

KLASIFIKASI JENIS REMPAH-REMPAH ALAMI UNTUK KECANTIKAN MENGGUNAKAN DENSENET 121

Cindy Fadillah, Supatman

Informatika, Universitas Mercu Buana Yogyakarta
Jl. Jembatan Merah No. 84C Gejayan, Yogyakarta, Indonesia
Cindyfadillah1874@gmail.com

ABSTRAK

Indonesia dikenal dengan kekayaan rempah-rempah yang memiliki banyak manfaat dalam masakan, kesehatan, dan kecantikan. Namun, kesulitan dalam membedakan berbagai jenis rempah dengan bentuk dan warna yang mirip menjadi masalah yang sering dihadapi. Penelitian ini bertujuan untuk menerapkan sistem klasifikasi citra rempah-rempah menggunakan DenseNet-121. Metode yang digunakan meliputi akuisisi citra rempah, pelabelan, preprocessing, dan pelatihan model CNN dengan dataset yang terdiri dari 1.075 gambar rempah, dibagi menjadi lima kelas (kunyit, jahe, kencur, cengkeh, dan serai). Model dilatih menggunakan optimizer Adamax dengan ukuran citra 110x110 piksel dan dievaluasi berdasarkan akurasi, precision, recall, dan f1-score. Hasil penelitian menunjukkan bahwa model berhasil mencapai akurasi 0.95, precision 0.95, recall 0.97, dan f1-score 0.95. Penelitian ini menunjukkan efektivitas CNN dalam klasifikasi rempah-rempah dan memberikan kontribusi untuk aplikasi pengolahan citra dalam industri rempah dan kecantikan.

Kata kunci : DenseNet-121, Klasifikasi, Rempah-rempah

1. PENDAHULUAN

Indonesia dikenal dengan kekayaan rempah-rempahnya yang melimpah, yang tidak hanya digunakan dalam masakan dan kesehatan tetapi juga memiliki manfaat signifikan bagi dan kecantikan. Rempah-rempah, seperti jahe (*Zingiber officinale*), kunyit (*Curcuma longa*), kencur (*Kaempferia galanga*), cengkeh (*Syzygium aromaticum*), dan serai (*Cymbopogon citratus*), telah digunakan oleh masyarakat Indonesia sebagai bahan dasar dalam pengobatan tradisional dan produk kecantikan alami. Rempah-rempah merupakan jenis tumbuhan yang sangat mudah ditemukan di wilayah Indonesia dan manfaatnya sangat banyak digunakan oleh masyarakat. Rempah-rempah terdapat pada bagian-bagian tumbuhan yang berasal dari bagian batang, daun, kulit kayu, umbi, rimpang, akar, biji, bunga dan bagian tubuh tumbuhan lainnya [1]. Selain itu, aroma kuat yang dihasilkan oleh rempah-rempah membuatnya sering digunakan sebagai perisa, pewarna, dan pengawet makanan [2].

Namun, dengan banyaknya jenis rempah yang memiliki kemiripan bentuk dan warna, sering kali masyarakat kesulitan dalam membedakan satu jenis rempah dengan yang lainnya. Penerapan teknologi untuk mengenali rempah secara otomatis dan akurat menjadi solusi yang sangat diperlukan. Salah satu teknologi yang dapat digunakan adalah Convolutional Neural Network (CNN), sebuah metode deep learning yang dapat mengidentifikasi objek dalam citra dengan tingkat akurasi yang tinggi. Dalam hal ini, CNN dapat mempermudah klasifikasi rempah-rempah dengan memanfaatkan gambar sebagai input untuk mengenali jenis rempah yang memiliki kesamaan bentuk dan warna [3].

Penelitian sebelumnya menunjukkan bahwa CNN, khususnya dengan menggunakan model yang

sudah dilatih (pretrained) seperti DenseNet121, dapat memberikan hasil yang sangat baik dalam pengolahan citra. Model DenseNet121 yang memiliki ribuan parameter ini terbukti mampu mengenali objek dalam citra secara efektif. Proses pelatihan model dengan arsitektur CNN DenseNet121 menghasilkan tingkat keakuratan mencapai 99%, sementara tingkat keakuratan validasi mencapai 88,78% [3]. Dalam penelitian lain, penerapan CNN pada klasifikasi rempah-rempah juga menunjukkan bahwa model ini efektif dalam mengidentifikasi jenis rempah dengan efisiensi dan akurasi tinggi [4].

