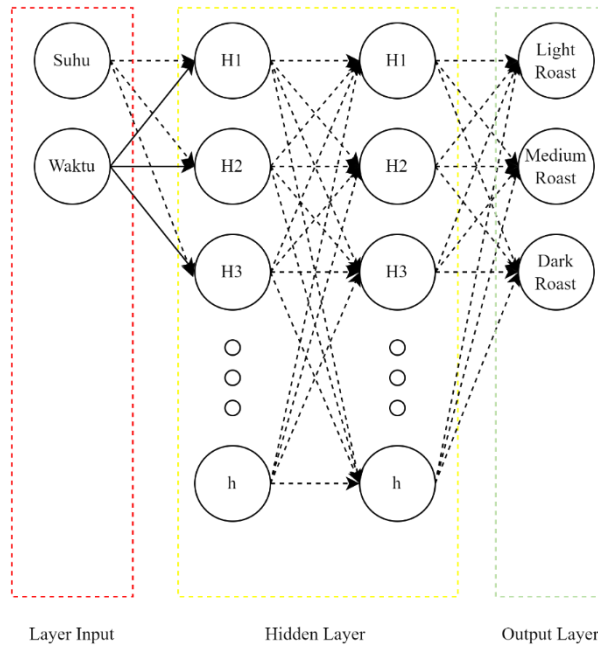
TABEL III: Suhu dan Waktu Penyangraian Biji Kopi *Dark Roast*

No	Suhu Maksimum Penyangraian	Waktu sangrai
1.	220 °C	10 menit
2.	220 °C	11 menit
3.	220 °C	12 menit
4.	230 °C	10 menit
5.	230 °C	11 menit
6.	230 °C	12 menit
7.	220 °C	12 menit
8.	220 °C	10 menit
9.	200 °C	10 menit
10.	200 °C	12 menit

2.2 Neural Network

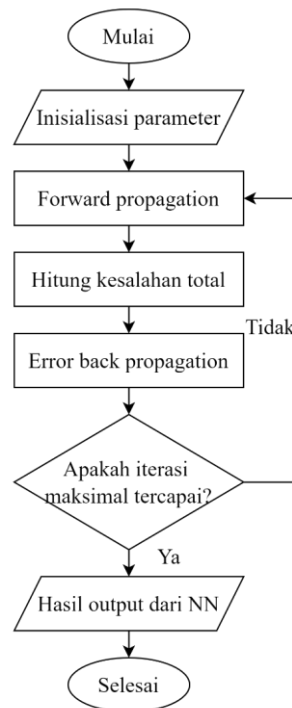
Jaringan Saraf Tiruan (JST) adalah sistem yang dirancang untuk meniru cara otak manusia memproses informasi, terutama dengan belajar melalui penyesuaian bobot pada koneksi antar *neuron*. Data yang dikumpulkan kemudian diolah melalui proses *ekstraksi* untuk mendapatkan informasi penting. Keberhasilan JST sangat bergantung pada bagaimana *neuron-neuron* di dalamnya saling terhubung, yang disebut sebagai arsitektur jaringan. Pada awalnya, bobot pada setiap koneksi antar *neuron* diberi nilai awal sebelum jaringan mulai dijalankan. Selama proses pembelajaran, bobot ini akan terus diperbarui hingga mencapai tingkat kesalahan (*galat*) yang paling kecil. Dalam merancang JST, pola hubungan antar *neuron* diatur sedemikian rupa sehingga setiap *neuron* dapat memproses informasi yang diterima dan mengirimkannya ke *neuron* lain melalui koneksinya. Koneksi ini melibatkan bobot dan *bias*, yang berperan penting dalam menentukan hasil akhir dari pengolahan data [4].





Gambar 1: Arsitektur Jaringan Saraf Tiruan

Penelitian ini menggunakan model jaringan saraf tiruan dengan algoritma *backpropagation* untuk mengklasifikasikan tingkat kematangan biji kopi berdasarkan suhu dan waktu penyangraian. Model ini bekerja dengan menerima data suhu dan durasi sangrai sebagai input, lalu memprosesnya melalui beberapa lapisan di dalam jaringan untuk mempelajari pola-pola tertentu. Fungsi aktivasi digunakan agar model bisa memahami hubungan yang kompleks antar data. Hasil akhirnya adalah prediksi tingkat penyangraian biji kopi, yaitu *light roast*, *medium roast*, atau *dark roast*.



