

Klasifikasi Buah Berry menggunakan Metode Residual Network (ResNet-50)

Titus Bintang Pekiek Putu Sangyoga¹, Mutaqin Akbar²

Informatika, Fakultas Teknologi Informasi, Universitas Mercu Buana Yogyakarta

¹211110118@student.mercubuana-yogya.ac.id, ²mutaqin@mercubuana-yogya.ac.id

Abstract

Berries are known to have high nutritional benefits, but challenges in accurately distinguishing the types are still common, especially in the agriculture and distribution industry in Indonesia. This research aims to build an automatic classification system for berries using deep learning method with Residual Network architecture (ResNet-50). The dataset used consists of 1,000 images of four types of berries: blackberry, blueberry, raspberry, and strawberry, obtained from public sources such as Kaggle, Roboflow, and previous research. The image data then went through a pre-processing stage of resizing, pixel normalization, and data augmentation to match the ResNet-50 input format. The model is trained using pretrained parameters from ImageNet by freezing all layers except the fully connected layer. Performance evaluation was done through confusion matrix and classification metrics such as accuracy, precision, recall, and F1-score. The test results show that the model achieved 100% classification accuracy on the test data, which means that all images were correctly classified. This shows that the classification approach using ResNet-50 is very effective in identifying berry types based on visual image features. This research is expected to be a reliable solution in supporting the automation of fruit classification in the agricultural sector and food industry.

Keywords: Image Classification, Berries, Deep Learning, Residual Network, ResNet-50.

Abstrak

Buah berry dikenal memiliki manfaat gizi tinggi, namun tantangan dalam membedakan jenis-jenisnya secara akurat masih sering terjadi, khususnya dalam industri pertanian dan distribusi di Indonesia. Penelitian ini bertujuan untuk membangun sistem klasifikasi otomatis buah berry menggunakan metode deep learning dengan arsitektur Residual Network (ResNet-50). Dataset yang digunakan terdiri dari 1.000 citra empat jenis buah berry: blackberry, blueberry, raspberry, dan strawberry, yang diperoleh dari sumber publik seperti Kaggle, Roboflow, serta penelitian terdahulu. Data citra kemudian melalui tahap pra-processing berupa resize, normalisasi piksel, dan augmentasi data agar sesuai dengan format input ResNet-50. Model dilatih menggunakan parameter pretrained dari ImageNet dengan pembekuan seluruh lapisan kecuali fully connected layer. Evaluasi performa dilakukan melalui confusion matrix dan metrik klasifikasi seperti akurasi, presisi, recall, dan F1-score. Hasil pengujian menunjukkan bahwa model berhasil mencapai akurasi klasifikasi sebesar 100% pada data uji, yang berarti seluruh citra berhasil diklasifikasikan dengan benar. Hal ini menunjukkan bahwa pendekatan klasifikasi menggunakan ResNet-50 sangat efektif dalam mengidentifikasi jenis buah berry berdasarkan fitur visual citra. Penelitian ini diharapkan dapat menjadi solusi yang andal dalam mendukung otomatisasi klasifikasi buah dalam sektor pertanian maupun industri pangan.

Kata kunci: Klasifikasi Citra, Buah Berry, Deep Learning, Residual Network, ResNet-50.

1. Pendahuluan

Buah berry merupakan kelompok buah yang dikenal luas karena rasa yang khas, warna yang menarik, dan kandungan gizi yang tinggi. Secara botani, buah berry mengacu pada buah berdaging yang berkembang dari ovarium tunggal dan biasanya mengandung banyak biji, seperti blueberry, blackberry, raspberry, strawberry, dan lain-lain. Namun, dalam penggunaan sehari-hari, istilah “berry” lebih sering digunakan secara umum untuk menyebut buah-buahan kecil dengan rasa yang manis dan berwarna cerah. Asal buah berry dapat dijumpai dari berbagai belahan dunia. Contohnya, blueberry dapat ditemui di Amerika Utara, sedangkan raspberry dan blackberry dapat ditemui di Eropa dan Asia. Buah-buahan ini telah dibudidayakan sejak berabad-abad lalu dan kini menjadi komoditas pertanian penting di berbagai negara, termasuk Indonesia. Manfaat buah berry sangat beragam. Selain kaya akan vitamin C, serat, dan antioksidan, buah berry juga diketahui berperan penting dalam berbagai penyakit degeneratif seperti penyakit jantung, kanker, dan gangguan kognitif. Kandungan senyawa seperti anthocyanin dan flavonoid pada berry juga memberikan efek anti-inflamasi dan meningkatkan sistem imun tubuh[1].

Di Indonesia sendiri, tingkat konsumsi buah berry di Indonesia masih tergolong rendah. Berdasarkan data Kementerian Kesehatan, lebih dari 95% masyarakat Indonesia belum memahami rekomendasi konsumsi buah dan sayur harian. Hal ini membuktikan bahwa buah berry belum menjadi prioritas konsumsi masyarakat Indonesia. Faktor rendahnya konsumsi buah berry ini antara lain adalah harga yang cukup mahal, keterbatasan distribusi, dan minimnya pengetahuan masyarakat Indonesia mengenai manfaat dari buah berry itu sendiri. Menurut studi dari Rachman penelitian di Denpasar mengungkapkan bahwa perilaku konsumsi buah berry dipengaruhi oleh pengetahuan gizi, aksesibilitas, serta pendapatan orang tua. Para ahli di bidang pangan dan kesehatan memandang buah berry sebagai sumber pangan fungsional yang potensial. Magananda dan Gandamastuti menyebutkan bahwa buah berry mengandung senyawa bioaktif seperti antosianin, flavonoid, dan vitamin C yang dapat berkontribusi dalam pencegahan penyakit kronis seperti diabetes, hipertensi, dan kanker. Oleh karena itu, pengembangan produk olahan berbasis buah berry, baik dalam bentuk jus, maupun ekstrak, menjadi peluang yang menjanjikan dalam dunia kesehatan dan industri pangan[2].

