

IMPLEMENTASI CNN RESNET50 UNTUK MENDETEKSI KUALITAS BUAH DAN SAYURAN DI PASAR TRADISIONAL

Qonita Salsabila Ainal Wasilah¹, Martanto², Arif Rinaldi Dikananda³, Dede Rohman⁴

^{1,4} Teknik Informatika, STMIK IKMI Cirebon

² Manajemen Informatika, STMIK IKMI Cirebon

³ Rekayasa Perangkat Lunak, STMIK IKMI Cirebon

Jl. Perjuangan No.10B, Kota Cirebon, Indonesia

qonitaso87@gmail.com

ABSTRAK

Kualitas dan kesegaran produk merupakan faktor penting dalam industri ritel yang mempengaruhi kepuasan pelanggan dan potensi kerugian akibat produk yang tidak layak. Pendekatan manual sering kali tidak efisien dan subjektif, sehingga diperlukan solusi otomatis yang lebih akurat dan konsisten. Dalam konteks ini, *Convolutional Neural Network (CNN) ResNet50* terbukti efektif dalam mengenali pola visual pada gambar, termasuk mendeteksi perubahan visual seperti warna dan tekstur yang berkaitan dengan kualitas produk. Penelitian ini bertujuan mengoptimalkan deteksi kesegaran produk menggunakan model *CNN ResNet50*. Dataset yang digunakan terdiri dari gambar produk segar, yang dibagi menjadi data pelatihan, validasi, dan pengujian. Proses penelitian mencakup pra-pemrosesan data, pelatihan model, dan pengujian untuk mengevaluasi kinerja model. Hasil menunjukkan bahwa model *CNN ResNet50* mencapai akurasi 84,43% dalam mendeteksi kualitas produk pada data uji. Akurasi ini menunjukkan kemampuan model untuk menggeneralisasi data baru dan mengurangi potensi kesalahan manusia. Temuan ini menunjukkan bahwa *CNN ResNet50* memiliki potensi besar untuk diterapkan dalam manajemen produk segar di industri ritel, meningkatkan efisiensi operasional, dan meminimalkan kerugian akibat produk yang rusak atau tidak layak.

Kata kunci : *Convolutional Neural Network*, Deteksi Kesegaran, Pengenalan Gambar, *ResNet50*.

1. PENDAHULUAN

Selama beberapa dekade terakhir, kemajuan dalam teknologi informasi telah membawa inovasi signifikan di berbagai sektor, termasuk industri ritel. Kemajuan dalam kecerdasan buatan (*artificial intelligence / AI*) dan pembelajaran mesin (*machine learning*) telah memungkinkan otomatisasi proses yang sebelumnya dilakukan secara manual, seperti mendeteksi kualitas produk. *Convolutional Neural Network (CNN)*, sebuah teknik pembelajaran mendalam yang dikenal efektif dalam menganalisis data visual, telah diterapkan secara luas dalam berbagai aplikasi mulai dari pengenalan wajah hingga deteksi objek. Belakangan ini, aplikasi *CNN* dalam kebutuhan industri spesifik semakin berkembang, terutama dalam sistem penilaian kualitas [1]- [2].

Dalam industri ritel, khususnya untuk produk segar seperti buah dan sayur, kualitas dan kesegaran sangat krusial karena secara langsung mempengaruhi kepuasan pelanggan dan daya saing bisnis [3].

Penanganan yang buruk atau umur simpan yang pendek dapat menyebabkan penurunan kualitas yang signifikan, merusak reputasi toko, dan mengikis kepercayaan konsumen [4].

Saat ini, deteksi kesegaran masih sebagian besar dilakukan secara manual, yang tidak hanya memakan waktu tetapi juga sangat subjektif, yang mengarah pada inkonsistensi dalam evaluasi produk. Hal ini menciptakan peluang untuk sistem otomatis yang lebih andal, konsisten, dan efisien [5].

Permintaan yang semakin tinggi terhadap produk segar berkualitas, terutama di daerah perkotaan seperti

Cirebon, telah mendorong bisnis ritel untuk berinovasi dalam manajemen stok dan proses pemantauan kualitas [6].

Sistem deteksi kesegaran otomatis menggunakan *CNN* diharapkan dapat memberikan solusi efektif untuk memastikan buah dan sayur yang dijual tetap segar dan berkualitas tinggi, sehingga meningkatkan kepuasan pelanggan. Oleh karena itu, penelitian ini berfokus pada optimalisasi sistem deteksi kesegaran berbasis *CNN*, dengan studi kasus pada toko buah dan sayur di Cirebon.

Meskipun kemajuan teknologi menjanjikan peningkatan efisiensi di sektor ritel, tantangan tetap ada, terutama dalam penerapan teknologi untuk deteksi kualitas dan kesegaran [1].

Salah satu masalah utama yang dihadapi pengecer yang menangani produk segar adalah ketidakpastian dalam menjaga standar kualitas yang konsisten [7]- [8].

