

Metode Ekstraksi Fitur dan Klasifikasi Visual Untuk Identifikasi Kualitas Pangan Lokal Berbasis Citra Digital

Feature Extraction and Visual Classification Methods for Identifying the Quality of Local Food Based on Digital Images

DANI ROFIANTO^{1*}, KHUSNATUL AMALIAH¹, TIARA KURNIA KHOERUNISSA², MELISA FITRI¹

Abstrak

Mutu pangan lokal memiliki peran penting dalam menjaga ketahanan pangan dan meningkatkan daya saing produk di pasar. Namun, penentuan mutu masih mengandalkan inspeksi visual manual yang bersifat subjektif dan tidak konsisten, sehingga berpotensi menimbulkan kerugian pascapanen serta menurunkan kepercayaan konsumen. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi mutu pangan berbasis citra digital dengan memanfaatkan arsitektur *deep learning EfficientNetV2B0* melalui pendekatan *transfer learning*. Dataset yang digunakan mencakup delapan kelas dari empat komoditas utama, yaitu apel, pisang, tomat, dan pare dalam kondisi segar dan tidak segar. Seluruh citra diproses melalui tahap prapengolahan berupa pengubahan ukuran dan normalisasi, serta dilakukan augmentasi data untuk meningkatkan variasi dan mencegah *overfitting*. Model dilatih dengan konfigurasi ringan dan dievaluasi menggunakan akurasi, presisi, *recall*, *F1-score*, serta *confusion matrix*. Hasil penelitian menunjukkan bahwa model mampu mencapai akurasi keseluruhan sebesar 99.8 persen dengan nilai presisi, *recall*, dan *F1-score* mendekati sempurna pada hampir semua kelas. Temuan ini membuktikan bahwa penerapan *transfer learning* dan augmentasi data efektif dalam membedakan pangan segar dan tidak segar berdasarkan citra digital. Secara praktis, sistem ini berpotensi mendukung petani dan pelaku usaha kecil menengah dalam melakukan inspeksi mutu yang lebih objektif, efisien, dan konsisten.

Kata Kunci: *deep learning, EfficientNetV2B0, klasifikasi citra, pangan lokal, transfer learning*

Abstract

Local food quality is essential for ensuring food security and enhancing product competitiveness in the market. Despite its importance, quality assessment predominantly depends on manual visual inspection, which is inherently subjective and inconsistent. This reliance contributes to post-harvest losses and diminished consumer trust. This study aims to develop a food quality classification system based on digital images by employing the *EfficientNetV2B0* deep learning architecture through a *transfer learning* approach. The dataset consists of eight classes from four major commodities, namely apples, bananas, tomatoes, and bitter gourds, each in fresh and non-fresh conditions. All images were pre-processed through resizing and normalization, followed by data augmentation to increase variability and mitigate *overfitting*. The model was trained using a lightweight configuration and evaluated with accuracy, precision, *recall*, *F1-score*, and *confusion matrix* metrics. The results show that the proposed model achieved an overall accuracy of 99.8 percent, with precision, *recall*, and *F1-score* values approaching perfection across most classes. These findings demonstrate that the combination of *transfer learning* and data augmentation is effective in distinguishing between fresh and non-fresh food products based on visual features. In practical terms, this system has potential to support farmers and small-medium enterprises in conducting more objective, efficient, and consistent quality inspections.

Keywords: *deep learning, EfficientNetV2B0, image classification, local food, transfer learning*

PENDAHULUAN

Pangan lokal memiliki peranan penting dalam mendukung ketahanan pangan dan pembangunan ekonomi berkelanjutan di Indonesia (Arsil dan Bruwer 2014; Gouvello *et al.*

¹ Program Studi Teknologi Rekayasa Perangkat Lunak, Jurusan Teknologi Informasi, Politeknik Negeri Lampung, Bandar Lampung 35141;

2017; Sugeng dan Fitria 2023). Keanekaragaman komoditas pangan lokal, mulai dari buah-buahan, sayuran, hingga hasil olahan tradisional, menjadikan sektor ini tidak hanya sebagai sumber pemenuhan kebutuhan gizi masyarakat, tetapi juga sebagai penopang kesejahteraan ekonomi bagi jutaan petani dan pelaku Usaha Mikro, Kecil, dan Menengah (UMKM) (Widowati & Nurfitriani, 2023). Menurut data Kementerian Pertanian Republik Indonesia Tahun 2023, lebih dari 40% konsumsi pangan nasional dipenuhi oleh produk lokal, sementara sekitar 60% petani dan UMKM menggantungkan penghidupan mereka dari sektor ini. Hal ini menunjukkan bahwa pengelolaan mutu pangan lokal yang baik bukan hanya berkaitan dengan kesehatan masyarakat, tetapi juga erat kaitannya dengan stabilitas ekonomi pedesaan serta daya saing produk nasional.

