



Identifikasi Citra Jenis Rempah-Rempah Menggunakan Arsitektur ResNet50

Christy Atika Sari*¹, Luthfiyana Hamidah Sherly Pradana², Eko Hari Rachmawanto³

^{1,2,3}Universitas Dian Nuswantoro, Semarang, Indonesia

E-mail : christy.atika.sari@dsn.dinus.ac.id*

*Penulis Korespondensi

Received 24 April 2025; Revised 17 May 2025; Accepted 13 June 2025

Abstrak - Indonesia memiliki berbagai jenis rempah yang digunakan dalam kuliner dan pengobatan tradisional. Namun, perubahan gaya hidup dan modernisasi menyebabkan generasi muda semakin kesulitan mengenali rempah secara langsung. Identifikasi konvensional masih mengandalkan pengamatan manual yang rentan terhadap kesalahan. Oleh karena itu, diperlukan solusi berbasis kecerdasan buatan untuk meningkatkan akurasi klasifikasi rempah-rempah. Penelitian ini menerapkan metode *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50, yang merupakan bagian dari Deep Learning, untuk mengklasifikasikan citra digital rempah-rempah. Model ini memanfaatkan Computer Vision untuk mengenali pola visual, Transfer learning untuk meningkatkan efisiensi pelatihan, serta teknik augmentasi data seperti rotasi, dan perubahan ukuran citra untuk meningkatkan ketahanan model. Evaluasi menggunakan Confusion Matrix dilakukan dengan berbagai skenario pembagian dataset, termasuk rasio 90:10, 80:20, 70:30, 60:40, dan 50:50. Hasil eksperimen menunjukkan bahwa model dengan rasio 90:10 memberikan akurasi terbaik, mencapai 98.04%, dengan precision, recall, dan F1-score yang tinggi. Kesimpulannya, metode CNN dengan ResNet50 terbukti efektif dalam mengidentifikasi rempah-rempah berbasis citra digital. Pengembangan lebih lanjut dapat dilakukan dengan menambah variasi dataset dan mengeksplorasi arsitektur Deep Learning lainnya guna meningkatkan performa model.

Kata Kunci: Augmentasi, Deep Learning, *Convolutional Neural Network*, ResNet50, Identifikasi Rempah

Abstract - Indonesia has various types of spices used in culinary and traditional medicine. However, changes in lifestyle and modernization have made it increasingly difficult for the younger generation to recognize spices directly. Conventional identification still relies on manual observation which is prone to errors. Therefore, an artificial intelligence-based solution is needed to improve the accuracy of spice classification. This study applies the *Convolutional Neural Network* (CNN) method with the ResNet50 architecture, which is part of Deep Learning, to classify digital images of spices. This model utilizes Computer Vision to recognize visual patterns, Transfer learning to improve training efficiency, and data augmentation techniques such as rotation, and image resizing to improve model robustness. Evaluation using Confusion Matrix was carried out with various dataset division scenarios, including ratios of 90:10, 80:20, 70:30, 60:40, and 50:50. The experimental results showed that the model with a ratio of 90:10 provided the best accuracy, reaching 98.04%, with high precision, recall, and F1-score. In conclusion, the CNN method with ResNet50 has proven effective in identifying spices based on digital images. Further development can be done by adding variations of datasets and exploring other Deep Learning architectures to improve model performance.

Keywords: Augmentation, Deep Learning, *Convolutional Neural Network*, ResNet50, Spice Identification



1. PENDAHULUAN

Rempah–rempah atau bumbu dapur telah lama dikenal sebagai salah satu bahan dasar penting dalam pembuatan masakan modern maupun tradisional. Rempah-rempah dapat dicirikan oleh aroma, bentuk, dan kualitasnya yang berbeda. Di Indonesia, rempah-rempah digunakan secara luas untuk meningkatkan cita rasa masakan lokal dan memberikan ciri khas pada setiap masakan agar masakan tersebut memiliki cita rasa yang kuat. Selain di bidang kuliner, rempah-rempahan seperti kencur dan jahe dapat di jadikan untuk bahan utama dalam pembuatan obat herbal (Agustina.N & Hermawan.S, 2023). Akan tetapi, perkembangan industri modern dan kecenderungan generasi muda yang lebih memilih makanan cepat saji menyebabkan pemanfaatan rempah-rempah secara langsung semakin menurun dan menjadikan mereka sulit untuk mengenali rempah-rempah secara langsung (Nisa & Candra, 2023). Hal ini didukung dengan adanya penelitian yang dilakukan pada sekelompok orang yang berasal dari Generasi Z. Penelitian ini menunjukkan bahwa dari 32 bumbu yang disediakan 56,25% responden hanya mampu mengidentifikasi 1–16 bumbu saja (Kholifah dkk, 2023). Sebaliknya, kemajuan teknologi yang semakin cepat dapat memberikan solusi untuk masalah tersebut. Teknologi *Computer Vision* adalah salah satu solusi yang dapat digunakan.

Computer Vision merupakan bidang yang mempelajari bagaimana komputer dapat mengenali objek dalam data visual (Simarmata dkk., 2024). *Computer Vision* adalah bidang ilmu komputer yang berkaitan dengan pemrosesan gambar. *Computer Vision* berkonsentrasi pada proses transformasi citra yang digunakan untuk mengekstrak pesan atau informasi yang dikirim. Tidak hanya menganalisis citra, *Computer Vision* dapat menghasilkan citra baru dengan kualitas yang lebih baik dibandingkan dengan citra aslinya (Setiawan dkk., 2021). Teknologi ini berkembang pesat, Berkat kemajuan teknologi dan teknik pengolahan gambar berbasis kecerdasan buatan seperti *Machine Learning* dan *Deep Learning*, mata pelajaran ini berkembang dengan cepat (Syafar & Darmatasia, 2023). Dalam menggunakan *Computer Vision*, terdapat beberapa pendekatan yang dapat digunakan untuk menyelesaikan permasalahan di atas. Salah satu dari pendekatan tersebut yaitu dengan menggunakan algoritma CNN.

Convolutional Neural Network merupakan algoritma pembelajaran mendalam pada jaringan saraf tiruan yang dapat digunakan untuk mengidentifikasi foto dan video maupun mendeteksi objek yang ada pada foto (Tilasefana & Putra, 2023). Algoritma ini adalah algoritma yang efisien untuk mengklasifikasikan dan mengidentifikasi objek berdasarkan variasi visual. Selain itu, algoritma CNN juga merupakan algoritma yang sering digunakan karena kemampuannya dalam memberikan identifikasi yang akurat dan otomatis (Abou Baker et al., 2022). Algoritma CNN bekerja dengan cara menangkap data visual menggunakan beberapa kisi konvolusional yang berfungsi untuk menyorot fitur-fitur penting dari gambar yang ditampilkan (Baker dkk., 2022). Selain itu, CNN memiliki kemampuan generalisasi yang tinggi sehingga CNN dapat digunakan untuk mengidentifikasi data yang belum pernah dilihat sebelumnya, Algoritma ini juga dilengkapi dengan lapisan *Pooling* yang berfungsi untuk mengurangi input sehingga dapat memproses informasi lebih cepat tanpa menghilangkan informasi penting dari cira digital (Tilasefana & Putra, 2023). Algoritma CNN dibangun berdasarkan pola visual yang sudah ada sebelumnya untuk mengekstrak informasi yang semakin spesifik dari setiap lapisan jaringan, CNN mampu mengidentifikasi perbedaan benda-benda seperti jahe, kunyit, dan temulawak yang secara visual terlihat mencolok.