Penggunaan CNN dalam klasifikasi citra rempah-rempah dapat membantu masyarakat Indonesia dalam mengenali berbagai jenis rempah dengan lebih mudah dan cepat. Seiring dengan kemajuan teknologi, pengenalan citra menggunakan model CNN juga telah berhasil diterapkan pada berbagai bidang lain seperti pengenalan penyakit kulit wajah, yang memiliki relevansi dalam aplikasi kecantikan [1]. Hal ini menegaskan bahwa penggunaan teknologi ini dapat diadaptasi untuk berbagai tujuan, termasuk meningkatkan kualitas produk kecantikan berbasis rempah di Indonesia.

2. TINJAUAN PUSTAKA

2.1. Rempah-Rempah


Rempah-rempah adalah bagian dari tanaman yang digunakan dalam berbagai keperluan, seperti bahan makanan, pengobatan, dan industri lainnya. Rempah-rempah dapat diperoleh dari berbagai bagian tanaman, termasuk batang, daun, kulit kayu, umbi, akar, biji, bunga, dan lainnya. Sebagai sumber daya hayati, rempah-rempah memiliki peran penting dalam sejarah kehidupan manusia dan tersebar luas di negara-negara tropis, seperti Indonesia, yang kaya akan sektor pertaniannya. Sebagai contoh, Indonesia dikenal

sebagai salah satu negara penghasil rempah-rempah yang memiliki kekayaan rempah yang luar biasa, yang digunakan dalam masakan, obat tradisional, hingga kosmetik [5][6].

2.2. Klasifikasi dalam Data Mining dan Computer Vision

Klasifikasi adalah proses untuk mengelompokkan data berdasarkan atribut atau karakteristik tertentu. Dalam konteks computer vision, klasifikasi gambar dilakukan dengan menganalisis ciri-ciri objek dalam gambar untuk mengelompokkan gambar berdasarkan kategori yang telah ditentukan sebelumnya. Dalam penelitian ini, klasifikasi gambar rempah-rempah bertujuan untuk mengidentifikasi berbagai jenis rempah-rempah berdasarkan citra visualnya menggunakan teknologi deep learning, khususnya Convolutional Neural Network [7].

2.3. Convolutional Neural Network (CNN)



Gambar 1. Arsitektur CNN [12]

Convolutional Neural Network (CNN) merupakan metode dalam deep learning yang sangat efektif untuk memproses data berbentuk gambar dua dimensi. CNN digunakan untuk mengidentifikasi dan mengklasifikasikan objek dalam gambar tanpa memerlukan ekstraksi ciri manual. CNN memiliki beberapa lapisan penting, antara lain lapisan konvolusi, pooling, dan fully connected, yang secara otomatis mengekstraksi fitur dari gambar dan melakukan klasifikasi berdasarkan pola yang ditemukan dalam data [8][9].

CNN bekerja dengan cara mengaplikasikan filter (kernel) untuk melakukan konvolusi pada citra input, sehingga menghasilkan fitur yang relevan yang digunakan untuk klasifikasi objek. Salah satu keuntungan utama dari CNN adalah kemampuannya untuk belajar fitur-fitur penting secara otomatis dari data gambar tanpa memerlukan proses ekstraksi fitur yang rumit [10]. Selain itu, CNN dapat mengatasi masalah overfitting dengan menggunakan teknik seperti dropout dan regularisasi [8].


3. METODE PENELITIAN

Studi ini menggunakan arsitektur DenseNet-121 untuk klasifikasi lima jenis rempah alami yang sering digunakan dalam kecantikan, yaitu kunyit, jahe, kencur, cengkeh, dan serai. Data citra rempah dikumpulkan, diproses, dan dilatih menggunakan DenseNet-121, yang dioptimalkan untuk mengenali pola visual seperti tekstur, warna, dan bentuk rempah

dengan akurasi tinggi. Alur penelitian mencakup akuisisi data, preprocessing, pelatihan model, serta evaluasi performa klasifikasi berdasarkan matrik akurasi dan confusion matrix.