Sejumlah penelitian dan laporan menunjukkan bahwa potensi besar ini kerap terhambat oleh persoalan mutu produk. Abera *et al.* (2020) menyatakan bahwa salah satu penyebab utama kerugian pascapanen adalah lemahnya penanganan pascapanen di sektor hortikultura. Hal ini diperkuat oleh laporan Kementerian Pertanian Tahun 2023 yang mengungkapkan bahwa kerugian akibat penurunan mutu pascapanen dapat mencapai lebih dari 25% dari total produksi setiap tahun. Kerugian tersebut terutama disebabkan oleh sistem penyimpanan yang belum sesuai standar, rantai distribusi yang masih tradisional, serta kondisi higienitas yang rendah. Penurunan mutu produk tidak hanya mengurangi keuntungan petani dan pelaku UMKM, tetapi juga menurunkan ketersediaan pangan berkualitas di pasar. Lebih jauh lagi, konsumen berisiko kehilangan kepercayaan terhadap produk lokal apabila produk dengan kualitas rendah tetap beredar, bahkan dalam kasus tertentu dapat membahayakan kesehatan masyarakat.

Selama ini, metode identifikasi mutu pangan masih banyak mengandalkan inspeksi visual manual oleh produsen maupun pedagang. Proses ini bersifat subjektif karena sangat tergantung pada pengalaman individu yang melakukan penilaian. Akibatnya, ketakkonsistenan dalam menentukan kualitas pangan sering terjadi, sehingga produk yang sebenarnya sudah menurun mutunya tetap dinyatakan layak jual. Ketergantungan pada metode manual ini jelas menjadi hambatan dalam upaya meningkatkan mutu pangan lokal, terutama jika ingin bersaing di pasar nasional maupun internasional yang menuntut standar mutu yang tinggi dan konsisten.

Seiring perkembangan teknologi, pemanfaatan citra digital dan kecerdasan buatan (*artificial intelligence*) menawarkan peluang baru untuk meningkatkan sistem penilaian mutu pangan (Misra *et al.* 2022; Purnama dan Sejati 2023; Chhetri 2024). Melalui pendekatan *computer vision*, citra pangan dapat diolah untuk mengekstraksi informasi visual seperti warna, tekstur, dan bentuk, yang kemudian diklasifikasikan untuk menentukan mutu produk. Teknologi ini menjanjikan sistem identifikasi mutu yang bersifat otomatis, objektif, dan efisien. Salah satu pendekatan terkini yang semakin banyak digunakan adalah *deep learning*, khususnya metode *transfer learning* yang memanfaatkan model pralatih seperti *EfficientNet* untuk tugas klasifikasi (Mandal dan Phatak 2023; Anurenjan dan Sreeni 2023). Keunggulan metode ini terletak pada kemampuannya mempelajari pola visual yang kompleks dengan *dataset* yang relatif terbatas, sekaligus menghasilkan performa akurasi yang tinggi.

Sejumlah penelitian sebelumnya telah menunjukkan efektivitas pendekatan berbasis citra digital dalam menilai mutu pangan. Diamante (2020) mengembangkan sistem berbasis citra untuk menilai kesegaran ikan dengan akurasi di atas 98%. Si *et al.* (2023) menerapkan metode *transfer learning* dengan *MobileNetV3* untuk mendeteksi cacat permukaan apel dan berhasil membedakan kategori mutu dengan tingkat ketelitian tinggi. Lee dan Lai (2022) meneliti mutu biji kopi menggunakan *deep convolutional neural network* dan menemukan bahwa metode berbasis komputer memberikan hasil yang lebih konsisten dibanding inspeksi manual. Sementara itu, Yuan dan Chen (2024) melakukan deteksi kualitas buah dan sayuran dengan pendekatan *deep features* dan *principal component analysis*, tetapi penelitian tersebut menghadapi keterbatasan karena memerlukan *dataset* yang sangat besar serta daya komputasi tinggi. Hasil-hasil penelitian ini mengindikasikan bahwa teknologi pengolahan citra digital memiliki potensi besar untuk meningkatkan sistem penilaian mutu pangan.


Meskipun demikian, masih terdapat sejumlah *research gap* yang perlu dijawab. Pertama, sebagian besar penelitian masih terbatas pada komoditas tertentu, seperti ikan, apel, atau kopi, sehingga penerapan untuk beragam pangan lokal di Indonesia masih minim. Kedua, meskipun pendekatan *deep learning* terbukti efektif, sebagian besar studi sebelumnya memerlukan *dataset* besar dan perangkat komputasi berdaya tinggi, yang sulit diadopsi oleh UMKM di tingkat lokal. Ketiga, penelitian yang secara khusus mengimplementasikan arsitektur modern seperti *EfficientNetV2B0* untuk klasifikasi mutu pangan lokal masih jarang ditemukan. Padahal, arsitektur ini dikenal efisien secara komputasi dan mampu mencapai performa tinggi dengan jumlah parameter relatif lebih sedikit.