Namun dari sisi budidaya, para petani dan pelaku pertanian masih menghadapi sejumlah tantangan. Salah satu tantangan utama adalah ketidaktauan dalam membedakan jenis-jenis buah berry secara akurat, baik berdasarkan struktur, bentuk, warna, maupun karakteristik kualitas buah berry itu sendiri. Hal ini menjadi hambatan dalam kegiatan penyortiran, penanaman, dan pemasaran. Selain itu,

beberapa jenis berry seperti blueberry dan raspberry yang memerlukan iklim yang lebih dingin dan kondisi tanah yang khusus, sedangkan Indonesia memiliki iklim tropis. Oleh karena itu, klasifikasi yang akurat berbasis teknologi, seperti pengolahan citra digital dan deep learning, sangat dibutuhkan untuk membantu proses identifikasi dan standarisasi kualitas buah berry secara efisien.

Klasifikasi otomatis berbasis pengolahan citra digital merupakan salah satu solusi yang banyak dikembangkan dalam beberapa tahun terakhir. Klasifikasi buah secara otomatis tidak hanya mempercepat proses penyortiran, tetapi juga membantu menjaga konsistensi kualitas produk dan mengurangi ketergantungan pada tenaga kerja manusia yang terkadang bisa saja melakukan kesalahan. Sistem ini bekerja dengan cara mengidentifikasi fitur visual dari citra buah, seperti bentuk, warna, dan tekstur, lalu mengklasifikasikannya menggunakan algoritma machine learning atau deep learning. Beberapa algoritma yang umum digunakan dalam klasifikasi citra buah antara lain adalah Support Vector Machine (SVM)[3], [4], K-Nearest Neighbors (KNN)[5], [6], dan Random Forest[7], [8]. Namun, seiring berkembangnya teknologi deep learning, algoritma berbasis Convolutional Neural Network (CNN)[9], [10] menjadi pendekatan yang sangat populer karena kemampuannya dalam mengekstraksi fitur kompleks dari gambar secara otomatis. Salah satu arsitektur CNN yang paling menonjol adalah Residual Network[11].

ResNet merupakan arsitektur jaringan syaraf konvolusional yang diperkenalkan oleh He, Zhang. ResNet dikembangkan untuk mengatasi masalah degradasi akurasi pada jaringan yang sangat dalam, di mana penambahan lapisan justru menyebabkan performa model menurun. Dengan menggunakan konsep residual learning dan shortcut connections, ResNet memungkinkan informasi dari lapisan sebelumnya dapat “melompati” satu atau beberapa lapisan, sehingga mengurangi risiko hilangnya informasi penting dan mempercepat proses pelatihan model[12]. ResNet terbukti unggul dalam berbagai tugas klasifikasi gambar, termasuk untuk data dengan kompleksitas visual tinggi seperti buah-buahan.

Beberapa penelitian terdahulu mengenai klasifikasi citra buah berry telah dilakukan[13]. Penelitian ini cukup relevan karena mengangkat topik klasifikasi buah yang berguna dalam otomatisasi industri pertanian, khususnya untuk buah berry yang memiliki nilai nutrisi tinggi namun konsumsi dan pemahamannya masih terbatas di Indonesia. Peneliti melakukan akuisisi data dengan kamera ponsel Iphone Xs dan mengekstraksi fitur statistik dari gambar grayscale seperti mean, standar deviasi, entropi, energi, smoothness, dan skewness, yang kemudian digunakan sebagai input ke dalam jaringan LVQ. Secara metodologi, penelitian ini disusun dengan

baik, melibatkan eksperimen parameter seperti epoch dan learning rate yang bervariasi. Peneliti menggunakan 150 data untuk pelatihan dan 50 data untuk pengujian, hasilnya menunjukkan performa yang cukup menjanjikan, dengan akurasi pengujian tertinggi mencapai 98,18% pada konfigurasi epoch 50 dan learning rate 0,01. Hasil yang diperoleh menekankan kesan kaedah LVQ dalam mengklasifikasikan *image* makanan, yang mempunyai implikasi positif untuk meningkatkan pemahaman dan penggunaan buah berry di Indonesia, di mana kesadaran tentang manfaat buah ini masih rendah. Secara keseluruhan, jurnal ini memberikan kontribusi yang bermanfaat dalam penerapan LVQ untuk klasifikasi visual dalam bidang pertanian digital.

Kemudian dilanjutkan dengan penelitian mengenai klasifikasi citra menggunakan Residual Network (Resnet) yang dilakukan oleh Ridhovan dan Suharto[14]. Dengan menggunakan dataset dari Kaggle yang telah diolah melalui proses *under sampling* dan augmentasi citra, peneliti menguji model Resnet152v2 dalam lima skenario pembagian data latih dan uji. Hasil penelitian menunjukkan bahwa skenario terbaik adalah saat data latih dan uji dibagi menjadi 80:20, yang menghasilkan akurasi 98% serta nilai evaluasi *confusion matrix* sebesar 0,35. Ini menunjukkan potensi besar metode Residual Network dalam mendeteksi penyakit tanaman secara otomatis. Secara keseluruhan, jurnal ini kuat dari segi metodologi dan implementasi teknis, dengan penjelasan rinci mengenai proses data dan evaluasi model. Penggunaan arsitektur deep learning yang telah terbukti seperti ResNet menjadi nilai tambah karena dapat menghemat waktu pelatihan tanpa mengorbankan akurasi. Namun, perlu peningkatan pada analisis *confusion matrix*, yang nilainya cenderung rendah, dan bisa diperbaiki dengan pendekatan data balancing atau parameter tuning lebih lanjut.