Proses evaluasi manual tidak hanya subjektif tetapi juga rentan terhadap kesalahan dan inkonsistensi, yang sering mengarah pada pemborosan atau produk yang kurang baik sampai ke konsumen. Banyak pengecer masih mengandalkan metode tradisional untuk pemantauan stok dan kualitas, yang menghambat efisiensi operasional dan meningkatkan biaya.

Meskipun penelitian mengenai penerapan teknologi pembelajaran mesin dan pengolahan citra untuk deteksi kualitas produk segar telah mendapatkan perhatian dalam beberapa tahun terakhir, masih terdapat kekurangan dalam literatur dan implementasi

praktis. Tren terbaru menunjukkan bahwa *CNN* memiliki potensi besar untuk mengatasi tantangan ini berkat kemampuan deteksi objek yang tepat dan analisis visual yang canggih. Namun, adopsinya di industri ritel, terutama di kota-kota kecil seperti Cirebon, masih jarang. Oleh karena itu, penting untuk mengeksplorasi bagaimana teknologi ini dapat diadaptasi dan dioptimalkan untuk memenuhi kebutuhan spesifik di lingkungan praktis.

Penelitian ini bertujuan untuk mengatasi tantangan deteksi kesegaran buah dan sayuran di lingkungan ritel dengan mengeksplorasi penerapan Convolutional Neural Network (CNN). Fokus utama dari penelitian ini adalah implementasi praktis yang bertujuan untuk meningkatkan efisiensi dan kualitas pelayanan di industri ritel. Oleh karena itu, penelitian ini tidak hanya bertujuan untuk memberikan kontribusi terhadap peningkatan operasional di sektor ritel, tetapi juga untuk mengisi kekosongan dalam literatur yang ada mengenai penerapan kecerdasan buatan (AI) dalam operasional dunia nyata. Dalam upaya mencapai tujuan tersebut, penelitian ini memilih untuk menggunakan arsitektur CNN ResNet50. Pemilihan ResNet50 didasarkan pada kemampuannya untuk mengatasi masalah *vanishing gradient* yang sering ditemui pada jaringan neural yang lebih dalam. Dengan pendekatan *residual learning*, ResNet50 mampu mempelajari representasi fitur visual yang lebih mendalam tanpa mengorbankan akurasi atau performa model. Kemampuan ResNet50 dalam mengenali pola visual yang kompleks menjadikannya sangat cocok untuk aplikasi deteksi kesegaran, di mana tingkat akurasi dan efisiensi sangat diperlukan untuk memenuhi tuntutan operasional yang cepat dan dinamis di industri ritel.

2. TINJAUAN PUSTAKA


Deteksi kesegaran buah dan sayuran merupakan salah satu tantangan utama dalam industri pertanian dan ritel, di mana kualitas produk sangat berpengaruh terhadap kepuasan konsumen dan efisiensi operasional. Berbagai metode telah dikembangkan untuk mengidentifikasi kualitas produk, salah satunya adalah penggunaan *Convolutional Neural Network* (CNN), sebuah teknik dalam kecerdasan buatan yang memanfaatkan gambar untuk melakukan klasifikasi dan deteksi objek.

2.1. Convolutional Neural Networks (CNN) untuk Klasifikasi Gambar

CNN adalah salah satu jenis jaringan saraf tiruan yang khusus dirancang untuk memproses data berbentuk gambar. Seiring dengan kemajuan teknologi, CNN telah banyak diterapkan dalam berbagai bidang, termasuk pengenalan wajah, deteksi objek, dan analisis medis. CNN menggunakan lapisan-lapisan konvolusi untuk mengekstraksi fitur dari gambar, seperti tepi, sudut, dan pola tekstur. Salah satu arsitektur CNN yang sering digunakan dalam tugas klasifikasi gambar adalah *ResNet* (Residual

Networks), yang memiliki kemampuan untuk menangani masalah *vanishing gradient* dan memungkinkan pelatihan model yang lebih dalam dan lebih akurat [2].

Model *ResNet50*, yang terdiri dari 50 lapisan, telah terbukti efektif dalam berbagai tugas klasifikasi gambar, termasuk deteksi kualitas buah dan sayuran. Berikut adalah gambar arsitektur CNN secara umum:



Gambar 1. Arsitektur CNN secara umum

2.2. Deteksi Kualitas Buah dan Sayuran Menggunakan Deep Learning

Beberapa penelitian telah menunjukkan keberhasilan penggunaan deep learning, khususnya CNN, dalam mendeteksi kualitas buah dan sayuran. Penelitian ini menunjukkan bahwa model CNN dapat digunakan untuk mengidentifikasi kualitas buah seperti apel, pisang, dan jeruk dengan akurasi yang tinggi. Teknik ini memungkinkan deteksi cacat, perubahan warna, dan kerusakan lainnya yang sulit dilakukan dengan metode tradisional. Selain itu, penggunaan CNN memberikan keunggulan dalam hal akurasi dan kecepatan, terutama ketika dataset yang digunakan cukup besar dan beragam [5].