Berdasarkan permasalahan yang diidentifikasi, penelitian ini bertujuan untuk mengembangkan model klasifikasi mutu pangan lokal berbasis citra digital menggunakan arsitektur *EfficientNetV2B0* melalui pendekatan *transfer learning*. *Dataset* yang digunakan mencakup delapan kelas, yaitu apel, pisang, tomat, dan pare, masing-masing dalam kondisi segar dan tidak segar. Penelitian ini melibatkan tahapan sistematis, mulai dari pengumpulan *dataset*, prapengolahan dan augmentasi data, pembangunan model, pelatihan, hingga evaluasi model. Kontribusi penelitian ini tidak hanya bersifat akademis, tetapi juga memberikan teknologi yang relevan bagi petani dan pelaku UMKM untuk meningkatkan kepercayaan konsumen, memperkuat daya saing produk lokal, serta mendukung ketahanan pangan nasional.

METODE

Tahapan Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan yang disusun secara sistematis untuk memastikan tujuan penelitian dapat tercapai. Alur tahapan penelitian ditunjukkan secara skematis pada Gambar 1.



Gambar 1 Diagram alur penelitian mulai dari pengumpulan data hingga evaluasi model

Pengumpulan *Dataset*

Dataset yang digunakan terdiri dari citra pangan lokal yang mencakup empat komoditas utama, yaitu apel, pisang, tomat, dan pare. Setiap komoditas dibagi ke dalam dua kategori mutu, yakni segar (*fresh*) dan tidak segar (*stale*), sehingga menghasilkan total delapan kelas target yang digunakan dalam penelitian ini. Citra dikumpulkan melalui dua metode utama yaitu dokumentasi langsung dan daring. Dokumentasi langsung dilakukan dengan pengambilan gambar di pasar tradisional dan lingkungan Usaha Mikro, Kecil, dan Menengah (UMKM). Gambar diambil dengan kamera digital berkualitas tinggi, yang disesuaikan dengan kondisi pasar yang sering kali memiliki pencahayaan alami yang tidak merata. Untuk mengatasi perbedaan pencahayaan, pencahayaan tambahan menggunakan lampu buatan dilakukan untuk memastikan gambar yang diambil memiliki kualitas yang baik. Citra diambil pada berbagai sudut untuk menangkap objek dengan jelas dan representatif, memperhatikan juga variasi dalam kondisi pencahayaan yang dapat mempengaruhi kualitas gambar. Selain pengambilan gambar langsung, *dataset* pendukung diperoleh dari sumber daring terbuka yang menyediakan citra komoditas pangan. Pengambilan gambar dari sumber daring ini dilakukan dengan mempertimbangkan relevansi dan keaslian gambar, serta memastikan bahwa gambar tersebut sesuai dengan kategori mutu yang ditetapkan dalam penelitian (segar atau tidak segar). Hanya

gambar dengan kondisi yang jelas dan sesuai dengan tujuan penelitian yang diambil, untuk memastikan konsistensi dan relevansi *dataset*.

Setelah citra dikumpulkan, langkah selanjutnya adalah pelabelan manual. Proses pelabelan dilakukan oleh dua orang penilai terlatih yang memiliki pemahaman tentang ciri-ciri visual yang membedakan antara pangan segar dan tidak segar. Ciri-ciri visual yang digunakan untuk pelabelan meliputi perubahan warna (misalnya, warna kecokelatan pada apel atau tomat yang sudah tidak segar), munculnya bercak hitam, tekstur kasar, dan tanda-tanda kerusakan fisik lainnya. Seluruh citra yang terkumpul diberi label dengan hati-hati untuk menjaga konsistensi antar kelas dan meminimalkan bias subjektif.

Untuk memastikan kualitas dan keakuratan pelabelan, setiap citra yang telah dilabeli kemudian divalidasi oleh penilai kedua, yang akan memverifikasi apakah label yang diberikan sudah sesuai dengan kondisi visual yang terlihat. Proses ini bertujuan untuk meminimalkan kesalahan dalam pelabelan yang dapat mempengaruhi hasil pelatihan model dan untuk memastikan bahwa data yang digunakan bersifat konsisten dan objektif.

Prapengolahan dan Augmentasi Data

Prapengolahan dilakukan agar data citra memiliki format seragam dan kualitas yang sesuai untuk dilatih pada model. Seluruh citra diubah ukurannya menjadi 256×256 piksel, kemudian dinormalisasi ke rentang $[0,1]$ untuk mempercepat proses konvergensi saat pelatihan. Pengurangan *noise* diterapkan untuk meminimalkan gangguan akibat pencahayaan tidak merata, sedangkan peningkatan kontras dilakukan dengan teknik *histogram equalization* agar perbedaan warna dan tekstur lebih jelas. Selain prapengolahan dasar, dilakukan pula augmentasi data guna memperbanyak variasi citra. Teknik augmentasi yang diterapkan meliputi rotasi acak, *flipping horizontal*, pergeseran posisi, *zoom*, serta penyesuaian tingkat kecerahan. Strategi ini penting untuk mencegah *overfitting* dan memperkuat kemampuan generalisasi model ketika menghadapi data baru di kondisi nyata.