Selanjutnya penelitian oleh [15] yang mengatasi keterbatasan pendekatan rule-based sebelumnya dengan memanfaatkan keunggulan deep learning dalam ekstraksi fitur citra secara otomatis. Dataset yang digunakan terdiri dari 1.046 citra, termasuk data sehat dan data terinfeksi, yang diproses melalui tahap *Resize*, Augmentasi, dan pembagian data. Hasil pelatihan menunjukkan performa sangat tinggi, dengan akurasi pelatihan 96,78% dan validasi 99,68%, serta nilai F1-score keseluruhan mencapai 99,09%. Secara umum, penelitian ini sangat baik dari sisi struktur metodologi dan hasil, serta memberikan kontribusi praktis bagi pengendalian penyakit di sektor budidaya rumput laut. Implementasi Residual Network terbukti efektif dalam mendeteksi dan membedakan jenis penyakit dengan akurasi yang tinggi. Meski begitu, jumlah data untuk kelas “sehat” tergolong rendah, sehingga peningkatan pada distribusi data kelas dapat menjadi perhatian untuk

penelitian lanjutan agar model lebih seimbang dan generalisasi semakin baik.

Penelitian mengenai Resnet oleh [16] yang digunakan untuk membantu proses diagnosis dan penanganan jerawat dengan mengklasifikasikan gambar kulit wajah ke dalam tiga jenis jerawat, yaitu : *acne-comedonice*, *acne-conglobata*, dan *acne-papulopustulosa*. Dataset yang digunakan berasal dari Roboflow dan terdiri dari 754 gambar. Proses pelatihan model melibatkan *proprocessing*, augmentasi data, serta penggunaan dropout dan optimizer Adam untuk meminimalisir *overfitting*. Model penelitian ini berhasil mencapai akurasi pelatihan hingga 98,35% dan akurasi validasi tertinggi sebesar 92,86% dengan evaluasi menggunakan *confusion matrix* menunjukkan akurasi keseluruhan sebesar 93%. Hasil evaluasi memperlihatkan bahwa model sangat baik dalam mengklasifikasikan jenis jerawat *acne-comedonica* dan *acne-papulopustulosa*, meskipun mengalami tantangan pada kelas *acne-conglobata*. Penelitian ini menunjukkan potensi besar penggunaan deep learning, khususnya CNN dengan ResNet-50, dalam bidang dermatologi digital. Namun, keterbatasan seperti ukuran dataset dan spesifikasi perangkat keras menjadi tantangan yang perlu ditangani dalam pengembangan lanjutan.

Terakhir penelitian mengenai Resnet yang dilakukan oleh [17], yang menggunakan dua dataset utama, yaitu BreakHist dan IDC. Dataset BreakHist mencakup delapan kelas, sedangkan IDC hanya dua kelas. Data BreakHist digunakan dengan empat level perbesaran mikroskopis. Ketidakseimbangan data antar kelas diatasi dengan *oversampling* dan *undersampling* secara acak pada data pelatihan, sehingga tiap kelas memiliki jumlah data yang setara. Evaluasi model dilakukan melalui pengukuran akurasi, presisi, dan *recall* menggunakan *confusion matrix*. Hasil pengujian menunjukkan bahwa perbesaran citra 400x memberikan performa terbaik untuk klasifikasi, terutama saat menggunakan ResNet50. Pada pengujian menggunakan metode *resampling*, ResNet50 mencapai akurasi rata-rata sebesar 81,67%, dengan *precision* 78,41% dan *recall* 82,91%. Jika tanpa *resampling*, hasilnya sedikit lebih rendah namun tidak signifikan. Penelitian ini juga menunjukkan bahwa performa model cenderung menurun saat jumlah kelas meningkat, terutama untuk lebih dari lima kelas. Untuk dataset IDC, ResNet18 menunjukkan hasil yang sedikit lebih baik dibanding ResNet50. Kesimpulan dari studi ini menekankan bahwa *random resampling* efektif untuk mengatasi data tidak seimbang pada klasifikasi citra histopatologi, namun penggunaannya lebih cocok untuk klasifikasi dengan jumlah kelas yang tidak terlalu banyak.

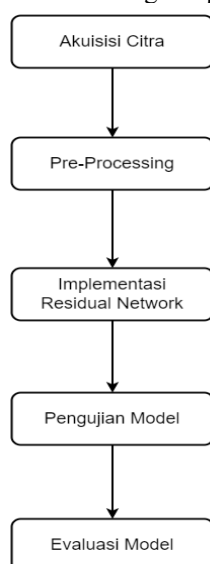
Berdasarkan permasalahan tersebut, penelitian ini memiliki tujuan utama. Tujuan pertama adalah untuk memperoleh fitur visual yang tepat dan dapat

diandalkan dalam proses klasifikasi buah berry dengan pendekatan Residual Network. Yang kedua adalah merancang dan mengembangkan sistem pelatihan yang efektif, agar model ResNet yang digunakan dapat belajar secara optimal dari data yang tersedia. Dengan tujuan tersebut, penelitian ini diharapkan dapat memberikan manfaat baik dari sisi pengembang teknologi maupun penerapannya dalam kehidupan nyata. Salah satu manfaat yang diharapkan adalah ditemukannya jenis fitur terbaik yang mampu membedakan buah berry secara akurat. Selain itu, penelitian ini juga diharapkan dapat menghasilkan sistem pelatihan klasifikasi yang efisien dan dapat diandalkan dalam berbagai kondisi.

Agar penelitian ini bisa berjalan lancar, maka diharuskan adanya batasan agar berjalan dengan fokus dan terarah. Penelitian ini hanya akan berfokus pada klasifikasi lima jenis buah berry. Selain itu, metode klasifikasi yang digunakan terbatas pada pendekatan Residual Network, tanpa membandingkan dengan metode klasifikasi lain. Proses pengujian dan evaluasi sistem dilakukan menggunakan data gambar yang telah dipersiapkan sebelumnya, sehingga tidak mencakup pengambilan data secara langsung dari lingkungan nyata.