3.1. Alur Penelitian

Penelitian ini terdiri dari enam tahap utama, dimulai dengan akuisisi citra rempah hingga evaluasi hasil klasifikasi berdasarkan tingkat akurasi model CNN. Alur penelitian ditunjukkan pada Gambar 2 berikut:



Gambar 2. Alur Penelitian

3.2. Akuisisi Citra Rempah

Citra rempah diambil menggunakan kamera smartphone Redmi Note 9 Pro dengan spesifikasi kamera 64 megapiksel. Gambar diambil pada jarak ± 10 cm dengan orientasi potret. Sumber citra diperoleh dari internet dan pasar tradisional. Sebanyak 1.075 gambar dikumpulkan, masing-masing terdiri dari 215 gambar per kelas (kunyit, jahe, kencur, cengkeh, serai).

Tabel 1. Rangkuman data citra rempah [13]

No	Kelas Rempah	Citra Rempah	Jumlah Citra
1	Cengkeh		215
2	Jahe		215
3	Kencur		215
4	Kunyit		215
5	Serai		215

3.3. Pelabelan Citra Rempah

Setelah citra diperoleh, langkah selanjutnya adalah pelabelan citra. Citra dikategorikan ke dalam

lima kelas: kunyit, jahe, kencur, cengkeh, dan serai. Proses pelabelan dilakukan secara manual dengan memastikan setiap gambar memiliki label sesuai dengan kategori rempah.

3.4. Resize

Resize dilakukan untuk menstandarisasi ukuran gambar input sehingga efisien untuk diolah oleh model CNN. Setiap gambar diubah ukurannya menjadi 110x110 piksel menggunakan perangkat lunak pengolahan gambar. Ukuran ini dipilih agar sesuai dengan arsitektur CNN yang digunakan, tanpa kehilangan detail visual penting pada citra rempah.

3.5. Dataset

Dataset dibuat dengan membagi data menjadi dua bagian: 80% untuk pelatihan dan 20% untuk pengujian.

3.6. Arsitektur DenseNet 121

Layers	Output Size	DenseNet-121
Convolution	112×112	
Pooling	56×56	
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	
	28×28	
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	
	14×14	
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$
Transition Layer (3)	14×14	
	7×7	
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$
Classification Layer	1×1	

Gambar 3. Desain Arsitektur DenseNet

Gambar tersebut menunjukkan arsitektur DenseNet-121, salah satu jaringan konvolusi (Convolutional Neural Network atau CNN) yang dirancang untuk tugas klasifikasi citra. Arsitektur ini terdiri dari beberapa komponen utama, yaitu Convolution Layer, Pooling Layer, Dense Blocks, Transition Layers, dan Classification Layer. Pada awalnya, lapisan konvolusi digunakan untuk mengekstraksi fitur awal dari citra masukan dengan ukuran keluaran 112×112 , diikuti oleh lapisan pooling untuk mengurangi dimensi data menjadi 56×56 . Selanjutnya, jaringan ini memiliki empat Dense Blocks yang saling terhubung melalui Transition Layers. Setiap Dense Block terdiri dari beberapa lapisan konvolusi kecil (1×1 dan 3×3), dengan jumlah lapisan berturut-turut sebanyak 6, 12, 24, dan 16.

Konektivitas di dalam Dense Blocks sangat padat karena setiap lapisan menerima input dari semua lapisan sebelumnya, memungkinkan propagasi informasi yang efisien dan meminimalkan redundansi. Transition Layers berfungsi untuk mereduksi dimensi data melalui operasi konvolusi dan pooling, menghasilkan ukuran keluaran bertahap dari 56×56 , 28×28 , 14×14 , hingga 7×7 . Pada bagian akhir, lapisan klasifikasi mengubah data menjadi prediksi kelas dengan ukuran keluaran 1×1 . Dengan desainnya yang efisien dalam penggunaan parameter dan kemampuannya menangkap fitur detail dari gambar, DenseNet-121 sering digunakan untuk tugas klasifikasi citra, seperti pengenalan jenis rempah-rempah.