Seperti penelitian yang telah dilakukan sebelumnya oleh Isna Wulandari dkk (2020) melakukan klasifikasi bumbu dan rempah dengan menggunakan 300 citra yang dibagi menjadi 3 kategori, tujuan dari penelitiannya adalah untuk mengetahui hasil akurasi dengan menggunakan hyperparameter yang dipilih pada penelitiannya, selanjutnya digunakan model CNN untuk pengenalan secara visual citra digital bumbu dan rempah serta untuk mengetahui



tingkat akurasi dari hasil klasifikasi (Wulandari, dkk 2020) Pada Penelitian Mellynia dkk Melakukan Identifikasi rempah-rempah menggunakan dataset gambar sebanyak 2700 citra dan 18 jenis rempah menggunakan metode CNN dan tensorflow untuk proses training dan testing data (Sanjaya & Nurraharjo 2023). Penelitian selanjutnya juga dilakukan oleh Chairun Nisa dkk(2024) melakukan identifikasi rempah dengan menggunakan dataset 250 citra yang dibagi menjadi 4 kelas. Tujuan penelitian ini untuk memberi solusi pengenalan rempah modern yang mudah di akses menggunakan Arsitektur jaringan CNN menggunakan empat lapisan konvolusi yang digunakan pada model (Nisa & Candra, 2023) Akan tetapi, pada tiga penelitian tersebut belum menggunakan arsitektur transfer learning. Transfer learning merupakan salah satu metode yang dimiliki CNN. Pada transfer learning, arsitektur CNN yang digunakan tidak memerlukan pembelajaran awal karena telah melakukan pembelajaran terhadap data-data lain sehingga tidak diperlukan pembelajaran dari awal (Nada Nafisa dkk, 2023).

Berdasarkan uraian yang telah ditulis, CNN menjadi pilihan utama dalam penelitian ini. Penelitian ini akan fokus pada penerapan Convolution Neural Network (CNN) dengan arsitektur ResNet50 untuk mengklasifikasi dan mengidentifikasi rempah-rempah yang performanya akan diuji menggunakan confusion matrix Tujuan utama dari penelitian ini adalah untuk mengembangkan sistem klasifikasi serta menguji tingkat performa menggunakan Confusion Matrix yang diperoleh dari hasil pelatihan yang diharapkan hasil evaluasi berbasis Confusion Matrix ini akan menunjukkan nilai yang lebih unggul

2. METODE PENELITIAN

2.1. Penelitian Terkait

Pada beberapa penelitian sebelumnya, hasil yang didapatkan merupakan gambaran penting peneliti untuk dijalankan nantinya, maka dari itu peneliti harus memiliki dasar atau pegangan yang kuat. Berikut merupakan hasil penelitian yang digunakan peneliti sebagai acuan dalam melakukan penelitian sesuai Tabel 1.

Tabel 1. Penelitian Terkait

Nama Peneliti	Masalah	Metode	Hasil
(Wulandari, dkk 2020)	Klasifikasi citra digital bumbu dan rempah dengan algoritma CNN	CNN	Uji dengan model 2 <i>Convolutional Layer</i> menghasilkan nilai akurasi 0,85 dan los 0,4773. Selanjutnya, uji data baru menghasilkan akurasi 88,89%.
(Sanjaya & Nurraharjo 2023)	Deteksi jenis rempah-rempah menggunakan metode CNN secara real time	CNN	Untuk proses pelatihan dan pengujian data, modul tensorflow digunakan. Hasilnya menunjukkan nilai keakuratan mengenali rempah-rempah sebesar 60%.
(Boimau & Kaesmetan, 2024).	Klasifikasi Citra Digital Bumbu dan Rempah-Rempah dengan Algoritma CNN	CNN	Pada eksplorasi 300 gambar bumbu dan rasa di klasifikasikan menjadi 3 seperti gingseng, jahe dan lengkuas, hasil klasifikasi didapatkan hasil 88,89%.
(Maulana dkk., 2024)	Identifikasi jenis rempah-rempah Indonesia menggunakan metode CNN dengan Arsitektur VGG16	CNN	Hasil penelitian menunjukkan bahwa model CNN yang dikembangkan dalam penelitian ini, yang menggunakan arsitektur VGG16, berhasil mengklasifikasikan gambar rempah dengan akurasi tertinggi sebesar 86,66%.

Tabel 1 memuat beberapa penelitian yang menggunakan metode *Convolutional Neural Network* (CNN) untuk mendeteksi dan mengklasifikasikan rempah-rempah serta tanaman obat. Penelitian pertama oleh Wulandari (2020) fokus pada klasifikasi citra digital bumbu dan rempah



menggunakan CNN. Mereka menguji model dengan dua lapisan *Convolutional* dan mencapai akurasi sebesar 85% dengan nilai kerugian (loss) 0,4773. Ketika model ini diuji dengan data baru, akurasi meningkat menjadi 88,89%. Hasil ini menunjukkan bahwa CNN cukup efektif untuk mengklasifikasikan rempah-rempah dalam penelitian ini. Penelitian kedua dilakukan oleh Sanjaya dan Nurraharjo (2021) yang menggunakan CNN untuk deteksi jenis rempah secara real-time. Mereka memanfaatkan modul TensorFlow untuk melatih dan menguji data. Namun, hasil yang diperoleh menunjukkan akurasi sebesar 60%, yang relatif lebih rendah dibandingkan penelitian lainnya. Meskipun demikian, penelitian ini menunjukkan potensi penggunaan CNN dalam deteksi real-time meskipun membutuhkan perbaikan pada akurasi. Boimau dan Kaesmetan (2021) juga melakukan penelitian serupa dengan mengklasifikasikan 300 gambar bumbu, seperti ginseng, jahe, dan lengkuas. Gambar-gambar ini dibagi dalam dua bagian, yaitu untuk pelatihan dan pengujian, dengan proporsi 80:20. Hasil pengujian menghasilkan akurasi 85% dengan kerugian 0,47. Dari tiga gambar per klasifikasi, hasil keseluruhan mencapai 88,89%, yang menunjukkan performa baik dari model CNN yang digunakan. Terakhir, penelitian oleh Raihan dkk. (2024) berfokus pada identifikasi jenis rempah-rempah Indonesia menggunakan metode CNN dengan Arsitektur VGG16. Hasil penelitian ini menunjukkan akurasi sebesar 86,66% membuktikan efektivitas metode ini dalam mengenali berbagai jenis rempah dengan cukup baik.