2. Metode Penelitian

Proses klasifikasi terhadap empat jenis buah berry menggunakan Residual Network (ResNet) melibatkan beberapa tahapan. Langkah-langkah berjalannya penelitian dalam mengidentifikasi varietas atau jenis buah berry terdiri dari akuisisi citra, preprocessing, implementasi arsitektur Residual Network, pengujian model, dan evaluasi model, seperti ditunjukkan dalam diagram pada Gambar 1.

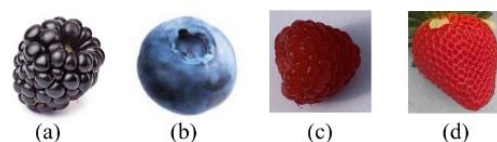


Gambar 1. Blok Diagram Alur Penelitian

2.1. Akuisisi Data

Akuisisi data adalah langkah untuk mengambil data image yang akan digunakan dalam proses penelitian.

Proses akuisisi data image buah berry ini menggabungkan dataset dari beberapa sumber, diantaranya dataset yang digunakan dalam studi penelitian oleh [13], serta dataset yang tersedia secara publik melalui platform Kaggle dan Roboflow. Dataset citra buah berry ini terdiri dari empat jenis buah berry, yaitu blackberry, blueberry, raspberry, strawberry dengan total 1000 citra, masing-masing sebanyak 250 citra per jenis buah berry. Contoh citra jenis buah berry dapat dilihat pada Gambar 2.



Gambar 2. Jenis Buah Berry Blackberry(a), Blueberry(b), Raspberry(c), Strawberry(d)

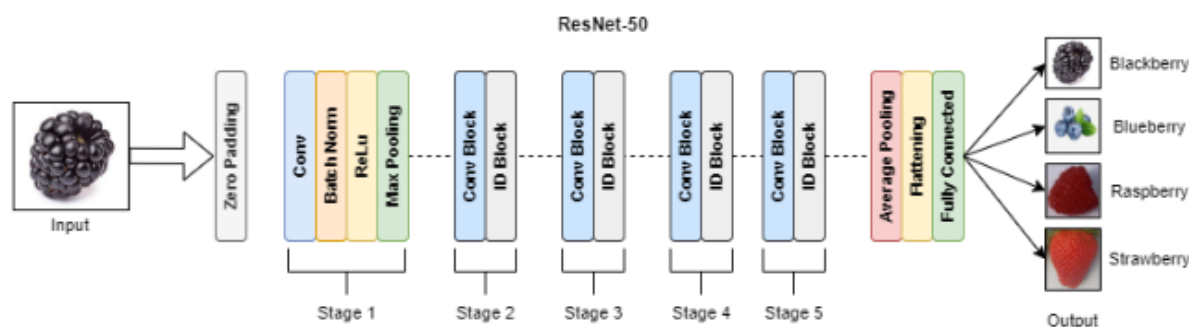
2.2. Pre-processing

Pre-Processing dilakukan setelah seluruh data citra berhasil dikumpulkan. Karena setiap data citra buah berry memiliki resolusi yang acak, maka dilakukan pengubahan ukuran (resize) untuk mempercepat proses pelatihan model selanjutnya. Proses resize ini dilakukan menggunakan Google Colaboratory, proses ini menghasilkan citra yang berukuran 224x224 piksel. Semua citra yang diresize disesuaikan dengan ukuran input yang dibutuhkan oleh model Residual Network. Dataset dengan total 1000 citra yang masing-masing kelas sebanyak 250 citra dibagi menjadi dua bagian, yaitu data latih dan data uji, dengan perbandingan 70:15, dimana 70% digunakan untuk data pelatihan dan 15% digunakan untuk data pengujian.

2.3. Implementasi Residual Network (ResNet-50)

Residual Network (ResNet) merupakan salah satu arsitektur deep learning yang dirancang untuk mengatasi permasalahan degradasi akurasi pada jaringan saraf berlapis-lapis yang sangat dalam. Arsitektur ini diperkenalkan oleh He Kaiming dkk pada 2016 dan memiliki karakteristik utama berupa residual block yang dilengkapi dengan shortcut connection atau skip connection. Shortcut connection memungkinkan data dari lapisan awal untuk langsung diteruskan ke lapisan yang lebih dalam tanpa melalui proses transformasi berlapis[18].

Dalam penelitian ini, digunakan arsitektur Residual Network (ResNet) seperti pada gambar 3, tepatnya varian ResNet-50, untuk melakukan klasifikasi citra buah berry. ResNet-50 terdiri dari 50 lapisan dan dibangun menggunakan struktur residual yang mengandalkan shortcut connection untuk memungkinkan aliran gradien tetap stabil selama proses pelatihan. ResNet-50 memulai pemrosesan citra dengan sebuah lapisan konvolusi awal berukuran 7x7 dengan 64 filter dan stride 2, diikuti oleh operasi max pooling 3x3 untuk mengurangi resolusi fitur. Setelah tahap awal ini, data akan melewati empat blok utama yaitu conv2_x, conv3_x, conv4_x, conv5_x,



Gambar 3. Arsitektur ResNet-50

yang masing-masing berperan dalam mengekstraksi fitur dengan kompleksitas dan kedalaman yang semakin meningkat.

Setiap blok dibangun menggunakan struktur bottleneck block, yaitu rangkaian tiga lapisan konvolusi yang terdiri dari 1x1, 3x3, dan 1x1. Lapisan 1x1 pertama berfungsi untuk mengurangi dimensi channel agar komputasi lebih efisien, kemudian dilanjutkan dengan konvolusi 3x3 yang mengekstraksi fitur spesial, dan diakhiri dengan konvolusi 1x1 yang meningkatkan kembali dimensi channel. Blok conv2_x menghasilkan output berukuran 56x56 dengan 256 channel dan terdiri dari tiga bottleneck block. Selanjutnya, conv3_x mengolah fitur menjadi ukuran 28x28 dengan 512 channel melalui empat bottleneck block. Blok conv4_x memproses fitur menjadi 14x14 dengan 1024 channel dan terdiri atas enam bottleneck block. Terakhir, conv5_x menghasilkan output sebesar 7x7 dengan 2048 channel dari tiga bottleneck block. Setelah semua blok residual selesai, fitur yang dihasilkan akan diringkas menggunakan average pooling dan diteruskan ke lapisan fully connected layer untuk melakukan klasifikasi ke dalam sejumlah kelas sesuai dengan kebutuhan.