2.3. Data Augmentation untuk Peningkatan Kinerja Model

Dalam meningkatkan kinerja model dan mencegah overfitting, teknik *data augmentation* digunakan untuk memperbanyak variasi data pelatihan tanpa menambah dataset secara manual. Teknik ini termasuk rotasi, pembalikan, zooming, dan perubahan kecerahan gambar. Penelitian ini menunjukkan bahwa *data augmentation* dapat meningkatkan generalisasi model dengan memperkenalkan variasi yang lebih besar dalam data pelatihan, yang penting untuk tugas klasifikasi gambar, termasuk deteksi kualitas buah dan sayuran. Teknik ini sangat berguna ketika dataset yang tersedia terbatas atau tidak cukup beragam untuk mencakup semua kemungkinan kondisi dunia nyata [12].

2.4. Tantangan dalam Deteksi Kualitas Buah dan Sayuran

Meskipun CNN telah terbukti efektif dalam deteksi kualitas, terdapat tantangan yang perlu diatasi. Faktor-faktor seperti kualitas gambar, kondisi pencahayaan, dan variasi tekstur buah dan sayuran dapat memengaruhi akurasi model. Penelitian ini menunjukkan bahwa pencahayaan yang buruk dan latar belakang yang tidak konsisten dapat menyebabkan kesalahan dalam klasifikasi. Selain itu, cacat yang halus atau perubahan warna yang minimal sering kali sulit dideteksi oleh model, terutama jika

dataset pelatihan tidak cukup representatif untuk variasi yang ada dalam produk segar dan rusak [1].

3. METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen untuk mengevaluasi efektivitas *Convolutional Neural Network (CNN) ResNet50* dalam mendeteksi kesegaran buah dan sayuran [9]- [11]. Penelitian dilakukan sebagai studi kasus di sebuah toko buah dan sayuran yang terletak di Cirebon.

Data yang digunakan dalam penelitian ini diperoleh dari dua sumber utama: dataset primer dan sekunder. Data primer diperoleh dengan menangkap gambar buah dan sayuran secara langsung di toko menggunakan kamera berkualitas tinggi. Gambar diambil di bawah berbagai kondisi pencahayaan, sudut pengambilan, dan tingkat kesegaran, seperti segar, semi-segar, dan rusak, untuk mencerminkan skenario dunia nyata secara akurat. Data sekunder diperoleh dari platform Kaggle, dengan memanfaatkan dataset "Fruit and Vegetable Image Recognition" [12].

Dataset ini menyediakan ribuan gambar berkualitas tinggi yang telah dilabeli, mewakili berbagai jenis buah dan sayuran, yang menjadi dasar untuk pelatihan dan pengujian model [13].

Dataset tersebut menjalani pra-pemrosesan sebelum digunakan untuk pelatihan. Gambar diubah ukurannya menjadi 224x224 piksel untuk memenuhi persyaratan input dari arsitektur *ResNet50* [14]- [15].

Normalisasi dilakukan untuk menskalakan nilai piksel dalam rentang [0,1], memastikan konsistensi di seluruh dataset. Teknik augmentasi data, termasuk rotasi acak, pembalikan horizontal, zooming, dan penyesuaian kecerahan, diterapkan untuk meningkatkan keberagaman dataset dan mengurangi risiko *overfitting* [16].

Setelah pra-pemrosesan, dataset dibagi menjadi tiga subset untuk memfasilitasi proses pelatihan dan evaluasi. Set pelatihan terdiri dari 70% data dan digunakan untuk mengoptimalkan parameter model [17].

Set validasi, yang terdiri dari 15% data, digunakan selama pelatihan untuk memantau kinerja dan mencegah *overfitting*. Set pengujian, yang menyusun 15% sisa data, digunakan untuk mengevaluasi kinerja akhir model. Struktur pembagian dataset dan kegiatan yang dilakukan dirangkum dalam Tabel 1.

Tabel 1. Tahapan dan Kegiatan Penelitian

Tahapan	Kegiatan	Deskripsi
Pengumpulan Data	Data primer dan sekunder	Gambar yang diambil di toko dan pengunduhan dataset Kaggle.
Pra-pemrosesan Data	Penyusunan ukuran, normalisasi, augmentasi	Menyiapkan gambar agar memenuhi persyaratan model <i>ResNet50</i> .

Tahapan	Kegiatan	Deskripsi
Pembagian Dataset	Pelatihan, validasi, pengujian	Pembagian dataset menjadi 70% pelatihan, 15% validasi, dan 15% pengujian.
Pelatihan Model	Penyesuaian model <i>ResNet50</i>	Mengoptimalkan parameter model <i>ResNet50</i> menggunakan set pelatihan.
Evaluasi Model	Akurasi, presisi, recall, F1-score	Mengevaluasi kinerja model menggunakan metrik standar pada set pengujian.
Penerapan Model	Klasifikasi waktu nyata atau integrasi sistem	Menyebarkan model terlatih untuk deteksi kualitas buah dan sayuran di toko.