Berdasarkan keempat penelitian diatas, penelitiannya hanya menggunakan metode clasic CNN yang mampu mengklasifikasikan jenis rempah dengan akurasi yang bervariasi. Untuk meningkatkan kualitas hasil yang ingin dicapai dibandingkan keempat penelitian diatas, penelitian ini akan mengoptimalkan model CNN menggunakan Resnet50 guna memperoleh ukuran kinerja yang lebih komprehensif, yang mencakup nilai presisi, recall, F1-score, dan akurasi total, penelitian ini akan difokuskan pada evaluasi menggunakan confusion matrix Diharapkan bahwa hasil evaluasi berbasis Confusion Matrix ini akan menunjukkan nilai yang lebih unggul dibandingkan empat penelitian sebelumnya, melalui penyetelan model yang lebih cermat serta pemilihan parameter yang optimal.

2.2. Convolutional Neural Network (CNN)

CNN salah satu algoritma yang mampu mengidentifikasi foto, video maupun mendeteksi objek yang ada pada foto dengan memanfaatkan dataset gambar yang sudah di kumpulkan (Tilasefana & Putra, 2023). Salah satu teknologi *Deep Learning* yang membantu proses klasifikasi adalah *Convolutional Neural Network* (CNN), *Convolution Neural Network* (CNN) sejenis perhitungan pembelajaran terarah dan penandaan informasi pada tahap preprocessing melakukan penamaan pada setiap gambar untuk persiapan dan informasi ujian (Boimau & Kaesmetan, 2024). *Convolutional Neural Network* (CNN) terinspirasi dari structure visual yang terdiri dari sel-sel yang merespons spesifik wilayah retina yang terlokalisasi menggunakan inputan gambar yang diproses serangkaian lapisan konvolusional stau fitur dua fungsi, CNN mampu mengolah gambar dan pengolahan data yang tidak terstruktur (Syafar & Darmatasia, 2023). Algoritma *Convolution Neural Network* (CNN) digunakan untuk mengidentifikasi jenis rempah rimpang *Convolutional* citra yang diambil sendiri menggunakan lensa kamera. Proses pengenalan citra dilakukan dengan mengevaluasi bentuk model dengan data yang diolah agar mendapatkan akurasi terbaik. Cara kerja dari *Convolutional Neural Network* (CNN) dengan memodifikasi perhitungan matematika lalu memvisualisasikan gambar untuk mengenali objek.

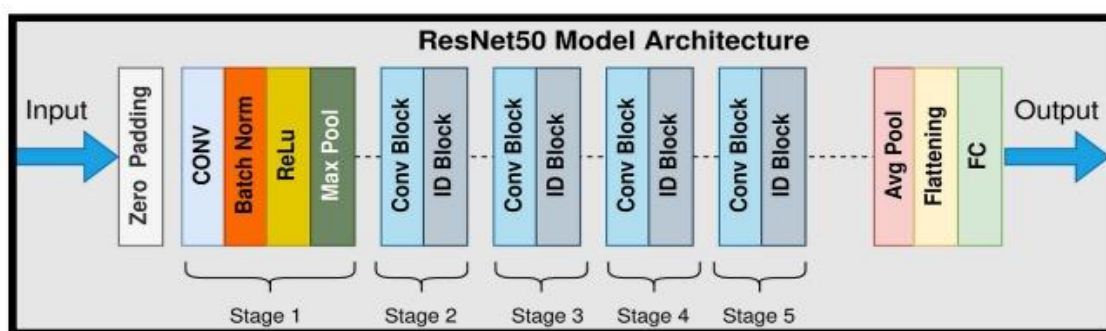
1. Lapisan Konvolusi (*convulational layer*). Lapisan ini bertanggung jawab untuk mengeluarkan fitur gambar dasar seperti tepi, sudut, dan tekstur filter yang dilatih.
2. Lapisan Aktivasi (*Action Layer*). Digunakan untuk menambahkan non-linearitas ke dalam model agar jaringan belajar representasi yang lebih kompleks.
3. Lapisan Pooling. Mengurangi dimensi dari fitur-fitur yang telah diekstraksi untuk mengurangi jumlah parameter dan komputasi dalam jaringan.



4. Lapisan *Fully Connected*. Lapisan yang menghubungkan semua neuron sebelumnya dan neuron di lapisan ini untuk melakukan klasifikasi berdasarkan karakteristik yang di ekstrasi.
5. Lapisan output. Lapisan terakhir yang menggunakan fungsi Softmax untuk menghasilkan probabilitas kelas untuk setiap jenis rempah-rempah.

2.3 ResNet50

ResNet50 merupakan salah satu varian dari *Residual Networks (ResNet)*, sebuah arsitektur jaringan saraf dalam yang dikembangkan oleh Microsoft Research pada tahun 2015 untuk mengatasi masalah vanishing gradient pada *Convolutional Neural Networks (CNN)* (Reddy & Juliet, 2019). Masalah ini sering terjadi pada jaringan tradisional (plain network) saat kedalaman meningkat, yang mengakibatkan hilangnya gradien selama backpropagation dan membuat pelatihan menjadi sulit. ResNet memecahkan masalah ini dengan memperkenalkan residual learning, di mana lapisan mempelajari perubahan kecil melalui shortcut connections yang melewati beberapa lapisan konvolusi (Al-Ghiffary dkk, 2023; Li dkk, 2022).



Gambar 1. Arsitektur ResNet50

Berdasarkan Gambar 1, arsitektur model ResNet50 terdiri dari beberapa tahap utama yang dirancang untuk melakukan ekstraksi fitur dan klasifikasi pada data citra (Susanto dkk, 2024). Dimulai dengan Zero Padding yang menambahkan lapisan padding agar dimensi citra tetap terjaga selama konvolusi. Kemudian, citra diproses melalui lapisan Convolution (CONV) yang berfungsi mengekstrak fitur dasar seperti tepi dan tekstur (Reddy & Juliet, 2019). Lapisan *Batch Normalization (Batch Norm)* digunakan untuk menstabilkan dan mempercepat proses pembelajaran dengan menormalkan output dari lapisan konvolusi (Cahyo dkk, 2023). Setelah itu, lapisan ReLU (Rectified Linear Activation Unit) diaplikasikan untuk mengatasi masalah non-linearitas, diikuti oleh Max Pooling (Max Pool) yang bertugas mengurangi dimensi spasial citra dan mempertahankan fitur penting. Arsitektur ini kemudian masuk ke Stage 2 hingga Stage 5, yang masing-masing terdiri dari blok residual seperti Conv Block dan Identity Block (ID Block) (Cahyo dkk, 2023). Blok residual ini memungkinkan adanya shortcut connections, yang membantu mengatasi masalah vanishing gradient dan memungkinkan jaringan belajar lebih dalam tanpa kehilangan informasi penting. Di akhir jaringan, terdapat Average Pooling (Avg Pool) yang merata-ratakan fitur dari seluruh citra, *Flattening* yang mengubah fitur yang diproses ke dalam bentuk vektor 1D, dan *Fully Connected Layer (FC)* untuk melakukan klasifikasi akhir (Cahyo & Al-Ghiffary, 2024). Output dari arsitektur ResNet50 ini adalah prediksi kelas dari citra input, di mana fitur-fitur kompleks dari setiap tahap sebelumnya digunakan untuk mengidentifikasi dengan akurasi yang lebih baik. Dalam ResNet, fungsi yang diinginkan, atau underlying mapping, dilambangkan sebagai $H(x)$, yang biasanya ditransformasikan langsung oleh beberapa lapisan nonlinier. Namun, dalam residual learning, jaringan ini tidak mempelajari $H(x)$ secara langsung, melainkan mempelajari residualnya, yaitu $F(x) := H(x) - x$. Secara formal, fungsi yang dihasilkan adalah $F(x) + x$, di mana shortcut connection membawa informasi dari



input tanpa modifikasi, dan hasilnya ditambahkan ke output dari lapisan yang ditransformasikan (Nugraha dkk, 2023).