Inti dari setiap residual block adalah shortcut connection, yaitu jalur pintas yang langsung menambahkan input awal ke output dari blok konvolusi. Dengan pendekatan ini, model tidak hanya belajar fungsi pemetaan langsung $H(x)$, tetapi justru belajar fungsi residual $F(x)=H(x)-x$, sehingga keluaran akhir menjadi $F(x)+x$. Teknik ini terbukti mampu bekerja secara optimal dalam berbagai aplikasi pengenalan citra karena kemampuannya mengeksplorasi fitur secara mendalam tanpa mengganggu stabilitas proses pelatihan.

Pada implementasi ini, ResNet-50 dimuat menggunakan parameter pretrained=True, yang berarti bobot awal model berasal dari pelatihan pada dataset ImageNet. Hal ini dimaksudkan agar model memiliki pengetahuan awal terhadap fitur visual umum. Untuk menyesuaikan dengan kebutuhan klasifikasi buah berry, seluruh parameter awal dibekukan, sehingga hanya lapisan fully connected layer yang dilatih ulang.

Proses pelatihan dilakukan dengan menggunakan fungsi loss CrossEntropyLoss dan algoritma optimasi Adam dengan learning rate sebesar 0.0001. Pelatihan dijalankan selama 20 epoch dengan memantau nilai akurasi dan loss pada data pelatihan serta validasi pada setiap epoch. Hasil dari proses ini menunjukkan sejauh mana kemampuan model dalam mengenali dan membedakan berbagai jenis buah berry berdasarkan fitur visual yang ditangkap dari citra.

2.4. Pengujian Klasifikasi

Setelah melakukan training dan testing pada model menggunakan ResNet-50, tahap selanjutnya adalah perhitungan *confusion matrix*. *Confusion Matrix* adalah pengukuran performa dari model klasifikasi *machine learning*, baik untuk klasifikasi dua kelas maupun multi-kelas[19]. Dalam kasus klasifikasi, *confusion matrix* terdiri dari empat komponen utama, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Setelah diperoleh representasi dari hasil kinerja proses, tahap selanjutnya adalah melakukan evaluasi terhadap performa model dengan menghitung sejumlah matriks evaluasi, *confusion matrix* dapat menghitung berbagai matriks evaluasi penting seperti akurasi, presisi, recall dan F1-score, memberikan gambaran lebih lengkap mengenai performa model dalam mengklasifikasi data secara tepat[20].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$Specificity = \frac{TN}{TP+TN} \times 100\% \quad (4)$$

$$F1-Score = \frac{2 \times (Precision \times Recall)}{(Precision + Recall)} \times 100\% \quad (5)$$

Keterangan :

TP : True Positive

TN : True Negative

FP : False Positive

FN : False Negative

Dalam evaluasi performa pada kasus klasifikasi multi-kelas, specificity tidak menjadi fokus utama. Sebaliknya, untuk menghitung precision, recall, dan F1-Score digunakan pendekatan macro average, yaitu

dengan mengambil rata-rata nilai matriks dari setiap kelas dan membaginya berdasarkan jumlah total kelas. Sementara itu, rumus akurasi dan rata-rata matriks kinerja lainnya dapat dilihat pada rumus berikut ini.

$$Accuracy = \frac{\text{Jumlah prediksi yang benar}}{\text{Jumlah seluruh prediksi}} \quad (6)$$

$$MAP = \frac{\sum_{k=1}^K Precision_k}{K} \times 100\% \quad (7)$$

$$MAR = \frac{\sum_{k=1}^K Recall_k}{K} \times 100\% \quad (8)$$

$$MAF = \frac{\sum_{k=1}^K F1Score_k}{K} \times 100\% \quad (9)$$

Keterangan :

MAP : *Macro Average Precision*

MAR : *Macro Average Recall*

MAF : *Macro Average F1-Score*

K : Jumlah kelas pada sistem klasifikasi multi-kelas

3. Hasil dan Pembahasan

3.1. Hasil Penelitian

Dalam penelitian ini, digunakan metode klasifikasi citra menggunakan pendekatan *deep learning* dengan memanfaatkan arsitektur ResNet-50. ResNet-50 adalah salah satu arsitektur *deep learning* yang dirancang untuk mengatasi permasalahan degradasi akurasi pada jaringan saraf berlapis-lapis yang sangat dalam. Model ini dilatih untuk mengelompokkan citra buah berry ke dalam beberapa kelas sesuai dengan jenisnya.

Penelitian ini menggunakan 4 jenis buah berry untuk melakukan klasifikasi dengan menggunakan Residual Network. Agar penelitian ini dapat bekerja dalam menentukan sebuah akurasi yang tinggi dibutuhkan dataset yang terdiri dari 4 jenis buah berry yaitu blackberry, blueberry, raspberry, dan strawberry. Yang kemudian melalui tahapan preprocessing seperti resize, normalisasi piksel, dan augmentasi data.

Output dari penelitian ini berupa klasifikasi dari setiap gambar uji, yang ditunjukkan dalam bentuk nilai probabilitas untuk masing-masing kelas serta label prediksi akhir. Selain itu, dilakukan juga evaluasi performa model menggunakan matriks-matriks seperti akurasi, precision, recall, dan confusion matrix untuk melihat seberapa baik model mengenali masing-masing jenis buah berry.

Hasil penelitian yang diperoleh menunjukkan bahwa model mampu melakukan klasifikasi citra buah berry dengan tingkat akurasi yang sangat tinggi. Hal ini menandakan fitur visual dari masing-masing jenis buah berry dapat dikenali secara efektif oleh model, sehingga pendekatan *deep learning* berbasis ResNet-50 dapat dijadikan solusi yang dapat diandalkan dalam proses identifikasi jenis buah berry secara otomatis.