Gambar 2: Flowchart Backpropagation



2.2.1 Input Layer

Dalam penelitian ini, data input untuk jaringan saraf tiruan terdiri dari parameter numerik berupa suhu dan waktu penyangraian biji kopi. Data tersebut diperoleh dari proses sangrai dan digunakan untuk mengklasifikasikan tingkat kematangan biji kopi. Tingkat penyangraian dibagi menjadi tiga kategori, yaitu *light roast*, *medium roast*, dan *dark roast*. Setiap data terdiri dari pasangan nilai suhu dan durasi sangrai, yang digunakan sebagai fitur untuk melatih model dalam mengenali pola kematangan biji kopi berdasarkan proses penyangraian yang berlangsung.

2.2.2 Hidden Layer

Hidden layer merupakan lapisan yang terletak di antara lapisan input dan output, yang berfungsi menangkap serta mempelajari pola-pola kompleks dari data melalui transformasi bobot dan bias. Jumlah dan ukuran *hidden layer* sangat memengaruhi kemampuan model dalam memahami hubungan *nonlinier* antar variabel. Dalam konteks klasifikasi tingkat kematangan biji kopi, *hidden layer* berperan penting dalam mengenali keterkaitan antara parameter suhu dan waktu penyangraian dengan kategori *roasting* yang dihasilkan. Pada penelitian ini, digunakan arsitektur awal berupa 2 *hidden layer* dengan masing-masing 5 neuron. Konfigurasi ini dipilih karena sederhana, efisien secara komputasi, namun tetap mampu merepresentasikan pola data dengan baik.

2.2.3 Activation Function

Fungsi aktivasi adalah bagian penting dari jaringan saraf tiruan karena membantu model belajar hubungan yang tidak hanya bersifat linier. Tanpa fungsi ini, jaringan saraf hanya akan mampu mempelajari pola yang sederhana. Dengan adanya fungsi aktivasi, jaringan bisa mengenali pola-pola yang lebih kompleks, yang sangat dibutuhkan dalam tugas seperti klasifikasi atau prediksi. Beberapa fungsi aktivasi yang sering digunakan dalam jaringan saraf tiruan antara lain *ReLU*, *sigmoid*, *tanh*, dan *softmax*.

ReLU adalah fungsi aktivasi yang paling umum digunakan, terutama pada lapisan tersembunyi. Cara kerjanya sederhana: nilai negatif akan diubah menjadi nol, sedangkan nilai positif tetap dipertahankan. Fungsi ini membantu mempercepat pelatihan dan mengurangi masalah yang bisa membuat model sulit belajar, seperti *vanishing gradient* [5]. Secara matematis, fungsi *ReLU* dituliskan sebagai:

$$f(x) = \max(0, x) \quad (1)$$

Fungsi *sigmoid* akan mengubah setiap nilai *input* menjadi angka antara 0 dan 1. Karena itu, *sigmoid* cocok digunakan untuk klasifikasi biner (dua kelas) [6]. Namun, pada jaringan yang dalam, fungsi ini bisa membuat proses pelatihan lebih lambat karena nilai *gradien*-nya bisa sangat kecil. Secara matematis, fungsi *sigmoid* dituliskan sebagai:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

Fungsi *tanh* mirip dengan *sigmoid*, tetapi hasil *output*-nya berada dalam rentang -1 sampai 1. Kelebihannya adalah rata-rata *output* mendekati nol, sehingga sering kali mempercepat proses pembelajaran jaringan [6]. Secara matematis, fungsi *tanh* dituliskan sebagai:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

Softmax biasanya digunakan pada lapisan akhir untuk klasifikasi dengan lebih dari dua kelas. Fungsi ini akan mengubah *output* menjadi bentuk probabilitas. Dengan kata lain, setiap kelas akan diberi nilai kemungkinan (antara 0 dan 1), dan totalnya akan berjumlah 1. Kelas dengan probabilitas tertinggi akan menjadi hasil prediksi [7]. Secara matematis, fungsi *softmax* dituliskan sebagai:

$$f_i(x) = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}} \quad (4)$$



2.3 Output layer

Lapisan output pada jaringan saraf tiruan di penelitian ini berfungsi untuk menentukan hasil akhir dari klasifikasi tingkat kematangan biji kopi, yaitu *light roast*, *medium roast*, atau *dark roast*. Pada bagian ini digunakan fungsi *aktivasi Softmax*, yang mengubah hasil keluaran jaringan menjadi nilai probabilitas untuk setiap kelas. Kelas dengan nilai probabilitas tertinggi akan dipilih sebagai prediksi akhir dari model.