Pembangunan Model Klasifikasi

Model klasifikasi yang digunakan adalah arsitektur *EfficientNetV2B0* yang diimplementasikan melalui pendekatan *transfer learning*. Pada tahap awal, bobot pralatih (*pre-trained weights*) dari ImageNet digunakan pada lapisan dasar untuk mengekstraksi fitur umum dari citra, seperti tepi, bentuk, dan tekstur. Selanjutnya, dilakukan proses *fine-tuning* dengan membuka sebagian lapisan *convolutional* agar model dapat menyesuaikan diri dengan dataset pangan lokal. Pada bagian akhir, ditambahkan *dense layer* dengan delapan *neuron* sesuai dengan jumlah kelas dataset. Fungsi aktivasi *softmax* digunakan pada lapisan *output* untuk menghasilkan distribusi probabilitas yang menunjukkan keyakinan model terhadap prediksi kelas.

Pelatihan Model

Pelatihan model dilakukan dengan membagi *dataset* menjadi 80% data latih dan 20% data validasi. Konfigurasi pelatihan menggunakan *batch size* 32 dengan jumlah *epoch* sebanyak 5. *Optimizer Adam* dipilih karena efisiensinya dalam mempercepat proses pembelajaran, dan *learning rate scheduler* diterapkan untuk menyesuaikan laju pembelajaran secara adaptif.

Evaluasi Model

Evaluasi model dilakukan menggunakan data uji yang dipisahkan dari data latih dan validasi. Beberapa metrik digunakan untuk menilai performa, yaitu akurasi, *presisi*, *recall*, dan *F1-score*. Akurasi digunakan untuk mengukur persentase prediksi yang benar, *presisi* untuk menilai ketepatan prediksi positif, *recall* untuk menilai kelengkapan prediksi, dan *F1-score* sebagai harmonisasi antara *presisi* dan *recall*. Selain itu, digunakan *confusion matrix* untuk melihat distribusi hasil prediksi pada setiap kelas. *Confusion matrix* memberikan gambaran


visual mengenai sejauh mana model mampu mengklasifikasikan citra dengan benar serta kesalahan yang masih terjadi.

HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian yang diperoleh dari serangkaian tahapan eksperimen sebagaimana telah dijelaskan pada metodologi, serta pembahasan yang mengaitkan hasil tersebut dengan penelitian sebelumnya. Penjelasan difokuskan pada bagaimana model *EfficientNetV2B0* melalui pendekatan *transfer learning* dapat digunakan untuk mengklasifikasikan kualitas pangan lokal berbasis citra digital. Subbagian disusun secara runtut mulai dari distribusi *dataset*, proses prapengolahan, pembangunan dan pelatihan model, hingga evaluasi akhir performa.

Distribusi *Dataset*

Dataset penelitian ini terdiri dari citra pangan lokal pada empat jenis komoditas, yaitu apel, pisang, tomat, dan pare. Setiap komoditas dibagi menjadi dua kategori mutu, yakni segar (*fresh*) dan tidak segar (*stale*). Dengan demikian, total terdapat delapan kelas target. Jumlah data relatif seimbang antar kelas, meskipun terdapat variasi tertentu. Kondisi ini cukup penting karena model *deep learning* cenderung sensitif terhadap ketidakseimbangan data, yang dapat menyebabkan bias prediksi terhadap kelas dengan jumlah sampel lebih banyak. Distribusi jumlah citra per kelas ditunjukkan pada Gambar 2 dan Tabel 1.



Gambar 2 Distribusi jumlah citra pada delapan kelas pangan lokal

Tabel 1 Jumlah citra per kelas dataset penelitian

Kelas	Jumlah Gambar
Apel Segar	1337
Pisang Segar	1267
Pare Segar	264
Tomat Segar	806
Apple Tidak Segar	1866
Pisang Tidak Segar	1169
Pare Tidak Segar	267
Tomat Tidak Segar	808

Tabel 1 memperlihatkan bahwa jumlah data pada setiap kelas cukup representatif. Visualisasi distribusi data ditunjukkan pada Gambar 2 dalam bentuk grafik, dimana terlihat perbedaan jumlah sampel antar kelas relatif kecil. Hal ini membantu memastikan bahwa model tidak mengalami bias signifikan selama proses pelatihan.

Selain distribusi numerik, contoh citra dari setiap kelas ditampilkan pada Gambar 3. Gambar ini memperlihatkan variasi visual antara produk segar dan tidak segar. Misalnya, apel segar umumnya memiliki warna cerah dan permukaan mulus, sementara apel tidak segar menunjukkan perubahan warna kecokelatan dengan bercak-bercak hitam. Perbedaan semacam ini menjadi dasar bagi model dalam membedakan kategori mutu.