Model *ResNet50* dilatih menggunakan set pelatihan, di mana model belajar mengenali pola visual yang menunjukkan kesegaran, seperti warna dan tekstur. Optimizer *Adam* dengan laju pembelajaran 0,001 digunakan, dan fungsi kerugian *cross-entropy* digunakan untuk meminimalkan kesalahan klasifikasi. Selama pelatihan, data validasi digunakan untuk memantau kemajuan dan menyempurnakan model, memastikan kinerja optimal dan menghindari *overfitting* [18].

Kinerja model dievaluasi menggunakan metrik standar, termasuk akurasi, presisi, recall, dan *F1-score*. Akurasi mengukur proporsi sampel yang diklasifikasikan dengan benar, presisi menilai kebenaran prediksi kesegaran, recall mengevaluasi tingkat deteksi sampel segar yang sebenarnya, dan *F1-score* memberikan ukuran seimbang antara presisi dan recall [19]- [20].

Metode sampling yang digunakan dalam penelitian ini adalah *purposive sampling*, yang memastikan relevansi dengan tujuan penelitian. Dataset Kaggle terdiri dari 800 gambar, yang dibagi rata di antara berbagai kategori kesegaran dan kerusakan. Data ini dilengkapi dengan gambar primer yang diambil dari toko buah dan sayuran di Cirebon, memungkinkan temuan untuk diterapkan secara lokal.

Beberapa keterbatasan diidentifikasi selama penelitian ini. Dataset terbatas pada buah dan sayuran yang ada dalam koleksi dataset Kaggle dan data primer, yang memerlukan pelatihan lebih lanjut untuk kategori tambahan. Selain itu, faktor lingkungan seperti ketidaksesuaian pencahayaan dan kualitas kamera di pengaturan ritel dapat memengaruhi akurasi deteksi. Keterbatasan ini menekankan perlunya penelitian lebih lanjut untuk mengadaptasi model untuk aplikasi yang lebih luas dan konteks yang beragam.

4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan temuan dari implementasi dan evaluasi model *Convolutional Neural Network (CNN) ResNet50* untuk mendeteksi kesegaran buah

dan sayuran. Penelitian ini mencakup pra-pemrosesan data, pelatihan model, validasi, pengujian, dan analisis kinerja berdasarkan metrik utama seperti akurasi, presisi, dan recall. Temuan-temuan ini memberikan dasar untuk mengevaluasi efektivitas model sebagai solusi otomatis, efisien, dan akurat.

4.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini mencakup delapan jenis buah dan sayuran: apel, pisang, mangga, dukus, brokoli, kale, sawi, dan kembang kol. Setiap jenis diberi label dalam dua kelas, "Segar" dan "Rusak", dengan distribusi gambar yang seimbang yaitu 50 gambar per kelas, menghasilkan 800 gambar total. Setelah dataset dibagi menjadi set pelatihan (70%), validasi (15%), dan pengujian (15%), distribusi yang seimbang memastikan keadilan selama pelatihan, seperti yang ditunjukkan pada Tabel 2.

Tabel 2. Deskripsi Dataset

Buah/Sayuran	Segar (Gambar)	Rusak (Gambar)
Apel	50	50
Pisang	50	50
Mangga	50	50
Dukus	50	50
Brokoli	50	50
Kale	50	50
Sawi	50	50
Kembang Kol	50	50

Untuk memberikan representasi visual, Gambar 1 menunjukkan contoh gambar dari dataset untuk kategori "Segar" dan "Rusak". Gambar-gambar ini menyoroti fitur visual yang membedakan, seperti warna dan tekstur, yang dipelajari model selama pelatihan.



Gambar 2. Contoh Gambar Buah dan Sayuran Segar dan Rusak

4.2. Pra-pemrosesan Data

Dataset melalui beberapa langkah persiapan untuk memastikan kompatibilitas dengan model *ResNet50* dan meningkatkan kualitasnya untuk pelatihan, validasi, dan pengujian.

4.2.1. Resize Gambar

Setiap gambar dalam dataset diubah ukurannya menjadi 224x224 piksel untuk mencocokkan ukuran input yang diperlukan oleh model *ResNet50*. Ukuran ini merupakan standar untuk jaringan syaraf konvolusional, terutama untuk arsitektur *ResNet*. Dengan mengubah ukuran gambar ke dimensi seragam, model dapat memproses data dengan efisien

tanpa kehilangan detail penting yang dibutuhkan untuk klasifikasi.

4.2.2. Normalisasi Gambar

Setelah pengubahan ukuran, langkah berikutnya adalah normalisasi. Proses ini melibatkan pembagian setiap nilai piksel dengan 255, menskalakan nilai piksel ke rentang $[0,1]$. Normalisasi menstabilkan distribusi piksel dan membuat gambar lebih mudah diproses oleh model.

4.2.3. Augmentasi Data

Dalam meningkatkan keragaman data pelatihan dan mencegah *overfitting*, berbagai teknik augmentasi data diterapkan khusus untuk set pelatihan. Ini termasuk rotasi acak hingga 30 derajat, pembalikan horizontal, dan zooming hingga 20%. Selain itu, pergeseran horizontal dan vertikal hingga 10% digunakan untuk memvariasikan posisi objek dalam frame, sementara penyesuaian kecerahan mensimulasikan kondisi pencahayaan yang berbeda.