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan mengembangkan model *Neural Network* untuk mengklasifikasikan tingkat kematangan biji kopi hasil penyangraian ke dalam tiga kategori, yaitu *light roast*, *medium roast*, dan *dark roast*. Model dibuat berdasarkan data hasil eksperimen berupa suhu dan waktu selama proses penyangraian. Penggunaan data ini memungkinkan model lebih representatif terhadap kondisi nyata. Untuk meningkatkan efisiensi pelatihan serta akurasi klasifikasi, digunakan algoritma optimasi *Adam*. Pelatihan model dilakukan menggunakan fungsi loss *Mean Squared Error* (MSE) yang menghitung seberapa besar perbedaan antara hasil prediksi dengan data sebenarnya.

Selain itu, penelitian ini juga menganalisis pengaruh jumlah unit tersembunyi (*hidden unit*) terhadap total kesalahan *Sum of Squared Error* (SSE) guna menemukan konfigurasi model yang paling optimal. Data dibagi dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Uji coba juga dilakukan terhadap berbagai nilai *learning rate* untuk mengevaluasi seberapa cepat dan stabil model dapat mencapai hasil terbaik. Evaluasi performa model dilakukan dengan mengukur nilai *SSE*, akurasi klasifikasi, serta menggunakan *confusion matrix* untuk melihat sejauh mana model dapat mengidentifikasi kelas dengan tepat. Hasil yang diperoleh menunjukkan bahwa model mampu melakukan klasifikasi secara otomatis dan akurat.

3.1 Performa Model Berdasarkan Nilai Loss MSE Setiap Iterasi

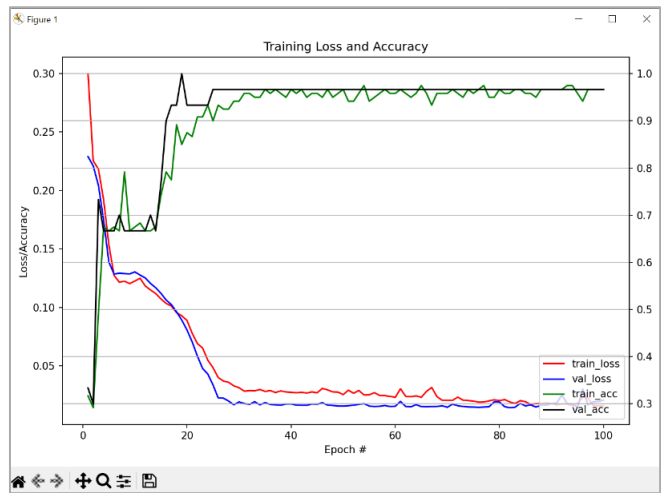
Adam (*Adaptive Moment Estimation*) adalah algoritma optimasi yang menggabungkan dua konsep utama dari algoritma sebelumnya, yaitu *Momentum* dan *RMSProp* [8]. Inti dari *Adam* adalah menyesuaikan laju pembelajaran (*learning rate*) untuk setiap parameter model dengan mempertimbangkan dua hal: rata-rata *gradien* dan rata-rata kuadrat *gradien*. Dengan demikian, *Adam* secara otomatis menyesuaikan laju pembelajaran berdasarkan informasi yang lebih lengkap mengenai *gradien* dan variansinya, memungkinkan pembaruan parameter yang lebih efisien.

Proses pelatihan model dilakukan dengan menggunakan algoritma optimasi *Adam* dengan nilai *learning rate* sebesar 0,01. Arsitektur model terdiri dari dua variabel *input*, yaitu suhu dan waktu penyangraian, serta dua *hidden layer* yang masing-masing terdiri atas lima neuron. Model ini menghasilkan tiga kelas *output*, yaitu *light roast*, *medium roast*, dan *dark roast*. Pelatihan dilakukan mulai dari iterasi ke-100 hingga ke-1000 untuk mengevaluasi peningkatan performa model secara bertahap. Hasil evaluasi berupa nilai kerugian (*loss*) dan akurasi pada iterasi tertentu, yakni iterasi ke-100, 500, dan 1000, disajikan dalam bentuk ilustrasi pada Gambar 3, Gambar 4, dan Gambar 5 untuk memberikan gambaran yang lebih jelas mengenai efektivitas algoritma *Adam* dalam mengoptimalkan performa model klasifikasi tingkat kematangan biji kopi.