Gambar 3 Contoh citra dataset segar dan tidak segar pada tiap komoditas

Prapengolahan dan Augmentasi Data

Citra yang dikumpulkan tidak serta-merta dapat digunakan untuk pelatihan. Perbedaan resolusi, pencahayaan, dan latar belakang dapat mengurangi konsistensi data. Oleh karena itu, dilakukan prapengolahan untuk meningkatkan kualitas citra dan menyeragamkan format data. Setiap citra diubah ukurannya menjadi 256×256 piksel agar sesuai dengan dimensi input *EfficientNetV2B0*. Nilai piksel dinormalisasi ke rentang $[0,1]$ untuk mempercepat proses konvergensi model. Proses pengurangan *noise* dilakukan untuk meminimalkan gangguan akibat pencahayaan tidak merata, sedangkan *histogram equalization* digunakan untuk memperjelas perbedaan warna dan tekstur. Selain itu, augmentasi data diterapkan untuk memperkaya variasi dataset. Teknik augmentasi yang digunakan meliputi rotasi acak, *flipping horizontal*, pergeseran posisi (*shifting*), *zoom*, dan penyesuaian kecerahan. Augmentasi ini bertujuan mencegah *overfitting* sekaligus meningkatkan kemampuan generalisasi model ketika menghadapi kondisi nyata yang lebih beragam.

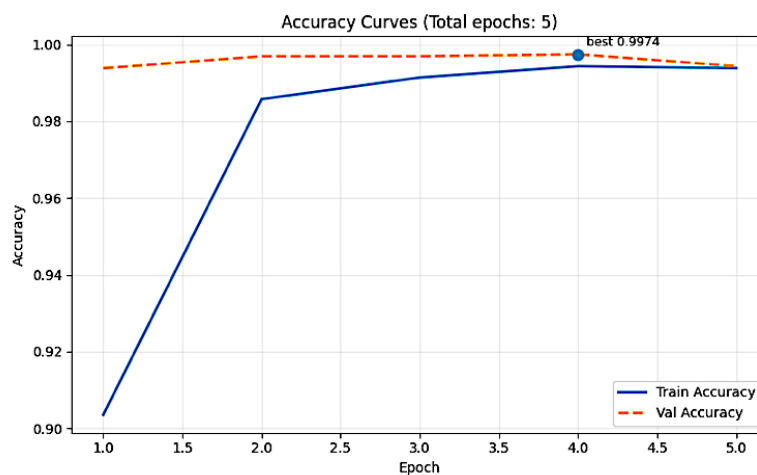
Model Klasifikasi

Model utama yang digunakan adalah *EfficientNetV2B0*. Pemilihan arsitektur ini didasarkan pada kombinasi efisiensi komputasi dan akurasi tinggi yang telah terbukti dalam berbagai tugas klasifikasi citra. Arsitektur ini menggunakan konsep *compound scaling*, yang menyeimbangkan kedalaman, lebar, dan resolusi model. Dalam penelitian ini, bobot prelatih dari ImageNet digunakan sebagai basis. Bobot tersebut berfungsi sebagai pengetahuan awal yang memungkinkan model mengenali pola dasar seperti tepi, tekstur, dan warna. Selanjutnya,

sebagian lapisan *convolutional* dibuka untuk *fine-tuning*, sehingga model dapat menyesuaikan diri dengan karakteristik *dataset* pangan lokal. Pada bagian akhir arsitektur, ditambahkan *dense layer* dengan delapan *neuron* sesuai jumlah kelas, dengan fungsi aktivasi *softmax*. Lapisan ini mengubah hasil keluaran menjadi distribusi probabilitas, sehingga model dapat memberikan prediksi kategori dengan tingkat keyakinan tertentu.