Gambar 2 menggambarkan contoh apel segar dan rusak dari dataset. Gambar di sebelah kiri menunjukkan apel segar, yang ditandai dengan warna cerah dan tekstur yang utuh. Gambar di sebelah kanan menampilkan apel rusak dengan perubahan warna yang terlihat dan kerusakan permukaan.



Gambar 3. Gambar Sampel Apel Segar dan Rusak

Gambar 3 dibawah ini menunjukkan hasil dari proses augmentasi yang diterapkan pada dataset. Contoh-contoh tersebut mencakup gambar yang diputar, dibalik, dan di-zoom, yang menunjukkan keragaman yang diperkenalkan ke dalam set pelatihan. Variasi ini membantu model untuk mempelajari pola dari berbagai sudut pandang dan meningkatkan kemampuan generalisasi model.



Gambar 4. Gambar yang Diperbesar dengan Rotasi, Pembalikan, dan Zooming

Langkah-langkah praproses dan augmentasi ini memastikan bahwa dataset tersebut komprehensif dan beragam, memungkinkan model *ResNet50* untuk

belajar secara efektif dan menangani berbagai situasi dunia nyata.

4.3. Pembagian Dataset

Dataset yang digunakan dalam penelitian ini dibagi menjadi tiga subset: pelatihan (train), validasi (validation), dan pengujian (test). Setiap subset dialokasikan secara proporsional untuk memastikan pelatihan dan evaluasi model yang optimal.

4.3.1. Set Pelatihan

Tujuh puluh persen (70%) dari total gambar dialokasikan untuk set pelatihan. Subset ini digunakan untuk melatih model *ResNet50*, memungkinkan model untuk mempelajari fitur visual seperti warna, tekstur, dan pola dari berbagai kategori buah dan sayuran.

4.3.2. Set Validasi

Lima belas persen (15%) dari dataset disisihkan untuk set validasi. Subset ini digunakan untuk mengevaluasi kinerja model selama proses pelatihan dan memastikan generalisasi ke data yang belum pernah dilihat.

4.3.3. Set Pengujian

Lima belas persen (15%) dari dataset dialokasikan untuk set pengujian. Subset ini digunakan secara eksklusif untuk mengukur kinerja akhir model setelah pelatihan dan validasi selesai.

4.3.4. Pelatihan Model

Model *ResNet50* yang digunakan dalam penelitian ini merupakan arsitektur Convolutional Neural Network (CNN) yang terdiri dari 50 lapisan, dengan pendekatan residual learning untuk mengatasi masalah vanishing gradient yang sering terjadi pada jaringan yang lebih dalam. Dengan adanya skip connections, informasi dapat melompat antar lapisan, memudahkan pelatihan dan meningkatkan akurasi model. Selama pelatihan, gambar yang telah diproses (resize dan normalisasi) dimasukkan ke dalam model. Lapisan konvolusi pertama akan mengekstraksi fitur dasar seperti tepi dan tekstur dari gambar. Kemudian, aktivasi ReLU diterapkan untuk menambahkan non-linearitas, diikuti oleh proses pooling untuk mengurangi dimensi spasial dan mempercepat komputasi. Proses ini diulang melalui beberapa blok residual, yang memungkinkan model untuk mempelajari pola yang lebih dalam tanpa mengorbankan performa. Proses pelatihan ini memungkinkan model untuk belajar secara efektif dari data, menghasilkan akurasi yang tinggi dan mengurangi risiko overfitting pada data yang belum pernah dilihat sebelumnya.

Model *ResNet50* dilatih selama 50 epoch menggunakan optimizer *Adam* dengan laju pembelajaran 0,001 dan fungsi kerugian *cross-entropy* kategorikal. Akurasi pelatihan dan validasi meningkat secara bertahap selama epoch, sementara kerugian secara konsisten menurun, menunjukkan pembelajaran

yang efektif dan minimal *overfitting*. Akurasi validasi mencapai 81,21% pada epoch ke-50, dengan kerugian validasi berkurang menjadi 0,0676.

Tabel 3. Metrik Pelatihan dan Validasi pada Epoch Terpilih

Epoch	Akurasi Pelatihan	Kerugian Pelatihan	Akurasi Validasi	Kerugian Validasi
1	12,06%	0,7564	7,27%	0,7004
10	32,25%	0,2783	59,39%	0,1694
20	54,27%	0,1665	66,06%	0,1237
30	70,60%	0,1206	74,55%	0,088
40	80,07%	0,0914	74,55%	0,0771
50	84,38%	0,0661	81,21%	0,0676

Berikut adalah persamaan yang digunakan untuk menghitung nilai-nilai pada Tabel 3. Akurasi dihitung dengan rumus:

$$Accuracy = \frac{\text{Jumlah Prediksi yang Benar}}{\text{Total Sampel}} \times 100\% \quad [18]$$

Dimana jumlah prediksi yang benar adalah jumlah sampel yang diklasifikasikan dengan benar oleh model, dan total sampel adalah jumlah data yang digunakan dalam pelatihan atau validasi. Kerugian (Loss) menggunakan *cross-entropy*:

$$Loss = - \sum_{i=1}^c y_i \log(p_i) \quad [18]$$

Di mana:

- y_i adalah label aktual (1 jika benar, 0 jika tidak) untuk kelas i ,
- p_i adalah probabilitas prediksi yang diberikan oleh model untuk kelas i ,
- c adalah jumlah kelas (dalam hal ini "Segar" dan "Rusak").