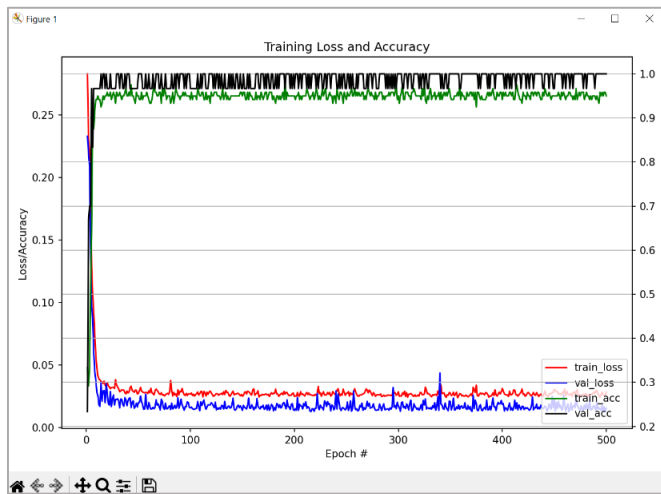
Berdasarkan data yang diperoleh pada Tabel IV, model menunjukkan performa yang baik dengan tingkat akurasi pada data uji (*test accuracy*) yang stabil sekitar 96,67%. Pada iterasi ke-100 nilai loss uji sebesar 0,0125 dengan akurasi 96,67%. Pada iterasi ke-500, loss uji meningkat ke 0,0274 namun akurasi tetap stabil di 96,67%. Sementara itu, pada iterasi ke-1000 nilai loss uji tercatat sebesar 0,0256 dengan akurasi masih bertahan di 96,67%. Hal ini menunjukkan bahwa model telah mencapai titik optimal sejak awal, tanpa peningkatan berarti pada akurasi data uji setelah epoch ke-500.

Meskipun terdapat fluktuasi kecil pada nilai kerugian (*loss*) baik pada data pelatihan (*train loss*) maupun data uji (*test loss*), secara keseluruhan model mampu mempelajari pola data dengan baik dan menjaga kemampuan generalisasi terhadap data uji. Dengan kata lain, stabilitas akurasi sebesar 96,67% pada berbagai iterasi mengindikasikan bahwa arsitektur yang digunakan sudah cukup representatif dalam menangkap hubungan antara variabel input (suhu dan waktu) dengan kategori profil *roasting*.

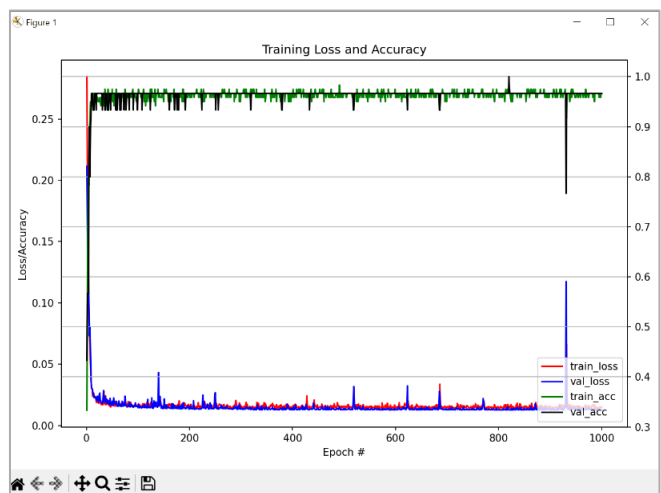




Gambar 3: Hasil Pelatihan Model pada Iterasi ke-100



Gambar 4: Hasil Pelatihan Model pada Iterasi ke-500



Gambar 5: Hasil Pelatihan Model pada Iterasi ke-1000

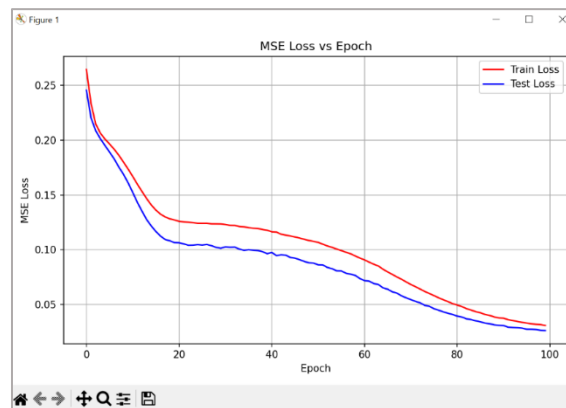


TABEL IV: Hasil Performa Model pada Setiap Iterasi Berdasarkan Nilai MSE Loss dan Akurasi