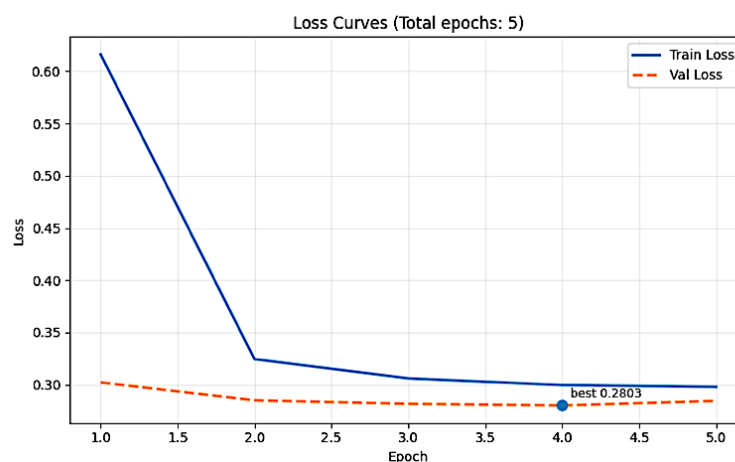
Hasil Pelatihan Model

Pelatihan dilakukan dengan membagi *dataset* menjadi 80% untuk pelatihan dan 20% untuk validasi. Proses pelatihan dijalankan dengan *batch size* 32 selama 5 *epoch* menggunakan *optimizer Adam*. Jumlah *epoch* dibatasi hanya 5 karena beberapa pertimbangan: (1) arsitektur *EfficientNetV2B0* yang digunakan memiliki sifat *pre-trained* sehingga sudah membawa bobot awal yang baik, sehingga tidak memerlukan *epoch* yang terlalu banyak; (2) penggunaan teknik *early stopping* memastikan pelatihan berhenti otomatis saat performa validasi tidak lagi meningkat, sehingga tambahan *epoch* berlebih cenderung tidak memberikan perbaikan signifikan; dan (3) pembatasan *epoch* juga bertujuan untuk mengurangi risiko *overfitting* serta menekan kebutuhan komputasi, agar hasil penelitian tetap relevan untuk diterapkan di lingkungan UMKM dengan sumber daya terbatas. Selain itu, *learning rate scheduler* diterapkan untuk mengatur laju pembelajaran secara adaptif, sementara *data augmentation* ditambahkan untuk meningkatkan generalisasi model. Selama proses pelatihan, metrik akurasi dan *loss* dipantau baik pada data latih maupun validasi. Hasil pemantauan divisualisasikan dalam bentuk kurva, yang ditunjukkan pada Gambar 4 untuk akurasi dan Gambar 5 untuk *loss*.



Gambar 4 Kurva akurasi pelatihan dan validasi

Dari grafik pada Gambar 4 terlihat bahwa akurasi meningkat signifikan sejak *epoch* pertama dan mencapai kestabilan pada *epoch* ketiga. Akurasi validasi mengikuti tren akurasi pelatihan dengan selisih yang kecil, menandakan bahwa model tidak mengalami *overfitting*.




Gambar 5 Kurva *loss* pelatihan dan validasi

Pada Gambar 5 dapat dilihat bahwa nilai *loss* menurun konsisten seiring bertambahnya *epoch*. Pada *epoch* kelima, *loss* baik pada data latih maupun validasi telah mendekati minimum, sehingga dapat disimpulkan bahwa model telah belajar secara optimal.

Evaluasi Model

Evaluasi dilakukan menggunakan data uji yang dipisahkan dari data latih dan validasi. Hasil evaluasi divisualisasikan melalui *confusion matrix* pada Gambar 6. Dari Gambar 6 dapat dilihat bahwa hampir seluruh citra berhasil diprediksi dengan benar, dengan nilai diagonal yang dominan pada setiap kelas. Kesalahan klasifikasi yang terjadi jumlahnya sangat kecil dan biasanya muncul pada kondisi citra dengan pencahayaan ekstrem atau objek yang mengalami kerusakan parsial.



Gambar 6 *Confusion matrix* hasil klasifikasi model pada data uji


Selain *confusion matrix*, laporan klasifikasi ditampilkan pada Gambar 7. Nilai presisi, *recall*, dan *F1-score* pada sebagian besar kelas mendekati 1.00, sementara akurasi keseluruhan mencapai 99.8%. Hal ini menunjukkan bahwa model tidak hanya akurat secara keseluruhan, tetapi juga konsisten dalam performa antar kelas.

	precision	recall	f1-score	support
Apel_Segar	1.000	1.000	1.000	338
Pisang_Segar	1.000	1.000	1.000	316
Pare_Segar	1.000	1.000	1.000	65
Tomat_Segar	0.9751	1.000	0.9874	196
Apel_TidakSegar	1.000	1.000	1.000	468
Pisang_TidakSegar	1.000	1.000	1.000	293
Pare_TidakSegar	1.000	1.000	1.000	71
Tomat_TidakSegar	1.000	0.9745	0.9871	196
Accuracy			0.9974	1943
Macro avg	0.9969	0.9968	0.9968	1943
Weight avg	0.9975	0.9974	0.9974	1943

Gambar 7 Laporan klasifikasi per kelas: presisi, *recall*, *F1-score*, jumlah sampel

Analisis Prediksi Citra

Gambar 8 memperlihatkan citra input beserta label asli dan label prediksi yang dihasilkan oleh model. Sebagian besar citra berhasil diklasifikasikan dengan benar dengan tingkat probabilitas di atas 0.90. Kesalahan prediksi yang muncul cenderung terjadi pada citra dengan kondisi *borderline*, misalnya buah yang sebagian masih segar namun sudah menunjukkan tanda-tanda kerusakan.



Gambar 8 Contoh hasil prediksi citra pangan lokal segar dan tidak segar

Diskusi

Hasil penelitian ini menunjukkan bahwa model *EfficientNetV2B0* yang diterapkan untuk klasifikasi kualitas pangan lokal berbasis citra digital berhasil mencapai performa yang sangat tinggi, dengan akurasi keseluruhan sebesar 99.8%. Nilai *presisi*, *recall*, dan *F1-score* yang mendekati sempurna di seluruh kelas mengindikasikan bahwa model ini tidak hanya dapat membedakan kualitas pangan segar dan tidak segar dengan tingkat akurasi yang tinggi, tetapi juga melakukannya dengan konsistensi yang sangat baik. Keberhasilan ini dapat dijelaskan melalui beberapa faktor utama. Pertama, penggunaan bobot pralatih dari ImageNet memberikan fondasi pengetahuan visual yang kuat, yang memungkinkan model mengenali pola dasar dengan lebih cepat dan efisien. Kedua, penerapan augmentasi data yang meliputi teknik-teknik seperti rotasi acak, *flipping horizontal*, *zooming*, dan penyesuaian kecerahan berhasil memperkaya variasi citra, yang pada gilirannya membantu mencegah *overfitting* dan meningkatkan kemampuan model untuk beradaptasi dengan kondisi nyata yang lebih beragam.