Fungsi ini mengukur perbedaan antara distribusi label aktual dan distribusi prediksi model. Semakin kecil nilai kerugian, semakin baik model dalam memprediksi kelas dengan benar.

Grafik-grafik ini menggambarkan tren metrik pelatihan dan validasi selama 50 epoch. Di sebelah kiri, grafik *Training and Validation Loss* menunjukkan penurunan yang stabil pada nilai loss pelatihan dan validasi, yang mengindikasikan bahwa model secara progresif mengoptimalkan prediksinya dan meminimalkan kesalahan selama pelatihan. Kurva loss validasi mengikuti dengan dekat kurva loss pelatihan, menunjukkan generalisasi yang efektif dan minim *overfitting*.



Gambar 5. Training dan Validation Over Epochs

Di sebelah kanan, grafik *Training and Validation Accuracy* menyoroti peningkatan kedua metrik

tersebut sepanjang *epoch*. Akurasi pelatihan meningkat secara stabil, mencerminkan kemampuan model untuk belajar dari dataset. Akurasi validasi menunjukkan peningkatan yang konsisten, mencapai tingkat yang stabil setelah sekitar 40 *epoch*, yang lebih lanjut mengonfirmasi kemampuan model untuk melakukan generalisasi pada data yang belum terlihat sebelumnya. Hasil ini menunjukkan bahwa model *ResNet50* belajar dengan efektif dari data sambil mempertahankan kinerja yang tangguh pada set validasi.

4.4. Evaluasi Model


Kinerja model *ResNet50* dievaluasi menggunakan dataset pelatihan, validasi, dan pengujian. Evaluasi ini bertujuan untuk menilai kemampuan model dalam mengklasifikasikan kualitas buah dan sayuran ke dalam kategori "Segar" dan "Rusak".

Pada dataset pelatihan, yang mencakup 70% dari total gambar, model mencapai akurasi 92,4% dan loss pelatihan sebesar 0,029. Hasil ini menunjukkan bahwa model efektif mempelajari fitur pembeda dari dataset sambil mempertahankan kesalahan yang minimal. Akurasi pelatihan yang tinggi ini mengindikasikan kapasitas model untuk mengklasifikasikan sampel yang ditemui selama pelatihan dengan akurat. Dataset validasi, yang mencakup 15% dari total gambar, digunakan untuk memantau kinerja model selama pelatihan dan memastikan generalisasi pada data yang belum terlihat. Model mencapai akurasi validasi sebesar 81,2% dan loss validasi sebesar 0,069.

Meskipun sedikit lebih rendah daripada metrik pelatihan, hasil ini mengonfirmasi kemampuan model untuk menggeneralisasi pembelajarannya pada data baru tanpa overfitting yang signifikan. Perbedaan kecil antara loss pelatihan dan validasi menunjukkan bahwa model mempertahankan kinerja yang seimbang. Dataset pengujian, juga 15% dari total gambar, memberikan ukuran akhir dari kemampuan generalisasi model pada data yang sepenuhnya belum terlihat. Model mencapai akurasi pengujian sebesar 84,4% dan loss pengujian sebesar 0,057. Metrik ini menunjukkan bahwa model mempertahankan tingkat akurasi dan ketahanan yang tinggi dalam mengklasifikasikan sampel yang belum terlihat, dengan hanya kesalahan prediksi minor yang diamati.

Agar lebih memahami sifat kesalahan ini, sebuah *confusion matrix* dihasilkan untuk dataset pengujian. *Confusion matrix* memberikan rincian yang mendalam mengenai prediksi model dengan membandingkan label yang sebenarnya dengan label yang diprediksi. Elemen diagonal dari matrix mewakili jumlah sampel yang diklasifikasikan dengan benar, sementara elemen non-diagonal mewakili misclassifications. *Confusion matrix* mengungkapkan bahwa sebagian besar prediksi akurat, dengan sebagian besar sampel diklasifikasikan dengan benar ke dalam kategori "Segar" atau "Rusak" mereka masing-masing. Namun, beberapa kesalahan tercatat, seperti false positives, di

mana sampel "Rusak" diprediksi sebagai "Segar," dan false negatives, di mana sampel "Segar" diklasifikasikan sebagai "Rusak." Kesalahan-kesalahan ini mungkin disebabkan oleh kesamaan visual yang halus atau variasi dalam pencahayaan dan tekstur.