3.1.1. Hasil Akuisisi

Tahap awal yang dilakukan dalam penelitian ini adalah mengumpulkan citra dari empat jenis buah berry. Proses akuisisi data image buah berry ini menggabungkan dataset dari beberapa sumber, diantaranya dataset yang digunakan dalam studi penelitian oleh Azzah Faaizah, serta dataset yang tersedia secara publik melalui platform Kaggle dan Roboflow. Dataset citra buah berry ini terdiri dari empat jenis buah berry, yaitu blackberry, blueberry, raspberry, strawberry dengan total 1000 citra, masing-masing sebanyak 250 citra per jenis buah berry.

Tabel 1. Data Penelitian

Jenis Berry	Jumlah Data
Blackberry	250
Blueberry	250
Raspberry	250
Strawberry	250

3.1.2. Hasil Pre-processing

Pada tahap pre-processing, dilakukan berbagai transformasi terhadap citra buah berry agar sesuai dengan format input yang dibutuhkan oleh model ResNet-50. Perubahan transformasi ini meliputi resize, normalisasi piksel, dan augmentasi data yang digunakan pada model ResNet-50 yang telah dilatih sebelumnya.

Langkah pertama yang dilakukan adalah mengubah seluruh data gambar menjadi dimensi yang seragam, yaitu 224x224 piksel. Ukuran ini dipilih karena standar input bagi model ResNet-50 yang telah dilatih sebelumnya (*pretrained*), yang akan digunakan untuk proses klasifikasi. Proses *Resize* ini penting agar dimensi semua citra seragam dan dapat diproses secara konsisten oleh model ResNet-50. Setelah itu, citra dikonversi menjadi format tensor menggunakan *ToTensor()*, yang juga sekaligus mengubah skala piksel dari rentang 0-255 menjadi 0-1. Proses *resize* ini dilakukan secara otomatis melalui pipeline transformasi PyTorch. Gambar asli tidak diubah secara permanen, namun saat dimuat oleh DataLoader, gambar langsung diubah ukurannya menjadi 224x224 piksel sebelum masuk ke model.

Setelah proses *resize*, dilakukan proses normalisasi piksel dengan nilai rata-rata [0.485, 0.456, 0.406] dan standar deviasi [0.229, 0.224, 0.225] pada masing-masing kanal warna RGB. Nilai ini mengacu pada distribusi statistik dari dataset ImageNet dan bertujuan untuk menyesuaikan skala data input sesuai dengan karakteristik data agar model ResNet-50 dapat belajar lebih cepat dan stabil selama proses pelatihan.

Setelah proses transformasi dilakukan, dataset kemudian dibagi menjadi tiga bagian utama, yaitu *Training Set* sebesar 70% yang digunakan untuk melatih model, *Validation Set* sebesar 15% yang digunakan untuk mengevaluasi performa model

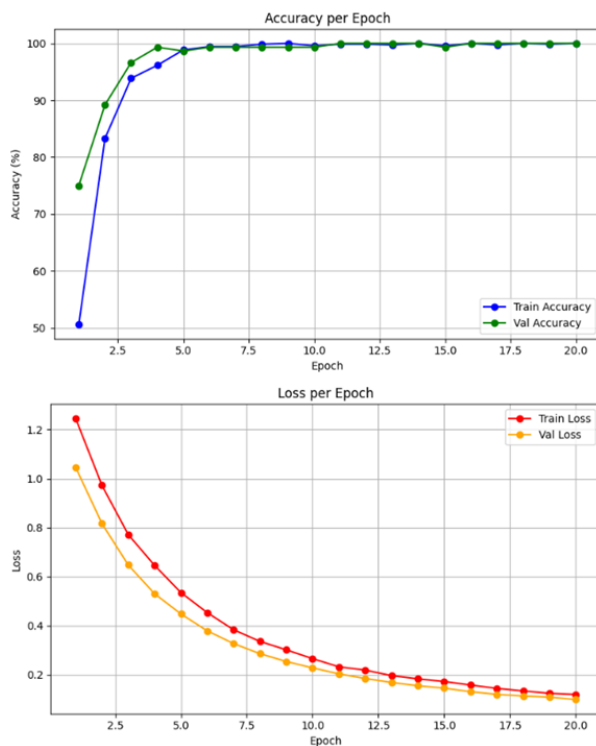
selama pelatihan, dan *Test Set* sebesar 15% yang digunakan sebagai menguji performa akhir model setelah proses pelatihan selesai. Pembagian ini dilakukan secara terpisah dalam direktori berbeda, yaitu train, val, dan test untuk mempermudah pengolahan dan pemanggilan dataset menggunakan ImageFolder pada library PyTorch.

Dengan melakukan preprocessing ini, citra buah berry yang sebelumnya memiliki ukuran yang tidak seragam menjadi lebih terstandarisasi dan siap digunakan dalam proses pelatihan model klasifikasi berbasis Residual Network 50.

3.2 Analisis Dan Pembahasan

3.2.1 Analisis Akurasi dan Loss

Pada proses pelatihan model klasifikasi buah berry menggunakan arsitektur ResNet-50, dilakukan pelatihan selama sejumlah epoch dengan memantau dua matriks utama yaitu akurasi dan loss untuk data training dan validation. Grafik hasil pelatihan ditampilkan pada Gambar 4 berikut ini.