2.5 Rempah-rempah

Rimpang adalah jenis akar modifikasi pada tumbuhan yang tumbuh secara horizontal di bawah permukaan tanah. Rimpang memiliki fungsi sebagai tempat penyimpanan cadangan makanan dan juga sebagai alat perbanyak vegetatif. Pada beberapa tumbuhan, rimpang juga berperan dalam proses perkembangbiakan karena dapat tumbuh tunas baru yang menjadi tanaman baru, rimpang sangat penting bagi tumbuhan yang hidup di tempat dengan kondisi lingkungan yang tidak stabil atau di tanah yang kurang subur karena ia menyimpan cadangan energi untuk bertahan hidup. Rimpang biasanya memiliki bentuk yang tebal dan berwarna lebih gelap dibandingkan akar biasa, dan sering kali ditemukan pada tumbuhan seperti jahe, kunyit, lengkuas, dan kencur. Berdasarkan sampel dataset pada Gambar 2, dibawah ini merupakan penjelasan dari sampel dataset setiap kelas dan alasan pemilihan rempah dari sisi ekonomi, kesamaan bentuk dan ukuran secara visual.



Gambar 2. Sample rempah-rempah

2.4 Pengujian hasil berbasis Confusion Matrix

Confusion Matrix adalah metode yang digunakan untuk mengevaluasi dan membandingkan hasil klasifikasi dengan nilai yang sebenarnya (Fathoni dkk., 2024). Dalam menunjukkan jumlah prediksi benar dan salah, metode ini dapat mengukur kinerja klasifikasi dengan cara membandingkan hasil klasifikasi yang sebenarnya dengan hasil klasifikasi yang diprediksi oleh sistem. Akurasi, Akurasi merupakan nilai yang mempresentasikan banyak data dapat mengklasifikasi sesuai data actual atau benar (Fabian Azmi & Voutama, 2024), sesuai dengan (1). Presisi, Presisi digunakan untuk mengukur seberapa banyak dari prediksi positif yang benar-benar positif (Fabian Azmi & Voutama, 2024), sesuai dengan (2). Recall, Recall digunakan untuk mengukur seberapa banyak data dari seluruh kasus positif yang berhasil diprediksi dengan benar (Fabian Azmi & Voutama, 2024). Hal ini penting digunakan unntuk mengetahui seberapa baik model mendeteksi kelas positif, sesuai dengan persmaan (3). F1 Score, F1 Score merupakan gabungan dari presisi dan recall yang digunakan untuk memberikan bobot yang sama pada



keduanya. Hal ini berguna pada saat muncul ketidakseimbangan kelas dalam dataset (Fabian Azmi & Voutama, 2024), sesuai (4).

$$Akurasi = \frac{TP+TN}{Total\ data} \quad (1)$$

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


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

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

Confusion matrix menggunakan tabel perhitungan yang dihasilkan oleh model dalam setiap kelasnya. Terdapat empat istilah untuk mempresentasikan hasil klasifikasi tersebut, yaitu:

1. True Positive (TP): model memprediksi kelas positif dan benar.
2. True Negative (TN): model memprediksi kelas negative dan benar.
3. False Positive (FP): model memprediksi kelas positif tetapi salah.
4. False Negative (FN): model memprediksi kelas negatif tetapi salah.

Untuk penjelasan bagian confusion matrix sesuai pada Gambar 3, dari kiri ke kanan pada baris pertama terdapat True Positive (TP) dan False Positive (FP). True Positive adalah hasil prediksi yang benar, di mana data yang diprediksi sebagai positif memang benar-benar positif. Sebaliknya, False Positive adalah hasil prediksi yang salah, di mana data yang sebenarnya negatif diprediksi oleh model sebagai positif. Kemudian, pada baris kedua dari kiri ke kanan terdapat False Negative (FN) dan True Negative (TN). False Negative adalah hasil prediksi yang salah, di mana data yang sebenarnya positif diprediksi sebagai negatif. Sedangkan True Negative adalah hasil prediksi yang benar, di mana data yang diprediksi sebagai negatif memang benar-benar negatif.



Gambar 3. Confusion Matrix

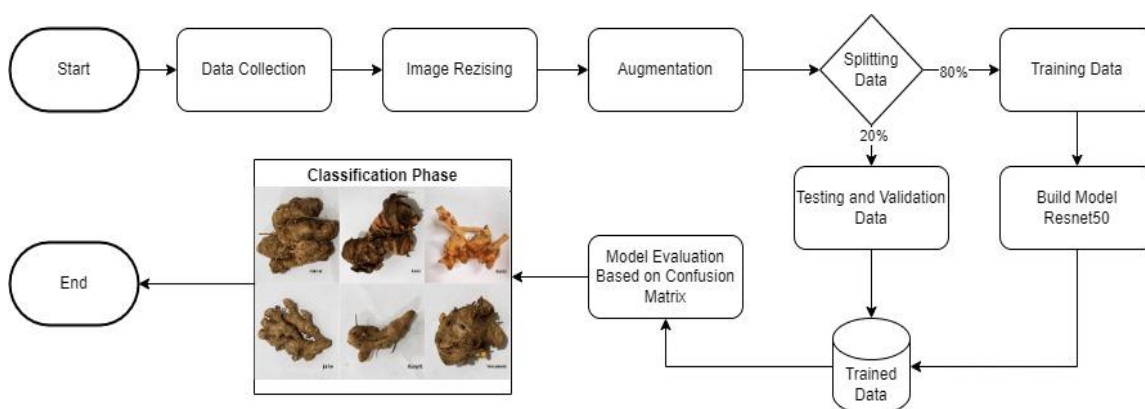
2.5 Usulan Metode

Berdasarkan Gambar 4, langkah-langkah utama dalam penelitian menggunakan CNN ResNet60 untuk deteksi rempah-rempah dapat dijelaskan sebagai berikut:

1. Pengumpulan Data (Data Collection). Proses dimulai dengan mengumpulkan gambar-gambar rempah yang akan digunakan sebagai dataset. Data ini kemudian dipersiapkan untuk proses pelatihan model CNN.