Untuk lapisan akhir disesuaikan dengan menambahkan beberapa lapisan fully connected setelah fitur akhir dari DenseNet-121 diperoleh. Langkah pertama adalah menggunakan GlobalAveragePooling2D(), yang berfungsi untuk meratakan fitur dari output convolution menjadi vektor 1 dimensi. Kemudian, lapisan Dense(512, activation='relu') ditambahkan untuk menangkap pola-pola yang lebih kompleks dari fitur yang telah diratakan, diikuti oleh lapisan Dense(256, activation='relu') untuk mengekstrak informasi yang lebih spesifik. Akhirnya, lapisan Dense(num_classes, activation='softmax') digunakan untuk menghasilkan output berupa probabilitas untuk setiap kelas (dalam hal ini lima kelas: kunyit, jahe, kencur, cengkeh, serai), sehingga model dapat melakukan klasifikasi dengan tepat.

3.7. Membedakan Jenis Rempah

Setelah model CNN selesai dilatih, model diuji untuk membedakan citra rempah berdasarkan kelasnya. Hasil prediksi dibandingkan dengan label sebenarnya untuk mengevaluasi Akurasi, Precision, Recall, dan F1-score.

Akurasi, Precision, Recall, dan F1-score dihitung menggunakan confusion matrix dengan rumus berikut:

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

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{precision} + \text{Recall}} \quad (4)$$

Di mana:

TP: True Positive (prediksi benar untuk kelas tertentu)

TN: True Negative (prediksi benar untuk kelas lain)

FP: False Positive (prediksi salah untuk kelas tertentu)

FN: False Negative (prediksi salah untuk kelas lain)

Hasil penelitian diharapkan mampu memberikan akurasi tinggi dalam membedakan lima kelas rempah. Akurasi yang tinggi menunjukkan efektivitas model dalam mengenali dan mengklasifikasikan citra rempah secara akurat.

4. HASIL DAN PEMBAHASAN

Penelitian ini menguji performa model DenseNet-121 dalam klasifikasi lima jenis rempah Indonesia: kunyit, jahe, kencur, cengkeh, dan serai. Dataset berjumlah 1.075 gambar digunakan, dengan pembagian 80% untuk pelatihan dan 20% untuk pengujian. Model dilatih menggunakan satu jenis optimizer, yaitu Adam, dengan evaluasi didasarkan pada metrik akurasi, nilai loss, recall, dan Precision. Pengujian dilakukan selama 20 epoch dengan ukuran citra input 110x110 piksel. Parameter pengujian dirangkum dalam tabel berikut:

Tabel 2. Parameter Skenario Pengujian

No	Parameter	Nilai/Uraian
1	Jumlah Epoch	20
2	Optimizer	Adamax
3	Tingkat Pembelajaran Awal	0.001
4	Ukuran Citra Input	110x110x3 (RGB)
5	Jumlah Kelas Output	5
6	Batch Size	16
7	Metrik Evaluasi	Akurasi, Precision, Recall, F1-score

4.1. Proses Pelatihan Model CNN

Model CNN yang digunakan dalam penelitian ini adalah DenseNet-121, yang merupakan model arsitektur CNN yang dirancang untuk efisiensi dalam memproses citra. Proses pelatihan model ini melibatkan beberapa tahapan, yang dijelaskan secara rinci berikut ini:

4.1.1. Pra-pemrosesan Data

Proses klasifikasi dimulai dengan pra-pemrosesan dataset yang terdiri dari 1.075 gambar, masing-masing mewakili lima jenis rempah: kunyit, jahe, kencur, cengkeh, dan serai. Dataset dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Pada tahap ini, semua gambar diubah ukurannya menjadi 110x110 piksel dengan 3 saluran warna (RGB) untuk memastikan konsistensi ukuran input model. Augmentasi data diterapkan untuk memperluas variasi dataset, mencakup teknik seperti rotasi, flipping horizontal/vertikal, dan penyesuaian pencahayaan, yang bertujuan meningkatkan kemampuan generalisasi model. Selanjutnya, normalisasi dilakukan dengan mengubah nilai piksel ke rentang [0, 1] untuk mempercepat proses pelatihan dan konvergensi model.