Gambar 4. Grafik Akurasi dan Loss Pada Pelatihan Model

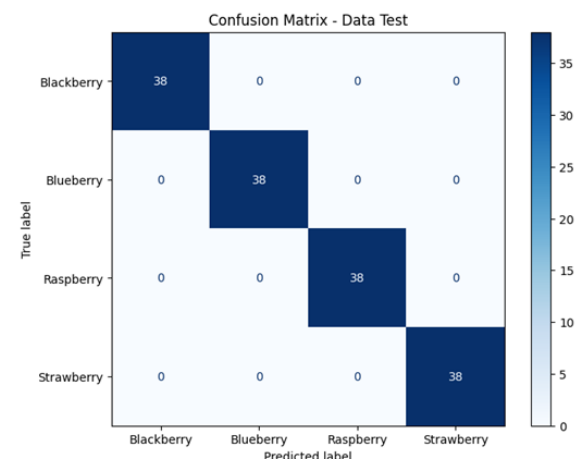
Berdasarkan grafik pada Gambar 7, menunjukkan hasil evaluasi kinerja model selama 20 epoch pelatihan, pada grafik pertama yaitu Akurasi, terlihat bahwa akurasi model meningkat tajam pada epoch awal dan kemudian stabil mendekati 100% setelah sekitar epoch ke-5, baik pada data pelatihan maupun validasi. Hal ini menunjukkan bahwa model mampu belajar dengan sangat cepat dan mencapai performa yang sangat tinggi dalam waktu yang singkat. Grafik kedua yaitu Loss, menunjukkan penurunan nilai loss yang konsisten baik pada data pelatihan maupun

validasi. Penurunan ini menggambarkan bahwa model semakin baik dalam meminimalkan kesalahan prediksi selama proses pelatihan. Selain itu, tidak terlihat adanya *gap* yang signifikan antara kurva pelatihan dan validasi pada kedua grafik, yang artinya bahwa model tidak mengalami *overfitting* dengan kata lain, model memiliki performa yang sangat baik, stabil, dan efektif terhadap data yang belum pernah sebelumnya.

3.2.2 Confusion Matrix

Evaluasi kinerja model klasifikasi citra buah berry pada tahap pengujian dilakukan dengan menggunakan *confusion matrix*. Gambar 8 menampilkan *confusion matrix* yang merepresentasikan jumlah prediksi yang benar dan salah untuk masing-masing kelas, yaitu Blackberry, Blueberry, Raspberry, dan Strawberry. Berdasarkan hasil evaluasi terhadap 152 citra uji (38 citra per kelas), model berhasil mengklasifikasikan seluruh citra dengan akurasi sempurna.

Terlihat bahwa keempat kelas memiliki nilai diagonal utama sebesar 38, yang berarti seluruh citra pada masing-masing kelas berhasil dikenali dengan benar oleh model. Tidak terdapat nilai di luar diagonal utama, yang menunjukkan bahwa tidak ada satupun citra yang salah diklasifikasikan. Dengan demikian, nilai akurasi, presisi, recall, dan F1-score untuk masing-masing kelas adalah 100%. Hasil confusion matrix ini menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik dan mampu membedakan ciri visual dari masing-masing jenis buah berry secara optimal. Keberhasilan ini tidak terlepas dari tahapan preprocessing yang tepat, pemilihan arsitektur model yang sesuai, serta proses pelatihan yang efektif.



Gambar 5. Confusion Matrix

3.2.3 Hasil Evaluasi

Selain menggunakan akurasi dan *confusion matrix*, evaluasi performa model klasifikasi buah berry juga dilakukan dengan matriks tambahan yaitu, Precision, Recall, dan F1-Score. Ketiga matriks ini dilakukan

untuk mengukur tingkat keberhasilan model dalam mengklasifikasi citra buah berry pada data uji.

Tabel 2. Laporan Evaluasi Matriks

Kelas	Precision	Recall	F1-Score
Blackberry	1.00	1.00	1.00
Blueberry	1.00	1.00	1.00
Raspberry	1.00	1.00	1.00
Strawberry	1.00	1.00	1.00

Berdasarkan hasil perhitungan matriks evaluasi memperoleh nilai yang sangat tinggi, yaitu 1.00 atau 100% untuk keempat kelas tersebut. Hal ini menunjukkan bahwa model mampu memprediksi setiap kelas dengan tingkat ketepatan yang sempurna tanpa adanya kesalahan klasifikasi. Jumlah data uji untuk masing-masing kelas berjumlah 38 citra, sehingga total data uji sebanyak 152 citra. Seluruh citra tersebut berhasil diklasifikasikan dengan benar dan tepat, sebagaimana dibuktikan oleh nilai akurasi sebesar 1.00. Selain itu, nilai macro average dan weighted average untuk semua metrik juga menjapai angka maksimal, yakni 1.00, yang menandakan bahwa performa model memiliki kemampuan yang sangat baik dalam mengenali dan membedakan citra berbagai jenis buah berry.

4. Kesimpulan

Artikel ini menyajikan klasifikasi buah berry menggunakan metode Residual Network. Berdasarkan data hasil penelitian dan pembahasan, dapat disimpulkan bahwa implementasi metode *deep learning* menggunakan arsitektur Residual Network (ResNet-50) mampu mengklasifikasi jenis buah berry. Dataset yang digunakan terdiri dari empat kelas buah berry, yaitu 250 *image* blackberry, 250 *image* blueberry, 250 *image* raspberry, dan 250 *image* strawberry dengan total 1000 citra yang dibagi menjadi data latih, validasi, dan data uji. Yang diawali dengan proses preprocessing berupa resize, normalisasi piksel, dan augmentasi data dilakukan untuk menyesuaikan citra dengan kebutuhan model dan meningkatkan performa pelatihan. Evaluasi performa model ResNet-50 menunjukkan performa klasifikasi yang sangat baik dengan hasil evaluasi berupa akurasi, presisi, recall, dan F1-score sebesar 100% pada data uji. Dengan tidak terdapatnya kesalahan klasifikasi antar kelas *confusion matrix*, yang berarti model ResNet-50 ini mampu mengenali setiap kelas secara akurat. Hasil ini menunjukkan bahwa pendekatan klasifikasi menggunakan ResNet-50 efektif dan dapat diandalkan dalam mengidentifikasi jenis buah berry berdasarkan fitur visual citra.