2. Pengubahan Ukuran Gambar (Image Resizing). Setelah data dikumpulkan, mengubah ukuran gambar agar seragam dan sesuai dengan ukuran input yang dibutuhkan oleh CNN. Hal ini bertujuan untuk memastikan konsistensi gambar yang akan dimasukkan ke dalam model.
3. Augmentasi Data (Augmentation). Augmentasi dilakukan untuk meningkatkan variasi dataset tanpa menambah data asli. Teknik ini seperti rotasi, flipping, pada gambar rempah-rempah untuk memperkaya variasi data pelatihan, yang bertujuan untuk meningkatkan ketahanan dan akurasi model.
4. Pembagian Data (Splitting Data). Dataset dibagi menjadi dua bagian, yaitu 80% untuk data pelatihan dan 20% untuk data validasi dan pengujian. Langkah ini penting untuk memastikan bahwa model tidak hanya mempelajari pola dari data pelatihan, tetapi juga diuji pada data baru yang belum pernah dilihat sebelumnya.
5. Pembangunan Model (Build Model ResNet-50). Model yang dibangun adalah arsitektur ResNet-50, yang memiliki kemampuan mendalam dalam mempelajari fitur-fitur kompleks dari gambar, seperti tekstur, bentuk, dan warna rempah-rempah untuk mengidentifikasi.
6. Proses Pelatihan (Training). Data yang sudah diproses melalui Augmentasi dan pembagian, digunakan untuk melatih model ResNet-50. Model belajar mengenali berbagai jenis rempah-rempah melalui lapisan konvolusi dan Pooling untuk mengekstraksi fitur-fitur yang relevan.
7. Klasifikasi Objek (Classification Phase). Setelah model dilatih, model ini digunakan untuk mengklasifikasikan gambar-gambar rempah berdasarkan kategori yang telah ditetapkan, seperti gambar-gambar rempah yang ditunjukkan pada gambar jahe, kunyit, kencur, temu kunci, temulawak, dan laos.
8. Evaluasi Model (Model Evaluation Based on Confusion Matrix). Model yang telah dilatih akan dievaluasi menggunakan Confusion Matrix untuk menghitung akurasi, precision, recall, dan F1-score. Evaluasi ini bertujuan untuk memberikan gambaran yang confusion matrix tentang kinerja model dalam mengklasifikasikan gambar-gambar rempah dengan benar.
9. Hasil Akhir. Hasil akhir adalah tingkat akurasi model dalam mendeteksi gambar rempah-rempah. Akurasi dihitung sebagai jumlah prediksi yang benar dibagi dengan total data uji, kemudian dikali 100% untuk mendapatkan persentase akurasi. Selain akurasi, metrik evaluasi lain seperti precision, recall, dan F1-score juga akan digunakan untuk mengukur performa keseluruhan model. Langkah-langkah ini memastikan bahwa model CNN yang digunakan dapat mendeteksi gambar rempah-rempah dengan akurasi tinggi, serta memberikan evaluasi yang confusion matrix melalui confusion matrix.



Gambar 4. Usulan metode



3. HASIL DAN PEMBAHASAN

Parameter dan hyperparameter yang digunakan peneliti dalam pelatihan model CNN ResNet50 sesuai Tabel 2. Hyperparameter adalah nilai yang ditentukan sebelum pelatihan dimulai yang sangat berpengaruh terhadap hasil model akhir. Optimizer (adam) merupakan parameter pertama yang dipilih karena efisiensinya dalam memproses pembelajaran model dengan cepat karena menyesuaikan Learning Rate secara adaptif dibandingkan metode optimasi lainnya dan lebih cocok untuk arsitektur seperti ResNet50. Selanjutnya adalah Execution Environment yang menggunakan GPU sebagai perangkat untuk melakukan eksekusi pada penelitian ini. GPU dipilih karena memiliki kemampuan komputasi paralel, terutama untuk pemrosesan model CNN ResNet50 yang membutuhkan perhitungan intensif, dengan GPU proses pelatihan lebih cepat dari CPU terutama ketika mengolah data dengan jumlah banyak seperti model CNN ResNet50.

Tabel 2. Hyperparameter

<i>Hyperparameter</i>	<i>Value</i>
Optimizer	Adam
Execution Environment	GPU
Max Epochs	40
Mini Batch Size	32
Validation Frequency	30 Iterasi
Verbose	False

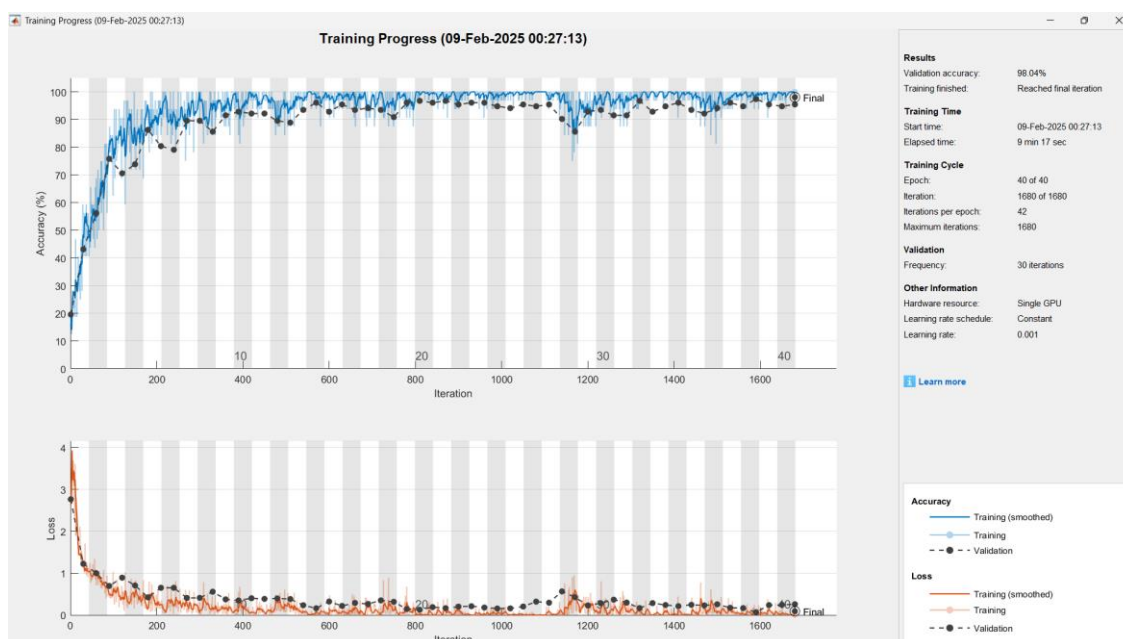
Parameter lain yang digunakan adalah Max Epochs, yang ditetapkan sebanyak 40. Epoch adalah jumlah siklus pelatihan pada seluruh dataset, menggunakan 40 Epoch cukup untuk menemukan pola dalam data tanpa mengalami risiko overfitting. Angka ini digunakan karena pengujian awal menunjukkan bahwa periode yang lebih lama dari 40 tidak meningkatkan akurasi secara signifikan. Selanjutnya ukuran Mini Batch, yang ditetapkan ke 32. Ukuran batch ini dipilih untuk menyeimbangkan kecepatan pelatihan dan penggunaan memori. Tanpa membebani memori GPU yang tersedia, batch kecil seperti 32 memungkinkan model untuk memperbarui parameter lebih sering, sehingga meningkatkan efisiensi pembelajaran model. Parameter terakhir adalah Frekuensi Validasi dan Data Validasi. Sekitar 20% data digunakan untuk validasi, artinya data tersebut tidak digunakan dalam penelitian melainkan untuk menilai kinerja model secara lebih menyeluruh. Setiap 30 iterasi, validasi dilakukan untuk memastikan bahwa model tidak hanya dapat belajar dari data yang dikumpulkan tetapi juga secara akurat memprediksi data yang belum diperiksa. Diharapkan model ini akan menghasilkan hasil yang akurat dan dapat diamati.