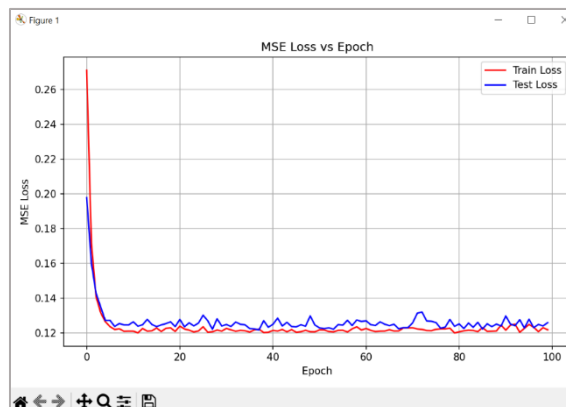
Epoch	Train Loss	Test Loss	Train Accuracy	Test Accuracy
100	0.0215	0.0125	95.00%	96.67%
200	0.0305	0.0200	96.67%	100.00%
300	0.0165	0.0058	96.67%	100.00%
400	0.0160	0.0053	96.67%	100.00%
500	0.0234	0.0274	97.50%	96.67%
600	0.0182	0.0170	95.00%	96.67%
700	0.0141	0.0100	98.33%	96.67%
800	0.0159	0.0123	96.67%	96.67%
900	0.0173	0.0110	95.83%	96.67%
1000	0.0149	0.0226	95.83%	96.67%

3.2 Pengaruh *Learning Rate* terhadap Nilai SSE

Learning rate merupakan salah satu parameter kunci dalam pelatihan jaringan saraf tiruan karena menentukan seberapa besar langkah perubahan bobot yang dilakukan model pada setiap iterasi [9]. Dalam penelitian ini, pengaruh *learning rate* terhadap nilai *Sum of Squared Error (SSE)* diamati untuk mengevaluasi efektivitas proses pembelajaran model. Pelatihan dilakukan menggunakan tiga variasi *learning rate*, yaitu 0.001, 0.01, dan 0.1, dengan jumlah *epoch* yang sama, yaitu 100 iterasi. Tujuan dari pengujian ini adalah untuk membandingkan seberapa cepat dan stabil setiap *learning rate* dalam menurunkan nilai *SSE*, serta mengamati apakah terjadi gejala underfitting, konvergensi stabil, atau overfitting selama proses pelatihan.

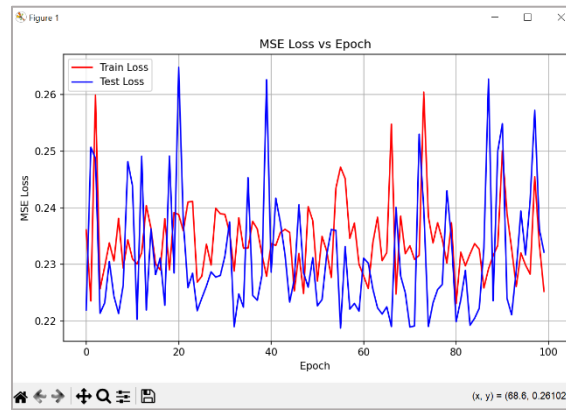


Gambar 6: Hasil Pelatihan Model dengan *Learning Rate* 0.001



Gambar 7: Hasil Pelatihan Model dengan *Learning Rate* 0.01





Gambar 8: Hasil Pelatihan Model dengan *Learning Rate* 0.1

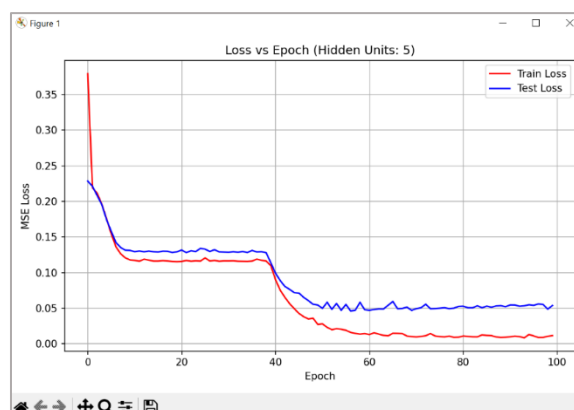
Berdasarkan Gambar 6 hingga Gambar 8, terlihat bahwa setiap nilai *learning rate* memberikan pengaruh yang berbeda terhadap nilai *loss* (*SSE*) dan akurasi model. Pada *learning rate* 0.001, penurunan *loss* berlangsung sangat lambat dan peningkatan akurasi juga minim, yang mengindikasikan bahwa model mengalami *underfitting* karena langkah pembelajarannya terlalu kecil. Sebaliknya, *learning rate* 0.1 menunjukkan penurunan *loss* yang cepat di awal pelatihan, namun disertai fluktuasi besar dan akurasi yang tidak stabil, sehingga berisiko menyebabkan *overfitting*. Sementara itu, *learning rate* 0.01 memberikan hasil terbaik, dengan penurunan *loss* yang stabil dan peningkatan akurasi yang seimbang antara data pelatihan dan pengujian. Hal ini menunjukkan bahwa *learning rate* 0.01 merupakan pilihan paling optimal untuk mencapai pelatihan model yang efektif dan stabil.