4.1.2. Arsitektur Model DenseNet-121

Arsitektur DenseNet-121 dipilih karena efisiensi parameter dan kemampuannya untuk

memanfaatkan fitur dari lapisan terdalam dengan menghubungkan semua lapisan secara langsung melalui Dense Blocks. DenseNet-121 terdiri dari beberapa bagian utama:

- Convolutional Layers:** Untuk mengekstrak fitur dari citra.
- Dense Blocks:** Menyediakan koneksi langsung antar lapisan, yang meningkatkan transfer informasi dan mempermudah pembelajaran model.
- Pooling Layers:** Mengurangi dimensi citra sambil mempertahankan fitur penting.
- Fully Connected Layers:** Setelah melalui tahap ekstraksi fitur, model akhirnya mengklasifikasikan citra ke dalam salah satu kelas rempah berdasarkan informasi yang terkumpul dari lapisan-lapisan sebelumnya.

4.1.3. Pelatihan Model

Pelatihan model dilakukan menggunakan optimizer Adam dengan tingkat pembelajaran awal sebesar 0.001. Setiap iterasi pelatihan menggunakan batch size sebesar 16 gambar, dan proses pelatihan dilakukan selama 20 epoch untuk memastikan model mencapai konvergensi. Fungsi loss yang digunakan adalah kategori cross-entropy, yang bertujuan menghitung perbedaan antara prediksi model dan label sebenarnya. Proses ini dirancang untuk memaksimalkan kemampuan model dalam mengenali pola-pola visual dari dataset.

4.1.4. Evaluasi Kinerja Model

Kinerja model dievaluasi menggunakan berbagai metrik, seperti accuracy untuk mengukur persentase prediksi yang benar, precision untuk menilai akurasi prediksi positif, recall untuk mengukur seberapa baik model mendeteksi sampel positif, dan f1-score yang merupakan rata-rata harmonis antara precision dan recall. Selain itu, confusion matrix digunakan untuk memberikan gambaran rinci tentang kesalahan prediksi untuk setiap kelas. Evaluasi dilakukan pada data pelatihan dan validasi untuk memahami kekuatan dan kelemahan model.


4.1.5. Visualisasi Performa Model

Visualisasi performa model melibatkan grafik loss yang menunjukkan penurunan nilai loss selama pelatihan dan validasi, grafik accuracy yang mengilustrasikan peningkatan akurasi model, serta grafik precision dan recall untuk memantau kestabilan prediksi model. Grafik ini memberikan wawasan tentang bagaimana model belajar dari data dan mengidentifikasi potensi overfitting atau fluktuasi performa pada data validasi.

Proses ini dirancang untuk memastikan model CNN DenseNet-121 mampu mempelajari pola-pola visual dengan efektif untuk mengklasifikasikan jenis rempah, meskipun ada potensi overfitting ringan yang masih perlu ditangani lebih lanjut.

4.2. Hasil Pengujian Model CNN

Pengujian menggunakan optimizer Adam menunjukkan hasil terbaik dengan akurasi tertinggi, Grafik akurasi dan nilai loss setiap epoch untuk masing-masing optimizer disajikan pada Gambar 4:



Gambar 4. Grafik Evaluasi Model

Gambar 4 menunjukkan evaluasi performa model selama 20 epoch berdasarkan metrik losses, accuracy, precision, dan recall untuk data pelatihan dan validasi.

a. Grafik Losses

Pada grafik losses, nilai loss mengalami penurunan signifikan di awal pelatihan, terutama hingga epoch ke-5, yang menandakan model belajar dengan baik. Setelah itu, nilai loss pada data pelatihan stabil di bawah 0.5, sementara nilai val_loss menunjukkan fluktuasi, yang mengindikasikan potensi overfitting ringan di beberapa epoch akhir.