Gambar 6. *Confusion Matrix* untuk Dataset Pengujian

Gambar ini menunjukkan distribusi prediksi model untuk dataset pengujian. Elemen diagonal mencerminkan jumlah klasifikasi yang benar, sementara elemen non-diagonal menyoroti misclassifications. Model menunjukkan kinerja yang kuat, dengan sebagian besar prediksi sesuai dengan label yang benar, meskipun beberapa kesalahan teramati.

Secara keseluruhan, model *ResNet50* mencapai akurasi tinggi di seluruh dataset, yang mengindikasikan kemampuannya untuk mengklasifikasikan kualitas buah dan sayuran dengan andal. Meskipun *confusion matrix* menyoroti area yang perlu perbaikan, seperti mengurangi misclassifications, hasil keseluruhan menunjukkan potensi model untuk aplikasi praktis dalam sistem kontrol kualitas otomatis. Optimasi lebih lanjut, seperti memperluas dataset dan meningkatkan teknik augmentasi data, dapat meningkatkan ketahanan dan akurasi model di aplikasi mendatang.

4.5. Penerapan Model

Setelah model *ResNet50* dilatih dan dievaluasi menggunakan dataset pengujian, sebuah visualisasi prediksi dilakukan untuk lebih memahami bagaimana model mengklasifikasikan kualitas buah dan sayuran ke dalam dua kategori: "Segar" dan "Rusak." Langkah ini melibatkan pemilihan acak gambar dari dataset pengujian, yang telah diproses sebelumnya (d disesuaikan ukuran dan dinormalisasi) sebelum dimasukkan ke dalam model. Prediksi ini memberikan wawasan tentang seberapa baik model mengidentifikasi fitur visual utama untuk klasifikasi.



Gambar 7. Hasil Prediksi Sampel untuk Apel

Gambar ini menampilkan prediksi model untuk dua gambar apel dari dataset pengujian. Gambar sebelah kiri mewakili apel yang diklasifikasikan sebagai "Segar," dengan warna cerah dan tanpa cacat yang terlihat. Gambar sebelah kanan menunjukkan apel yang diklasifikasikan sebagai "Rusak," dengan perubahan warna dan tanda-tanda kerusakan yang terlihat pada permukaannya. Hasil ini menunjukkan kemampuan model untuk membedakan dengan akurat antara produk segar dan rusak.

Berikut adalah perbandingan antara data asli dan prediksi model untuk delapan sampel buah dan sayuran, termasuk satu prediksi yang salah, sebagai bagian dari evaluasi kinerja model.

Tabel 3. Hasil perbandingan antara data asli dan prediksi model

No	Nama Buah	Data Asli	Prediksi
1	Duku	Rusak	Rusak
2	Kangkung	Baik	Baik
3	Apel	Rusak	Baik
4	Pisang	Baik	Baik
5	Brokoli	Rusak	Rusak
6	Sawi	Rusak	Rusak
7	Kembangkol	Baik	Baik
8	Mangga	Baik	Rusak

Prediksi ini juga menunjukkan potensi model untuk aplikasi dunia nyata, seperti sistem pemilahan otomatis untuk kontrol kualitas. Meskipun model menunjukkan kinerja yang baik dalam membedakan kategori, kesalahan sesekali, seperti sensitivitas terhadap perubahan warna yang halus, menunjukkan area untuk perbaikan lebih lanjut, termasuk memperkaya dataset dan menerapkan teknik augmentasi yang lebih maju. Visualisasi ini menegaskan kapasitas model untuk menggeneralisasi pembelajarannya pada sampel yang belum terlihat, memberikan kepercayaan dalam penerapannya untuk tugas praktis di industri ritel dan pertanian.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa model Convolutional Neural Network (CNN) dengan arsitektur ResNet50 efektif dalam mendeteksi kesegaran buah dan sayuran. Model ini berhasil mencapai akurasi pengujian sebesar 84,4% dengan kerugian (loss) 0,057, yang menunjukkan kemampuan model untuk membedakan produk segar dan rusak

dengan baik. Meskipun demikian, faktor-faktor seperti kualitas gambar, pencahayaan, dan variasi cacat visual mempengaruhi kinerja model, terutama pada kasus dengan perubahan warna yang halus atau pencahayaan yang buruk. Penerapan model ini di industri ritel menunjukkan potensi besar untuk meningkatkan efisiensi operasional, mengurangi limbah, dan memastikan kualitas produk. Model ini dapat digunakan untuk sistem pemilahan otomatis, yang akan mempercepat proses kontrol kualitas di sektor ritel.

Untuk pengembangan lebih lanjut, disarankan untuk memperluas dataset dengan variasi yang lebih banyak, serta menerapkan teknik augmentasi data yang lebih canggih guna meningkatkan kinerja model. Selain itu, eksplorasi model lain seperti EfficientNet dan integrasi teknologi berbasis IoT untuk deteksi waktu nyata juga dapat memperkuat aplikasi model ini di sepanjang rantai pasokan. Model ini juga memiliki potensi untuk diterapkan di sektor pertanian guna membantu petani dalam memantau kesegaran produk di lapangan atau pasca-panen, yang dapat berkontribusi pada peningkatan efisiensi dan kualitas produk di industri pertanian.