3.3 Pengaruh Jumlah *Hidden Unit* Terhadap *SSE*

Jumlah *hidden unit* atau neuron tersembunyi dalam jaringan saraf tiruan merupakan salah satu parameter penting yang berperan dalam kemampuan model untuk mempelajari dan mengenali pola dalam data. Pada penelitian ini, dilakukan pengujian terhadap pengaruh variasi jumlah *hidden unit* terhadap nilai *Sum of Squared Error* (*SSE*), yang digunakan sebagai indikator akurasi prediksi model.

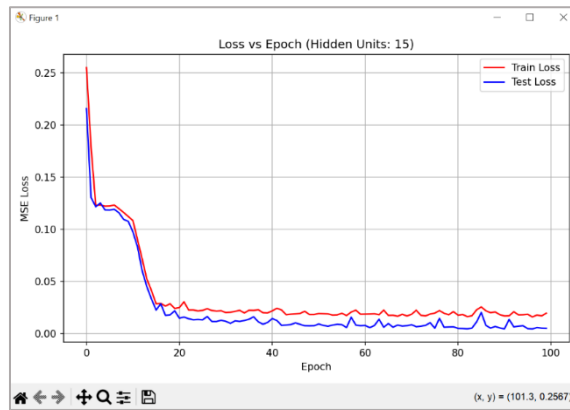
Pelatihan dilakukan dengan menggunakan enam variasi jumlah *hidden unit*, yaitu 5, 10, 15, 20, 25, dan 30, dengan jumlah *epoch* yang sama, yaitu 100 iterasi. Tujuan dari pengujian ini adalah untuk mengevaluasi bagaimana kompleksitas jaringan saraf mempengaruhi kualitas hasil pembelajaran, apakah model mengalami *underfitting*, konvergensi optimal, atau *overfitting*.

Meskipun hasil pengujian menunjukkan bahwa 15 neuron memberikan performa paling stabil, arsitektur awal dengan 2 *hidden layer* berisi masing-masing 5 neuron tetap dipertahankan. Konfigurasi ini lebih sederhana, efisien secara komputasi, dan sudah cukup mampu menghasilkan akurasi tinggi pada data uji, sehingga sesuai untuk kebutuhan aplikasi nyata.

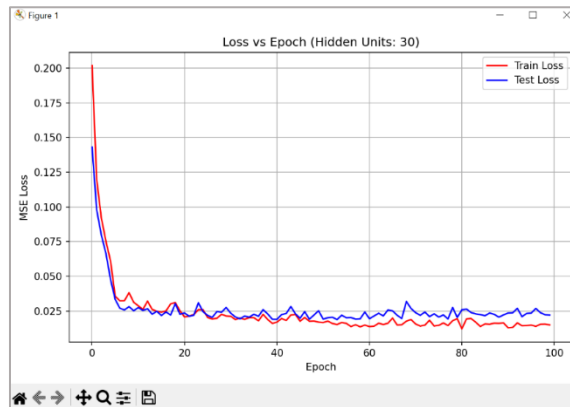


Gambar 9: Hasil Pelatihan Model Dengan 5 *Hidden Unit*





Gambar 10: Hasil Pelatihan Model Dengan 15 *Hidden Unit*



Gambar 11: Hasil Pelatihan Model Dengan 30 *Hidden Unit*

Berdasarkan Gambar 9, 10, dan 11, variasi jumlah *hidden unit* terbukti memengaruhi nilai *loss (SSE)* dan performa model. Pada jumlah *hidden unit* sebanyak 5, *SSE* menurun sangat lambat dan tetap tinggi hingga akhir pelatihan, menandakan *underfitting* akibat kapasitas model yang terlalu rendah. Sebaliknya, pada 30 *hidden unit*, penurunan *SSE* tidak stabil dan cenderung fluktuatif, menunjukkan gejala *overfitting* karena model terlalu kompleks. Sementara itu, konfigurasi dengan 15 *hidden unit* menunjukkan penurunan *SSE* yang cepat dan stabil, tanpa fluktuasi berarti, sehingga dapat dikategorikan sebagai konvergensi optimal dan menjadi konfigurasi paling seimbang untuk menghasilkan model yang akurat dan stabil.