Proses Augmentasi yang diterapkan pada dataset klasifikasi rempah bertujuan untuk memperkaya variasi untuk meningkatkan kemampuan model dalam mengenali pola pada gambar rempah. Augmentasi dilakukan dengan menggunakan teknik rotasi acak pada gambar yang terdapat dalam dataset. Setiap gambar diputar dengan rentang sudut antara -20 hingga 20 derajat, sehingga menciptakan proses variasi dalam posisi objek yang akan dilihat oleh model. Proses Augmentasi ini menghasilkan gambar-gambar baru yang memiliki orientasi berbeda dari gambar aslinya dan mengurangi kemungkinan overfitting yang sering terjadi ketika model hanya dilatih menggunakan data yang terbatas sesuai Tabel 3.



Tabel 3. Hasil Augmentasi

	Nama Rempah					
	Jahe	Kencur	Kunyit	Laos	Temu kunci	Temulawak
Kondisi Sebelum Augmentasi						
Kondisi Sesudah Augmentasi						



Gambar 6. Training Progress proporsi 90 : 10%

Berdasarkan Gambar 6 menggunakan proporsi 90:10, di mana 90% dari total data dialokasikan untuk proses pelatihan dan 10% untuk validasi. Pemilihan data testing sebanyak 10% secara random akan memberikan hasil testing lebih valid. Pembagian ini dirancang untuk memberikan kesempatan bagi model untuk belajar dari sebagian besar data yang tersedia, sambil tetap mempertahankan cukup data untuk menguji kemampuan model dalam melakukan generalisasi. Dengan pendekatan ini, diharapkan model dapat mengurangi risiko overfitting dan menunjukkan performa yang baik ketika dihadapkan pada data yang belum pernah dilihat sebelumnya. Setelah menyelesaikan proses pelatihan, model berhasil mencapai akurasi validasi sebesar 98.04% dalam waktu total 9 menit 17 detik. Grafik akurasi menunjukkan tren peningkatan yang konsisten, dengan akurasi pelatihan mendekati 100% dan akurasi validasi yang tetap tinggi meskipun terdapat fluktuasi kecil. Selain itu, grafik loss menunjukkan penurunan yang stabil, yang mengindikasikan bahwa model telah belajar dengan baik dari data yang diberikan. Dengan total 40 epoch dan 1680 iterasi, serta menggunakan sumber daya single



GPU dengan Learning Rate sebesar 0.001, hasil ini mencerminkan efektivitas pelatihan model dan kesiapan untuk diterapkan pada data baru.

Tabel 4. Perbandingan Performa Model

Proporsi Data	Learning Rate	Loss Validasi	Waktu pelatihan	Jumlah Iterasi	Training Execution
90:10	0,001	~0,09	9 Menit 17 Detik	1680	Single GPU
80 : 20	0.001	~0.05	8 menit 22 detik	1520	Single GPU
70 : 30	0.001	~0.10	7 menit 30 detik	1320	Single GPU
60 : 40	0.001	~0.15	6 menit 30 detik	1120	Single GPU
50 : 50	0.001	~0.20	5 menit 33 detik	920	Single GPU

Berdasarkan Tabel 4, perbandingan performa model di atas, dapat disimpulkan bahwa proporsi data pelatihan dan validasi memberikan pengaruh signifikan terhadap waktu pelatihan, jumlah iterasi, dan nilai loss validasi. Semakin besar proporsi data latih, nilai loss validasi cenderung semakin kecil, dan akurasi validasi semakin tinggi. Sebagai contoh, pada proporsi 90:10, loss validasi tercatat sekitar 0,09, menunjukkan kemampuan model yang sangat baik dalam memprediksi data validasi. Selain itu, waktu pelatihan dan jumlah iterasi juga dipengaruhi oleh proporsi data. Pada proporsi 90:10, waktu pelatihan tercatat selama 9 menit 17 detik dengan jumlah iterasi 1680. Sebaliknya, pada proporsi 50:50, waktu pelatihan lebih singkat, yaitu 5 menit 33 detik dengan jumlah iterasi 920. Hal ini menunjukkan bahwa penggunaan lebih banyak data pelatihan cenderung memperpanjang waktu pelatihan, tetapi menghasilkan model yang lebih akurat. Model yang diuji menggunakan Learning Rate konstan sebesar 0,001 dengan eksekusi pelatihan pada GPU tunggal menghasilkan performa yang stabil, tanpa indikasi overfitting, sebagaimana terlihat dari konvergensi nilai loss dan akurasi yang baik pada semua proporsi data. Namun, proporsi data yang lebih besar untuk pelatihan memberikan hasil prediksi yang lebih optimal terhadap data validasi. Setelah melakukan evaluasi performa model berdasarkan proporsi data, parameter pelatihan seperti loss validasi, waktu pelatihan, dan jumlah iterasi, analisis lebih lanjut dapat dilakukan terhadap metrik evaluasi klasifikasi. Tabel berikut menyajikan hasil evaluasi performa model menggunakan metrik akurasi, precision, sensitivity (recall), dan F1-score untuk masing-masing kelas pada berbagai proporsi data. Analisis ini bertujuan untuk memberikan gambaran yang lebih rinci mengenai kemampuan model dalam mengklasifikasikan setiap kelas dengan akurat.