b. Grafik Accuracy

Grafik accuracy memperlihatkan tren peningkatan akurasi baik pada data pelatihan maupun validasi. Akurasi pelatihan meningkat pesat di awal dan mencapai stabilitas mendekati 0.8, sedangkan val_accuracy mengalami fluktuasi namun tetap berada di kisaran yang cukup baik. Hal ini menunjukkan bahwa model memiliki performa yang tinggi pada data pelatihan, tetapi masih mengalami variasi performa pada data validasi.

c. Grafik Precision

Pada grafik precision, nilai precision untuk data pelatihan naik dengan cepat dan mencapai stabilitas setelah epoch ke-5, sedangkan val_precision cenderung berfluktuasi. Pola ini menunjukkan bahwa model mampu memprediksi kelas positif dengan baik pada data pelatihan, meskipun performa pada data validasi masih belum sepenuhnya stabil.

d. Grafik Recall

Pada grafik recall, nilai recall juga meningkat pesat pada awal pelatihan dan mencapai stabilitas pada data pelatihan setelah beberapa epoch. Namun, val_recall menunjukkan fluktuasi yang cukup tajam, mengindikasikan bahwa performa model terhadap data validasi masih bervariasi.

Secara keseluruhan, model menunjukkan performa yang baik dalam mempelajari pola dari citra rempah, dengan peningkatan akurasi, precision, dan recall yang konsisten pada data pelatihan. Namun, fluktuasi pada metrik validasi seperti val_loss, val_accuracy, val_precision, dan val_recall menunjukkan bahwa model mengalami sedikit overfitting. Hal ini perlu dianalisis lebih lanjut untuk meningkatkan stabilitas performa model, misalnya dengan menambahkan regularisasi atau teknik augmentasi data.

4.3. Analisis Grafik Evaluasi Model CNN

Berdasarkan grafik yang disajikan, model CNN yang dilatih menggunakan optimizer Adam menunjukkan kinerja yang cukup baik. Model berhasil mencapai akurasi yang tinggi dan nilai loss yang rendah, mengindikasikan kemampuan model dalam mengklasifikasikan data dengan benar. Namun, adanya sedikit perbedaan antara kinerja pada data pelatihan dan validasi mengindikasikan potensi terjadinya overfitting. Fluktuasi pada metrik presisi dan recall mengindikasikan adanya ketidakseimbangan data atau kompleksitas masalah yang sedang dihadapi. Untuk meningkatkan kinerja model, disarankan untuk menerapkan teknik regularisasi, early stopping, atau augmentasi data. Selain itu, penyetelan hyperparameter seperti learning rate dan jumlah layer juga dapat membantu. Dengan melakukan analisis lebih lanjut pada matriks konfusi dan visualisasi fitur, kita dapat memperoleh pemahaman yang lebih mendalam mengenai kekuatan dan kelemahan model.

4.4. Adam

Grafik menunjukkan kurva akurasi model selama pelatihan dan pengujian untuk masing-masing optimizer.

Tabel 3. Hasil Pengujian

Kategori	Precision	Recall	F1-Score
Cengkeh	0.90	1.00	0.95
Jahe	0.83	1.00	0.91
Kencur	1.00	0.85	0.92
Kunyit	1.00	1.00	1.00
Serai	1.00	1.00	1.00
Accuracy			0.95
Macro avg	0.95	0.97	0.95

Tabel tersebut menyajikan hasil evaluasi kinerja model klasifikasi yang telah dilatih untuk membedakan antara cengkeh, jahe, kencur, kunyit, dan serai. Evaluasi dilakukan menggunakan metrik

precision, recall, f1-score, accuracy, dan rata-rata tertimbang.

Analisis hasil menunjukkan bahwa model yang dibangun memiliki kinerja yang baik dalam mengklasifikasikan jenis rempah. Berdasarkan metrik evaluasi, model menunjukkan nilai precision, recall, dan f1-score yang tinggi untuk sebagian besar kelas rempah.

Precision mengindikasikan proporsi prediksi positif yang benar dari semua prediksi positif, dengan nilai tinggi yang menunjukkan bahwa model jarang melakukan kesalahan dalam mengklasifikasikan sampel sebagai kelas positif.