Perbandingan dengan penelitian sebelumnya menunjukkan bahwa hasil yang diperoleh dalam penelitian ini melampaui capaian yang telah dicapai oleh studi-studi terdahulu. Sebagai contoh, penelitian Diamante (2020) mengembangkan sistem berbasis citra untuk menilai kesegaran ikan dengan akurasi lebih dari 98%, sementara Si *et al.* (2023) menerapkan *transfer learning* menggunakan *MobileNetV3* untuk mendeteksi cacat permukaan apel, yang menghasilkan tingkat ketelitian tinggi dalam membedakan kategori mutu. Meski demikian, penelitian ini mencatatkan akurasi sebesar 99.8%, yang lebih tinggi dibandingkan dengan hasil-hasil penelitian sebelumnya, sekaligus menunjukkan bahwa *EfficientNetV2B0*, yang dipadukan dengan teknik *transfer learning* dan augmentasi data, merupakan pendekatan yang sangat efektif dalam tugas klasifikasi kualitas pangan lokal.

Lebih lanjut, Penelitian Hsia *et al.* (2022) menunjukkan bahwa *deep Convolutional Neural Networks* (CNN) untuk penilaian mutu biji kopi menghasilkan hasil yang lebih konsisten dibandingkan dengan inspeksi manual. Hal ini juga tercermin dalam penelitian ini, di mana metode berbasis citra digital menawarkan penilaian yang lebih objektif dan konsisten, mengurangi potensi kesalahan subjektif yang biasa terjadi dalam inspeksi manual. Sementara

itu, Yuan dan Chen (2024) menggunakan pendekatan *deep features* dan PCA untuk deteksi kualitas buah dan sayuran, namun penelitian tersebut mengalami kendala terkait kebutuhan akan dataset yang sangat besar dan daya komputasi yang tinggi. Dalam penelitian ini, meskipun dataset yang digunakan relatif kecil dan spesifik pada empat jenis komoditas, model *EfficientNetV2B0* mampu menunjukkan performa yang sangat baik dengan sumber daya komputasi yang lebih rendah, menjadikannya pilihan yang lebih praktis dan aplikatif, terutama bagi UMKM yang memiliki keterbatasan dalam hal infrastruktur.

Namun demikian, penelitian ini masih memiliki beberapa keterbatasan yang perlu diperhatikan. Pertama, jenis komoditas yang digunakan hanya terbatas pada empat pangan lokal, yaitu apel, pisang, tomat, dan pare. Perluasan *dataset* yang mencakup lebih banyak jenis pangan akan memberikan gambaran yang lebih representatif mengenai keberagaman produk pangan lokal yang ada di pasar. Kedua, meskipun citra yang digunakan telah melalui prapengolahan yang cermat, sebagian besar data dikumpulkan dalam kondisi pencahayaan yang terkontrol. Oleh karena itu, penelitian lanjutan yang melibatkan variasi kondisi pencahayaan alami, seperti yang ada di pasar tradisional atau dalam distribusi logistik, akan sangat berguna untuk meningkatkan daya adaptasi model pada lingkungan yang lebih realistis.

Secara praktis, sistem yang diusulkan memiliki potensi besar untuk diimplementasikan pada skala UMKM dan petani lokal. Dengan memanfaatkan perangkat yang relatif sederhana seperti kamera *smartphone*, sistem ini dapat memberikan solusi yang cepat, objektif, dan konsisten untuk menilai kualitas pangan. Teknologi ini tidak hanya dapat membantu mengurangi kerugian pascapanen, tetapi juga meningkatkan kepercayaan konsumen dan daya saing produk lokal di pasar nasional maupun internasional. Dengan hasil yang menunjukkan akurasi tinggi dan penerapan yang praktis, sistem ini terbukti relevan dan dapat diterapkan secara efisien, memberikan kontribusi nyata dalam mendukung ketahanan pangan dan memperkuat ekonomi lokal.