Hasil evaluasi pada Tabel 5 menunjukkan bahwa proporsi data pelatihan dan validasi memengaruhi performa model berdasarkan metrik evaluasi. Proporsi data 90:10 menghasilkan nilai akurasi tertinggi sebesar 98,04%, dengan semua kelas menunjukkan nilai precision dan sensitivity (recall) yang sangat baik, terutama untuk Class 1 yang mencapai 100% dalam precision. Pada proporsi 80:20, akurasi model sedikit menurun menjadi 97,05%, namun nilai precision dan recall tetap tinggi, menunjukkan kemampuan model yang baik dalam mengklasifikasikan data. Sebaliknya, pada proporsi 50:50, akurasi menurun menjadi 95,29%, dengan beberapa kelas, seperti Class 2 dan Class 3, menunjukkan nilai precision dan recall yang lebih rendah dibandingkan dengan proporsi yang lebih besar untuk pelatihan. Hal ini mengindikasikan bahwa model dengan proporsi data pelatihan yang lebih besar cenderung lebih efektif dalam mempelajari pola data dan menghasilkan performa klasifikasi yang lebih optimal. Analisis ini menegaskan pentingnya pemilihan proporsi data yang tepat untuk mencapai hasil yang maksimal dalam pelatihan model. Tabel 5 menunjukkan bahwa model memiliki performa klasifikasi yang baik, meskipun beberapa kesalahan prediksi kecil masih terjadi pada kelas tertentu. Secara keseluruhan, model yang digunakan dalam penelitian ini menunjukkan performa yang konsisten dan sangat baik dalam mengklasifikasikan data pada kelima skenario pembagian data. Tingkat akurasi rata-rata yang dicapai adalah 95,51%, yang mencerminkan



kemampuan model dalam mengatasi perubahan proporsi data latih dan data uji. Hasil ini mengindikasikan bahwa model yang dikembangkan memiliki keandalan yang tinggi untuk diterapkan dalam tugas klasifikasi pada domain penelitian ini.

Tabel 5. Evaluasi Performa Model pada Berbagai Proporsi Data

Proporsi Data	Class	Akurasi	Precision	Sensitivity(recall)	F1- Score
90 : 10	Class 1	98,04%	100%	96.30%	98.11%
	Class 2		96.55%	93.33%	94.92%
	Class 3		96.77%	100%	98.36%
	Class 4		100%	100%	100%
	Class 5		100%	100%	100%
	Class 6		96.77%	100%	98.36%
80 : 20	Class 1	97.05%	98.15%		98.15%
	Class 2		89.23%	96.67%	92.80%
	Class 3		98.33%	98.33%	98.33%
	Class 4		100%	100%	100%
	Class 5		100%	100%	100%
	Class 6		100%	91.67%	95.65%
70 : 30	Class 1	95.86%	90.80%	96.34%	93.49%
	Class 2		93.33%	93.33%	93.33%
	Class 3		98.84%	94.44%	96.59%
	Class 4		97.80%	98.89%	98.34%
	Class 5		100%	94.12%	96.97%
	Class 6		97.75%	96.67%	97.21%
60 : 40	Class 1	96.73%	98.04%	91.74%	94.79%
	Class 2		93.44%	95.00%	94.21%
	Class 3		99.15%	97.50%	98.32%
	Class 4		98.36%	100%	99.17%
	Class 5		100%	100%	100%
	Class 6		94.40%	98.33%	96.33%
50 : 50	Class 1	95.29%	93.43%	94.12%	98.47%
	Class 2		94.00%	94.00%	94.00%
	Class 3		98.01%	98.67%	98.34%
	Class 4		97.39%	99.33%	98.35%
	Class 5		100.00%	100.00%	100.00%
	Class 6		92.41%	89.33%	90.85%

4. KESIMPULAN

Model CNN dengan arsitektur ResNet50 berhasil diterapkan untuk mengidentifikasi enam jenis rempah-rempah, yaitu jahe, kunyit, kencur, temulawak, lengkuas, dan temu kunci. Dataset yang digunakan terdiri dari 1.528 citra yang diproses menggunakan Augmentasi data, sehingga meningkatkan variasi data dan membantu model dalam mengenali karakteristik rempah-rempah secara lebih baik. Teknik transfer learning diterapkan dalam pelatihan model untuk memanfaatkan fitur bawaan ResNet50, yang mampu meningkatkan efisiensi dan akurasi model dalam klasifikasi citra rempah-rempah. Evaluasi model menggunakan Confusion Matrix dengan berbagai rasio pembagian data, yaitu 90:10, 80:20, 70:30, 60:40, 50:50. Hasil terbaik diperoleh pada rasio 90:10, dengan akurasi mencapai 98,04%, dimana 80:20 menghasilkan akurasi 0.99% lebih rendah dan rasio 60:40 menghasilkan 2,75% lebih rendah. Metrik evaluasi seperti precision, recall, dan F1-score menunjukkan hasil yang stabil dan akurat untuk setiap kelas rempah-rempah, sehingga membuktikan keandalan model dalam klasifikasi citra. Model



yang dikembangkan dapat menjadi dasar bagi pengembangan sistem identifikasi rempah-rempah berbasis citra digital, yang berpotensi digunakan dalam berbagai bidang seperti industri pangan, penelitian, dan edukasi. Untuk penelitian selanjutnya, dapat dikembangkan menjadi aplikasi praktis berbasis web atau mobile yang dilengkapi dengan fitur integrasi ke perangkat keras seperti kamera atau pemindai.

DAFTAR PUSTAKA

- Abou Baker, N., Zengeler, N., & Handmann, U. (2022). A Transfer Learning Evaluation of Deep Neural Networks for Image Classification. *Machine Learning and Knowledge Extraction*, 4(1), 22–41. <https://doi.org/10.3390/make4010002>
- Agustina, N., & Hermawan, S. (2023). Implementasi *Convolutional Neural Network* untuk Klasifikasi Rempah – Rempah Khas Indonesia. *Of Computer and Information Technology*, 07. <http://e-journal.unipma.ac.id/index.php/doubleclick>
- Al-Ghiffary, M. M. I., Sari, C. A., Rachmawanto, E. H., Yacoob, N. M., Cahyo, N. R. D., & Ali, R. R. (2023). Milkfish Freshness Classification Using *Convolutional Neural Networks* Based on Resnet50 Architecture. *Advance Sustainable Science Engineering and Technology*, 5(3), 0230304. <https://doi.org/10.26877/asset.v5i3.17017>
- Boimau, R. A., & Kaesmetan, Y. R. (2024). Klasifikasi Citra Digital Bumbu dan Rempah Dengan Algoritma *Convolutional Neural Network* (CNN). *Teknik Informatika Dan Jaringan*, 2(3), 26–34. <https://doi.org/10.62951/repeater.v2i3.81>
- Cahyo, N. R. D., & Al-Ghiffary, M. M. I. (2024). An Image Processing Study: Image Enhancement, Image Segmentation, and Image Classification using Milkfish Freshness Images. *IJECAR International Journal of Engineering Computing Advanced Research*, 1(1), 11–22.
- Cahyo, N. R. D., Sari, C. A., Rachmawanto, E. H., Jatmoko, C., Al-Jawry, R. R. A., & Alkhafaji, M. A. (2023). A Comparison of Multi Class Support Vector Machine vs Deep *Convolutional Neural Network* for Brain Tumor Classification. *2023 International Seminar on Application for Technology of Information and Communication (ISemantic)*, 12(2), 358–363. <https://doi.org/10.1109/iSemantic59612.2023.10295336>
- Fabian Azmi, A., & Voutama, A. (2024). Prediksi Churn Nasabah Bank Menggunakan Klasifikasi Random Forest Dan Decision Tree Dengan Evaluasi Confusion Matrix. *Jurnal Ilmiah Komputer Dan Informatika*, 13(1), 111–119.
- Gh, M., Rasyid, M., & Hasanah, U. (2023). Potensi Herba dan Rempah Sebagai Tanaman Obat Keluarga. In *BIOMA* (Vol. 5, Issue 2).
- Kholifah, A. N., Rahardja, D. M., & Karnita, R. (2023). Perancangan Aplikasi Edukasi Berbasis Mobile Tentang Pengenalan Bumbu Rempah Masakan Khas Indonesia Bagi Generasi Z. *Andharupa: Jurnal Desain Komunikasi Visual & Multimedia*, 09, 59–59. <http://publikasi.dinus.ac.id/index.php/andharupa/index>
- Li, X. X., Li, D., Ren, W. X., & Zhang, J. S. (2022). Loosening Identification of Multi-Bolt Connections Based on Wavelet Transform and ResNet-50 *Convolutional Neural Network*. *Sensors*, 22(18). <https://doi.org/10.3390/s22186825>
- Mahrus Fathoni, F., Aji Putra, C., Lina Nurlaili, A., & Timur, J. (2024). Klasifikasi Penyakit Daun Anggur Menggunakan Metode K-Nearest Neighbor Berdasarkan Gray Level Co-Occurrence Matrix. *Jurnal Ilmiah Informatika Dan Komputer*, 3(1), 8–15. <https://doi.org/https://ojs.unsiq.ac.id/index.php/biner>
- Maulana, R., Dwi Zahra Putri, R., Ade Amelia, T., Syahputra, H., Ramadhani, F., & Iskandar Psr V Medan Esatate Kab Deli Serdang, J. W. (2024). Identifikasi Jenis Rempah-Rempah Indonesia Dengan *Convolutional Neural Network* (CNN) Menggunakan Arsitektur VGG16. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 8, Issue 4).
- Muzzazinah, M., Yunus, A., Rinanto, Y., Suherlan, Y., Ramli, M., Putri, D. S., Ningtyas, D. W., Rahma, A. L., & Nabila, S. J. (2024). Profile of chemical compounds and potency of galangal