Daftar Rujukan

- [1] S. H. Nile and S. W. Park, "Edible berries: Bioactive components and their effect on human health," *Nutrition*, vol. 30, no. 2, pp. 134–144, Feb. 2014, doi: 10.1016/j.nut.2013.04.007.
- [2] R. C. Megananda and B. Gandamastuti, "Potensi nutrasetikal buah berry dalam industri pangan: Artikel review," 2023.
- [3] Ismail, Nurhikma Arifin, and Prihastinur, "Klasifikasi Kematangan Buah Naga Berdasarkan Fitur Warna Menggunakan Algoritma Multi-Class Support Vector Machine," *J. Inform. Teknol. Dan Sains*, vol. 5, no. 1, pp. 121–126, Feb. 2023, doi: 10.51401/jinteks.v5i1.2203.
- [4] A. R. Damanik, S. Annisa, A. I. Rafeli, A. S. Liana, and D. S. Prasvita, "Klasifikasi Jenis Buah Cherry Menggunakan Support Vector Machine (SVM) Berdasarkan Tekstur dan Warna Citra," *Pros. Semin. Nas. Mhs. Bid. Ilmu Komput. Dan Apl.*, vol. 3, no. 1, Art. no. 1, Oct. 2022.
- [5] R. S. Ilhamy and U. P. Sanjaya, "Algoritma K-Nearest Neighbors (KNN) untuk Klasifikasi Citra Buah Pisang dengan Ekstraksi Ciri Gray Level Co-Occurrence," *J. Telematika*, vol. 17, no. 2, pp. 88–93, Feb. 2023, doi: 10.61769/telematika.v17i2.525.
- [6] H. R. Cahyaputra and R. Rahmadewi, "KLASIFIKASI TINGKAT KEMATANGAN BUAH PAPRIKA MENGGUNAKAN METODE K-NEAREST NEIGHBOR BERDASARKAN WARNA RGB MELALUI APLIKASI MATLAB," *JIPJ. Ilm. Penelit. Dan Pembelajaran Inform.*, vol. 9, no. 1, pp. 242–249, Feb. 2024, doi: 10.29100/jipi.v9i1.4440.
- [7] F. Santoso and E. Hartati, "Penggunaan Algoritma Random Forest Dalam Klasifikasi Buah Segar Dan Busuk," *J. Algoritme*, vol. 3, no. 1, pp. 133–140, Oct. 2022, doi: 10.35957/algoritme.v3i1.3404.
- [8] A. Putra Argadinata, D. Abdul Fatah, and H. Sukri, "KLASIFIKASI KUALITAS BUAH APEL MENGGUNAKAN METODE RANDOM FOREST," *JATI J. Mhs. Tek. Inform.*, vol. 9, no. 2, pp. 2016–2022, Mar. 2025, doi: 10.36040/jati.v9i2.12854.
- [9] S. Juliansyah and A. D. Laksito, "Klasifikasi Citra Buah Pir Menggunakan Convolutional Neural Network," vol. 11, no. 1, pp. 65–72, Apr. 2021, doi: 10.22441/incomtech.v11i1.10185.
- [10] J. D. Marfianto and M. Akbar, "Klasifikasi Jenis Buah Nanas Menggunakan Convolution Neural Network," *J. Transform.*, vol. 21, no. 1, Art. no. 1, Aug. 2023, doi: 10.26623/transformatika.v21i2.6369.
- [11] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agric.*, vol. 147, pp. 70–90, Apr. 2018, doi: 10.1016/j.compag.2018.02.016.
- [12] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," Dec. 10, 2015, *arXiv: arXiv:1512.03385*. doi: 10.48550/arXiv.1512.03385.
- [13] A. Faaizah and M. Akbar, "Sistem Klasifikasi Buah Berry Menggunakan Image Berry Dengan Metode Learning Vector Quantization," *IKRA-ITH Inform. J. Komput. Dan Inform.*, vol. 7, no. 3, pp. 85–92, Nov. 2023, doi: 10.37817/ikraith-informatika.v7i3.3066.
- [14] A. Ridhovan and A. Suharso, "Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum," *JIPJ. Ilm. Penelit. Dan Pembelajaran Inform.*, vol. 7, no. 1, pp. 58–65, Feb. 2022, doi: 10.29100/jipi.v7i1.2410.
- [15] N. Nurlinda, E. Hasmin, and J. Jufri, "Deteksi Penyakit Rumput Laut Dengan Residual Neural Network," *J. Tek. Inf. Dan Komput. Tekinkom*, vol. 7, no. 2, p. 637, Dec. 2024, doi: 10.37600/tekinkom.v7i2.1621.
- [16] M. I. Anshori, M. A. Zafar Sidiq, R. A. Yaqin, and I. W. Prasetyo Agung, "Klasifikasi Jenis Jerawat Secara Otomatis Dengan Convolutional Neural Network Menggunakan Arsitektur Resnet-50," *J. Manaj. Inform. JAMIKA*, vol. 15,

- no. 1, pp. 73–84, Apr. 2025, doi: 10.34010/jamika.v15i1.13712.
- [17] W. Setiawan, “Klasifikasi Citra Histopatologi Kanker Payudara menggunakan Data Resampling Random dan Residual Network,” *J. Sist. Inf. BISNIS*, vol. 11, no. 1, pp. 70–77, Aug. 2021, doi: 10.21456/vol11iss1pp70-79.
- [18] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” 2015, *arXiv*. doi: 10.48550/ARXIV.1512.03385.
- [19] S. Sathyanarayanan, “Confusion Matrix-Based Performance Evaluation Metrics,” *Afr. J. Biomed. Res.*, pp. 4023–4031, Nov. 2024, doi: 10.53555/AJBR.v27i4S.4345.
- [20] Ž. Đ. Vujovic, “Classification Model Evaluation Metrics,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 12, no. 6, 2021, doi: 10.14569/ijacsa.2021.0120670.