3.4 Coefusion Matrix

Confusion matrix adalah metode evaluasi yang digunakan untuk menilai sejauh mana model yang dikembangkan dapat bekerja sesuai dengan yang diharapkan. Untuk itu, kelebihan dan kekurangan sistem dianalisis menggunakan tiga parameter evaluasi utama, yaitu akurasi, presisi, dan recall. Akurasi mengukur sejauh mana hasil klasifikasi secara keseluruhan sesuai dengan data yang benar, sedangkan presisi menggambarkan seberapa tepat prediksi model terhadap suatu kelas jika dibandingkan dengan seluruh prediksi yang dihasilkan. Di sisi lain, recall mengukur kemampuan model dalam mengenali seluruh data yang benar-benar termasuk dalam suatu kelas. Presisi menghitung proporsi prediksi yang benar di antara seluruh data yang diprediksi sebagai positif, sedangkan recall menunjukkan seberapa banyak data yang benar-benar positif berhasil dikenali oleh model. Berikut adalah rumus matematis yang digunakan untuk menghitung akurasi, presisi, dan recall:

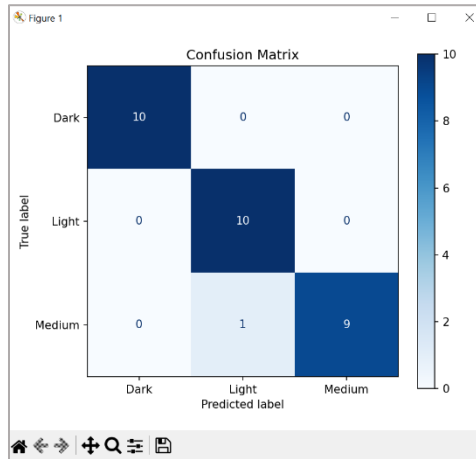
$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{5}$$

$$Precision = \frac{TP}{TP+FP} \tag{6}$$



$$Recall = \frac{TP}{TP+FN} \tag{7}$$

Dalam evaluasi model klasifikasi, istilah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) digunakan untuk menggambarkan hasil prediksi model terhadap data sebenarnya. TP menunjukkan jumlah data yang benar-benar positif dan berhasil diklasifikasikan dengan tepat sebagai positif oleh model. TN adalah data negatif yang juga diklasifikasikan dengan benar sebagai negatif. FP terjadi ketika model salah mengklasifikasikan data negatif sebagai positif, sedangkan FN adalah data positif yang justru diklasifikasikan secara keliru sebagai negatif. Keempat komponen ini digunakan sebagai dasar dalam menghitung metrik evaluasi seperti akurasi, presisi, dan recall untuk mengukur performa model secara menyeluruh [10].



Gambar 12: Hasil Klasifikasi Model Menggunakan *Confusion Matrix*

TABEL V: Hasil Klasifikasi Data Pengujian

Kategori	Tabel Klasifikasi			Prediksi	Hasil
	Light	Medium	Dark	Presentasi	Presentasi
Light	10	0	0	100%	0%
Medium	1	9	0	90%	10%
Dark	0	0	10	100%	0%

TABEL VI: Hasil Analisis Data Pengujian

Kategori	TP	TN	FP	FN	Precision	Recall	Accuracy
Light	10	19	1	0	90.91%	100%	96.67%
Medium	9	20	0	1	100%	90%	96.67%
Dark	10	20	0	0	100%	100%	100%
Total					96.97%	96.67%	96.67%

Tabel V menunjukkan hasil klasifikasi terhadap data uji yang digunakan untuk mengevaluasi kemampuan sistem dalam mengenali tingkat kematangan kopi, yang terdiri dari tiga kelas, yaitu *Light*, *Medium*, dan *Dark*. Hasil pengujian menunjukkan bahwa sistem berhasil mengklasifikasikan seluruh data pada kelas *Light* dan *Dark* dengan benar. Namun, pada kelas *Medium*, terdapat satu data yang diklasifikasikan secara keliru. Secara keseluruhan, dari 30 data uji, sistem mampu mengklasifikasikan 29 data dengan tepat. Satu kesalahan terjadi pada data kelas *Medium* yang diprediksi sebagai *Light*.

Kesalahan ini kemungkinan disebabkan oleh kemiripan karakteristik antara kelas *Medium* dan *Light*, terutama pada nilai suhu dan waktu penyangraian yang berada di area transisi. Kemiripan tersebut menjadi tantangan dalam proses klasifikasi, sebagaimana terlihat pada Tabel V. Sedangkan pada Tabel VI adalah hasil kinerja sistem yang



diperoleh dengan menghitung akurasi, presisi, dan recall. Berdasarkan pengujian yang dilakukan, nilai *precision* yang diperoleh adalah 96.97% dan nilai *recall*, serta akurasi masing-masing adalah 96.67% dan 96.67%.