Recall, yang mengukur proporsi sampel positif yang benar-benar diklasifikasikan sebagai positif, juga menunjukkan hasil yang baik, mengindikasikan bahwa model mampu mengenali sebagian besar sampel positif dengan akurat.

F1-score, yang merupakan nilai harmonik antara precision dan recall, memberikan gambaran keseluruhan yang baik tentang kinerja model.

Akurasi keseluruhan mencapai 95%, menunjukkan bahwa model mampu mengklasifikasikan 95% sampel dengan benar. Hasil yang diperoleh menunjukkan bahwa model dapat membedakan dengan jelas antara kelas-kelas rempah yang diuji, dengan beberapa kelas seperti cengkeh, kunyit, dan serai menunjukkan kinerja yang sangat baik. Namun, ada sedikit kesulitan dalam mengklasifikasikan cengkeh dan jahe, yang tercermin dalam nilai metrik yang lebih rendah untuk kedua kelas tersebut.

Berdasarkan tabel, dapat disimpulkan bahwa model yang dibangun memiliki kinerja yang cukup baik dalam mengklasifikasikan jenis rempah. Hal ini ditunjukkan oleh nilai accuracy keseluruhan yang mencapai 0.95, yang berarti model berhasil mengklasifikasikan 95% dari total sampel dengan benar.


Nilai precision, recall, dan f1-score untuk masing-masing kelas juga menunjukkan hasil yang baik. Ini mengindikasikan bahwa model mampu membedakan dengan cukup baik antara kelas-kelas rempah yang berbeda, terutama untuk kelas cengkeh, kunyit, dan serai yang memiliki nilai metrik yang tinggi.

4.5. Analisis Confusion Matrix

Confusion matrix menggambarkan performa model dalam mengklasifikasikan setiap jenis rempah. Optimizer Adam memberikan hasil terbaik dengan klasifikasi akurat untuk semua kelas rempah. Berikut adalah ringkasan hasil confusion matrix:

Confusion matrix adalah sebuah tabel yang menunjukkan kinerja model klasifikasi dengan membandingkan prediksi model dengan label aktual. Setiap sel dalam matriks mewakili jumlah sampel yang diklasifikasikan ke dalam kelas tertentu, baik secara benar maupun salah.

Berdasarkan confusion matrix yang ditampilkan, dapat disimpulkan bahwa model yang menggunakan optimizer Adam memiliki kinerja yang sangat baik dalam mengklasifikasikan jenis rempah.



Gambar 5. Tabel Confusion Matrix untuk Optimizer Adam

Pada confusion matrix, nilai-nilai pada diagonal utama menunjukkan jumlah sampel yang diklasifikasikan dengan benar oleh model. Semakin tinggi nilai pada diagonal utama, semakin baik kinerja model dalam mengklasifikasikan sampel dengan tepat. Pada matrix ini, nilai pada diagonal utama cukup tinggi untuk semua kelas rempah, yang menunjukkan bahwa model dapat mengklasifikasikan sebagian besar sampel dengan benar.

Di sisi lain, nilai-nilai di luar diagonal utama mencerminkan sampel yang salah diklasifikasikan. Nilai yang rendah pada sel-sel di luar diagonal utama menunjukkan bahwa model jarang melakukan kesalahan dalam mengklasifikasikan sampel ke kelas yang salah.

Selanjutnya, ketika melihat kinerja per kelas, model menunjukkan hasil yang sangat baik dalam mengklasifikasikan jenis rempah seperti cengkeh, kunyit, dan serai, yang memiliki angka prediksi yang sangat akurat. Namun, model sedikit mengalami kesulitan dalam mengklasifikasikan jahe dan kencur, yang tercermin dari adanya beberapa sampel jahe dan kencur yang salah diklasifikasikan ke kelas rempah lainnya. Hal ini mengindikasikan bahwa model masih perlu perbaikan lebih lanjut untuk menangani kelas-kelas rempah yang memiliki kesamaan visual lebih kuat.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian ini, model DenseNet-121 terbukti efektif dalam mengklasifikasikan lima jenis rempah Indonesia dengan akurasi tinggi sebesar 95%, serta precision dan