- (Kaempferia galanga L.) essential oils from Kemuning Village, Karanganyar District, Central Java, Indonesia. *Biodiversitas Journal of Biological Diversity*, 25(4), 1386–1393. <https://doi.org/10.13057/biodiv/d250406>
- Nada Nafisa, A., Nia Devina Br Purba, E., Aulia Alfarisi Harahap, F., Adawiyah Putri, N., Komputer, I., & Matematika dan Ilmu Pengetahuan Alam, F. (2023). Implementasi Algoritma *Convolutional Neural Network* Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma. *Teknologi Informasi, Komputer Dan Aplikasinya (JTika)*, 05(1), 53–61. <http://jtika.if.unram.ac.id/index.php/JTIKA/>
- Nisa, C., & Candra, F. (2023). Klasifikasi Jenis Rempah-Rempah Menggunakan Algoritma *Convolutional Neural Network*. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(1), 78–84. <https://doi.org/10.57152/malcom.v4i1.1018>
- Nugraha, G. S., Darmawan, M. I., & Dwiyanaputra, R. (2023). Comparison of CNN's Architecture GoogleNet, AlexNet, VGG-16, Lenet -5, Resnet-50 in Arabic Handwriting Pattern Recognition. *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*. <https://doi.org/10.22219/kinetik.v8i2.1667>
- Pangan, J., Gizi, D., Agustina, S., Kurniawan, M. F., Nurhalimah, S., & Pangan, J. T. (2024). Analisis Sensori dan Kimia Stik Substitusi Tepung Kacang Hijau dengan Penambahan Rempah Temu Kunci Sensory and Chemical Analysis of Mung Bean Powder Stick Substitution with the Addition of Fingerroot Spice. *Pangan Dan Gizi*, 14(1), 54–65.
- Reddy, A. S. B., & Juliet, D. S. (2019). Transfer Learning with ResNet-50 for Malaria Cell-Image Classification. *2019 International Conference on Communication and Signal Processing (ICCSP)*, 0945–0949. <https://doi.org/10.1109/ICCSP.2019.8697909>
- Salat, S. Y. S., Yuniastri, R., Pramasari, I. F., Tukiran, T., Ruhana, A., & Imron, A. (2024). Peningkatan Produktivitas Jamu Serbuk Melalui Penerapan Teknologi Tepat Guna. *JMM (Jurnal Masyarakat Mandiri)*, 8(1), 985. <https://doi.org/10.31764/jmm.v8i1.20318>
- Sanjaya, M., & Nurraharjo, E. (2023). Deteksi Jenis Rempah-Rempah Menggunakan Metode *Convolutional Neural Network* Secara Real Time. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 7(1), 22–31. <https://tunasbangsa.ac.id/ejurnal/index.php/jsakti>
- Sari Hadati Mulya, & Mirum Sapat Surbakti. (2021). Terites, Kuliner Ekstrim Khas Karo Sebagai Daya Tarik Wisata Kuliner. *Hospitaliti Dan Pariwisata*, 3(1), 21–34.
- Setiawan, F. B., Aldo Wijaya, O. J., Pratomo, L. H., & Riyadi, S. (2021). Sistem Navigasi Automated Guided Vehicle Berbasis Computer Vision dan Implementasi pada Raspberry Pi. *Jurnal Rekayasa Elektrika*, 17(1), 7–14. <https://doi.org/10.17529/jre.v17i1.18087>
- Simarmata, A. M., Zizwan Putra, A., & Mahmud Husein, A. (2024). Penerapan Metode Computer Vision Dalam Klasifikasi Buah Jeruk Menggunakan Teknik Image Pre-Processing. *DSI: Jurnal Data Science Indonesia*, 3(2), 110–116. <https://doi.org/10.47709/dsi.v3i2.4010>
- Susanto, A., Sari, C. A., Rachmawanto, E. H., Mulyono, I. U. W., & Mohd Yaacob, N. (2024). A Comparative Study of Javanese Script Classification with GoogleNet, DenseNet, ResNet, VGG16 and VGG19. *Scientific Journal of Informatics*, 11(1), 31–40. <https://doi.org/10.15294/sji.v11i1.47305>
- Syafar, A. M., & Darmatasia. (2023). Implementasi *Convolutional Neural Network* untuk Klasifikasi Tanaman Rimpang Secara Virtual. *Instek*, 8(1). <http://journal.uin-alauddin.ac.id/index.php/instek/index>
- Tilasefana, R. A., & Putra, R. E. (2023). Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG NET Untuk Pengenalan Cuaca. *Journal of Informatics and Computer Science*, 05.
- Wulandari, I., Yasin, H., & Widiharah, T. (2020a). Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma *Convolutional Neural Network* (CNN). *Journal Gaussian*, 9(3), 273–282. <https://ejournal3.undip.ac.id/index.php/gaussian/>



Wulandari, I., Yasin, H., & Widiharih, T. (2020b). Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma *Convolutional Neural Network* (CNN). *GAUSSIAN*, 9(3), 273–282. <https://ejournal3.undip.ac.id/index.php/gaussian/>