4. KESIMPULAN

Sistem klasifikasi tingkat kematangan biji kopi yang dikembangkan menggunakan *neural network* dengan input suhu maksimum dan waktu sangrai berhasil mengelompokkan biji kopi ke dalam tiga kategori, yaitu *light roast*, *medium roast*, dan *dark roast*. Model dengan konfigurasi dua *hidden layer* berisi lima *neuron* dan *learning rate* 0,01, yang dioptimalkan dengan algoritma *Adam*, mencapai akurasi uji sebesar 96,67%, dengan nilai *precision* 96,97% dan *recall* 96,67%. Hasil pengujian variasi jumlah *hidden unit* menunjukkan bahwa 15 *neuron* memberikan performa paling stabil, ditunjukkan oleh nilai *loss* yang rendah serta tidak adanya gejala *underfitting* maupun *overfitting*.

5. UCAPAN TERIMAKASIH

Penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada dosen pembimbing atas segala bimbingan, dukungan, dan arahan yang sangat berharga selama proses penelitian ini. Ucapan terima kasih juga disampaikan kepada keluarga dan teman-teman atas dukungan moral yang tak henti-hentinya. Selain itu, apresiasi juga diberikan kepada semua pihak yang telah berkontribusi, baik secara langsung maupun tidak langsung, dalam membantu kelancaran dan keberhasilan penelitian ini.

DAFTAR PUSTAKA

- [1] A. F. Setiadi F., A. A. Kurniawan, A. D. Hartanto, and H. Hartatik, "Implementasi Metode CNN dan Deep Learning untuk Menentukan Tingkat Roasting Biji Kopi," *Intechno J. (Information Technol. Journal)*, vol. 4, no. 2, pp. 48–54, 2022, doi: 10.24076/intechnojournal.2022v4i2.1563.
- [2] I. Alfiantama, M. I. Kresnawan, and A. P. Handoko, "Klasifikasi Tingkat Roasting Biji Kopi Dengan Metode CNN," *Pros. Semin. Nas. Teknol. Dan Sains Tahun 2024*, vol. 3, pp. 285–290, 2024.
- [3] K. Marzuki and M. Q. Apriani, "Coffee Roaster Maturity Level Classification Based on Convolutional Neural Network," *Math. Model. Eng. Probl.*, vol. 12, no. 1, pp. 46–54, 2025, doi: 10.18280/mmep.120106.
- [4] D. Setyowati and S. Sunardiyo, "Prakiraan Kebutuhan Energi Listrik Dengan Jaringan Saraf Tiruan (Artificial Neural Network) Metode Backpropagation Tahun 2020-2025," *J. EECCIS (Electrics, Electron. Commun. Control. Informatics, Syst.)*, vol. 14, no. 1, pp. 6–9, 2020, doi: 10.21776/jeccis.v14i1.604.
- [5] B. S. C. Putra and I. Tahyudin, "Performance Evaluation of CNN-LSTM and CNN-FNN Combinations for Pneumonia Classification Using Chest X-ray Images," vol. 8, no. January, pp. 196–207, 2025.
- [6] D. N. Fitriani and S. Bahri, "Prediksi PREDIKSI TINGKAT OBESITAS MENGGUNAKAN NEURAL NETWORK: PENDEKATAN KLASIFIKASI BINER," *Param. J. Mat. Stat. dan Ter.*, vol. 3, no. 01, pp. 85–92, 2024, doi: 10.30598/parameterv3i01pp85-92.
- [7] M. R. R. Allaam, A. T. Wibowo, and E. Rachmawati, "Klasifikasi Genus Tanaman Sukulen Menggunakan Convolutional Neural Network," *eProceedings Eng.*, vol. 8, no. 2, p. 1153, 2021, [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/14708>
- [8] Y. A. Fernandes and Y. Fatma, "METODE DEEP LEARNING DALAM TEKNOLOGI DEEPFAKE ;," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 3403–3410, 2025.
- [9] E. Khatizah, "KONSEP MATEMATIKA DI BALIK JARINGAN SARAF TIRUAN SEBAGAI FONDASI KECERDASAN BUATAN," vol. 20, no. 2, pp. 145–156, 2024.
- [10] M. Azhari, Z. Situmorang, and R. Rosnelly, "Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes," *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 640, 2021, doi: 10.30865/mib.v5i2.2937.