recall yang sangat baik, meskipun ada tantangan dalam membedakan jahe dan kencur. Keunggulan model terletak pada efisiensi parameter dan kemampuannya menangkap fitur visual penting, namun potensi overfitting yang terdeteksi menunjukkan perlunya teknik regularisasi dan augmentasi data untuk meningkatkan kestabilan. Penelitian ini membuka peluang untuk pengembangan aplikasi berbasis citra dalam industri rempah dan kecantikan, dengan saran untuk meningkatkan augmentasi data, tuning hyperparameter, dan memperbanyak variasi dataset guna meningkatkan performa model di kondisi dunia nyata. Penerapan teknologi ini di masa depan dapat mempercepat klasifikasi rempah, memberikan kontribusi besar pada industri kecantikan, dan mempermudah masyarakat dalam membedakan jenis rempah yang serupa.

DAFTAR PUSTAKA

- [1] Pratama, L. Z. (2023). Klasifikasi Citra Rempah-rempah dengan Menggunakan Algoritma Convolutional Neural Network (Cnn).
- [2] Puspita, Y. H., & Sabri, A. (2024). Perbandingan Arsitektur MobileNetV2 dan DenseNet121 untuk Klasifikasi. *Jurnal Ilmiah Komputasi*, 23(1), 67-74.
- [3] Rachmadinasya, S. A., Melvandino, F. H., & Ramza, H. (2023). KLASIFIKASI AKTIVITAS OLAHRAGA BERDASARKAN CITRA FOTO DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. *Jurnal Informatika dan Teknik Elektro Terapan*, 11(3s1).
- [4] Suandana, I. N., Asriyanik, A., & Apriandari, W. (2024). PEMANFAATAN CNN (CONVOLUTION NEURAL NETWORK) DAN MOBILENET V2 DALAM KLASIFIKASI REMPAH-REMPAH LOKAL DI INDONESIA. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(5), 10109-10116.
- [5] Jatmoko, C., & Sinaga, D. (2020). K-Nearest Neighbor Dan Ekstraksi Warna Mean RGB Untuk Identifikasi Kunyit Atau Temulawak. 564-570.
- [6] Kaharuddin, Kusri, & Luthfi, E. T. (2019). Klasifikasi Jenis Rempah-Rempah Berdasarkan Fitur Warna Rgb Dan Tekstur Menggunakan Algoritma K-Nearest Neighbor. *Jurnal Informatika Interaktif*, 4(1), 17-22.
- [7] Nursyahfitri, R., Maharadja, A. N., Farissa, R. A., & Umaidah, Y. (2021). Klasifikasi Penentuan Jenis Obat Menggunakan Algoritma Decision Tree. *Jurnal Informatika Polinema*, 7(3), 53-60.
- [8] Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *Jurnal ALGOR*, 2, 12-21.
- [9] Nashr, M. H., Fachrurrozi, M., Triningsih, E., & Miraswan, K. J. (2020). Pengenalan Motif Kain Songket Pada Citra Kamera Smartphone Dengan Beragam Sudut Pandang Menggunakan Cnn. *Jurnal Ilmu Komputer Dan Teknologi Informasi*, 22-26.
- [10] Septian, M. R. D., Paliwang, A. A. A., Cahyanti, M., & Swedia, E. R. (2020). Penyakit Tanaman Apel Dari Citra Daun Dengan Convolutional Neural Network. *Sebatik*, 24(2), 207-212.
- [11] Fatoni, H., Maulana, D. A., & Adam, R. I. (2024). DETEKSI DAN KLASIFIKASI KENDARAAN RINGAN DAN BERAT UNTUK JALAN TOL MENGGUNAKAN CNN. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(6), 11252-11259.
- [12] <https://www.semanticscholar.org/paper/Classification-of-Buried-Objects-Using-Deep-on-GPR-Sezgin-Alpdemir/3fe47e5e255cd04c51b6512ed82a5f7bb893c67d/figure/1>
- [13] <https://www.kaggle.com/datasets/albertnathaniel12/indonesian-spices-dataset>