DAFTAR PUSTAKA

- [1] S. D. P. Bahari and U. Latifa, "Klasifikasi Buah Segar Menggunakan Teknik Computer Vision untuk Pendeteksian Kualitas dan Kesegaran Buah," JATI (Jurnal Mahasiswa Teknik Informatika), 2023.
- [2] R. Namruddin, M. Mirfan, and I. Irfandi, "Klasifikasi Kesegaran Buah Apel Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Android," Pros. SISFOTEK, 2023.
- [3] A. Rivalzo, "Klasifikasi Tingkat Kematangan Buah Tomat Menggunakan Metode Convolutional Neural Network pada Pengolahan Citra Digital," eprints.upnyk.ac.id, 2023.
- [4] P. N. Safitri, *Analisis Strategi Penjualan Produk Menggunakan Association Rule dengan Algoritma Apriori (Studi Kasus: Penjualan Produk Pamela Satu Supermarket)*, dspace.uui.ac.id, 2022.
- [5] L. Lusiana, A. Wibowo, and T. K. Dewi, "Implementasi Algoritma Deep Learning You Only Look Once (YOLOv5) untuk Deteksi Buah Segar dan Busuk," Paspalum J. Ilm., 2023.
- [6] S. A. Azis and Z. Zulaika, "Implementasi Teknologi Image Processing untuk Identifikasi Kandungan Formalin dan Kesegaran Daging Sapi," repository.polman-babel.ac.id, 2024.
- [7] L. Fadhilah and W. Hadikurniawati, "Deteksi Jenis Buah Mangga Menggunakan Metode CNN (Convolutional Neural Network) Berbasis Android Secara Real-Time," INTECOMS J., 2024.
- [8] A. Sutikno, S. D. Pohan, and A. Aljabar, "Klasifikasi Penyakit pada Sawi Pakcoy dengan

- Menggunakan Metode Convolutional Neural Network (CNN)," J. TIKA, 2024.
- [9] J. R. Ziliwu, G. C. Setyawan, and ..., "Penerapan ESP32-CAM dan TinyML dalam Klasifikasi Gambar Buah dan Sayuran," *Jutisi J. Ilm.*, 2024.
- [10] N. Nurafiya and A. Y. Chandra, "Analisis Performa Akurasi Klasifikasi Citra Jenis Sayur Salada Menggunakan Arsitektur VGG16, Xception, dan NasNetMobile," *J. Media Inform.*, 2024.
- [11] S. A. Prasetya, M. Mihuandayani, and ..., "Implementasi Convolutional Neural Network untuk Klasifikasi Tingkat Kematangan Buah Nanas Menggunakan YOLOv8," *Sci.*, 2024.
- [12] R. B. Tosi, H. Dorothea Mbura, and ..., "Implementasi CNN dalam Mengidentifikasi Kematangan Cabai Berdasarkan Warna," *Indones. J.*, 2024.
- [13] A. Faqih, F. A. Pratama, and M. A. Assalihee, "Comparison of Pneumonia Detection Using Convolutional Neural Network (CNN) Method on Balanced and Imbalanced Datasets," vol. 3, 2024.
- [14] T. Yuniati and M. F. Sidiq, "Literature Review: Legalisasi Dokumen Elektronik Menggunakan Tanda," *J. RESTI*, vol. 4, no. 6, pp. 1058–1069, 2020.
- [15] N. S. N. Safitr, "Implementasi Deep Learning Mengklasifikasi Kematangan Buah Merah Menggunakan Algoritma Convolutional Neural Network," *repository.um-sorong.ac.id*, 2024.
- [16] M. S. Hawibowo, *Aplikasi Pengklasifikasi Kematangan Pepaya Menggunakan Metode CNN Berbasis Android*, *dspace.uui.ac.id*, 2024.
- [17] N. W. Utami, I. N. Purnama, and I. P. R. Prajna, "Klasifikasi Tanaman Upakara Adat Hindu di Kebun Raya Eka Karya Bali Menggunakan Algoritma Convolutional Neural Network," *J. Inform. Teknol.*, 2023.
- [18] H. A. Fauzan, *Identifikasi Penyakit pada Tanaman Selada Menggunakan Algoritma Convolutional Neural Network (CNN)*, *digilib.uinsgd.ac.id*, 2023.
- [19] Y. Sutanto, C. P. H., D. Wahyuni, and Y. Arman, "Implementasi Convolutional Neural Network dalam Menentukan Tingkat Kematangan Jeruk Siam Pontianak Berdasarkan Citra," *Positron*, vol. 12, no. 2, pp. 163–170, 2022.
- [20] B. L. S. Lestari and E. Septiani, "Pengaruh Citra Merek dan Kualitas Produk terhadap Keputusan Pembelian Smartphone Iphone pada Mahasiswa di Universitas Mataram," *Alexandria*, 2021.