SIMPULAN

Penelitian ini mengusulkan sistem identifikasi kualitas pangan lokal berbasis citra digital dengan *deep learning* menggunakan arsitektur *EfficientNetV2B0* melalui *pendekatan transfer learning*. *Dataset* terdiri dari delapan kelas (apel, pisang, tomat, dan pare; segar dan tidak segar), yang diproses melalui tahapan prapengolahan dan augmentasi untuk memperkaya variasi data. Model kemudian dilatih dengan konfigurasi ringan dan dievaluasi menggunakan *confusion matrix*. Hasil penelitian menunjukkan bahwa model mampu mengklasifikasikan mutu pangan lokal dengan akurasi sangat tinggi, yaitu sekitar 99.8%, dengan nilai presisi, *recall*, dan *F1-score* yang hampir sempurna pada seluruh kelas. Kurva akurasi dan *loss* memperlihatkan proses pembelajaran yang stabil tanpa indikasi *overfitting*. Capaian ini membuktikan bahwa kombinasi *transfer learning EfficientNetV2B0* dan augmentasi data efektif dalam membedakan produk segar dan tidak segar. Secara praktis, sistem ini berpotensi diterapkan oleh petani dan UMKM untuk mendukung inspeksi mutu yang objektif, cepat, dan konsisten. Meski terbatas pada empat komoditas, hasil ini memberikan dasar kuat bagi pengembangan lebih lanjut ke jenis pangan lain serta penerapan di perangkat *edge* berdaya rendah. Dengan demikian, metode yang diusulkan terbukti andal dan aplikatif untuk mendukung ketahanan pangan lokal berbasis teknologi digital.

UCAPAN TERIMA KASIH

Penelitian ini didanai oleh Dana Hibah Penelitian DIPA Politeknik Negeri Lampung Tahun Anggaran 2025. Penulis menyampaikan terima kasih kepada LPPM Polinela atas fasilitasi dan dukungan administratif selama proses penelitian. Ucapan terima kasih juga ditujukan kepada rekan-rekan peneliti, asisten lapangan, serta mitra UMKM dan pedagang pasar lokal yang telah membantu dalam proses dokumentasi citra serta verifikasi label mutu.

DAFTAR PUSTAKA

- Abera G, Ibrahim AM, Forsido SF, Kuyu CG. 2020. Assessment on post-harvest losses of tomato (*Lycopersicon esculentum* Mill.) in selected districts of East Shewa Zone of Ethiopia using a commodity system analysis methodology. *Heliyon*. 6(4):e03749. <https://doi.org/10.1016/j.heliyon.2020.e03749>.
- Arsil P, Li E, Bruwer J. 2014. Perspectives on consumer perceptions of local foods: A view from Indonesia. *Journal of International Food and Agribusiness Marketing*. 26(2):107–123. <https://doi.org/10.1080/08974438.2012.755725>.
- Chhetri KB. 2024. Applications of artificial intelligence and machine learning in food quality control and safety assessment. *Food Engineering Reviews*. 16(1):1–21. <https://doi.org/10.1007/s12393-023-09363-1>.
- Diamante RA. 2020. Freshness classification of milkfish (*Chanos chanos*) using wavelet transformation in image extraction. *International Journal of Advanced Trends in Computer Science and Engineering*. 9(1.1):76–79. <https://doi.org/10.30534/ijatcse/2020/1491.12020>.
- Gouvello L, Hochart LE, Laffoley D, Simard F, Andrade C, Angel D, Callier M, Monbrison D, Fezzardi D, Haroun R, Harris A, Hughes A, Massa F, Roque E, Soto D, Stead S, Marino G. 2017. Aquaculture and marine protected areas: Potential opportunities and synergies. *Aquatic Conservation: Marine and Freshwater Ecosystems*. 27(S1):138–150. <https://doi.org/10.1002/aqc.2821>.
- Hsia CH, Lee YH, Lai CF. 2022. An explainable and lightweight deep convolutional neural network for quality detection of green coffee beans. *Applied Sciences (Switzerland)*. 12(21):10966. <https://doi.org/10.3390/app122110966>.
- Mandal AC, Phatak A. 2023. Optimizing deep learning based retinal diseases classification on optical coherence tomography scans. *Proceedings of the European Conference on Biomedical Optics (ECBO 2023)*. <https://doi.org/10.1117/12.2672249>.
- Misra NN, Dixit Y, Mallahi A, Bhullar MS, Upadhyay R, Martynenko A. 2020. IoT, big data, and artificial intelligence in agriculture and food industry. *IEEE Internet of Things Journal*. 7(11):1–1. <https://doi.org/10.1109/JIOT.2020.2998584>.
- Purnama S, Sejati W. 2023. Internet of things, big data, and artificial intelligence in the food and agriculture sector. *International Transactions on Artificial Intelligence (ITALIC)*. 1(2):156–174. <https://doi.org/10.33050/italic.v1i2.274>.
- Si H, Wang Y, Zhao W, Wang M, Song J, Wan L, Song Z, Li Y, Fernando B, Sun C. 2023. Apple surface defect detection method based on weight comparison transfer learning with MobileNetV3. *Agriculture*. 13(4):824. <https://doi.org/10.3390/agriculture13040824>.
- Sugeng S, Fitria A. 2023. Food sovereignty for Indonesia: The epistemological dimension of knowledge and variety of local food. *Jurnal Analisis Hukum*. 6(1):18–32. <https://doi.org/10.38043/jah.v6i1.4179>.
- Widowati S, Nurfitriani RA. 2023. Diversifikasi pangan lokal untuk ketahanan pangan: perspektif ekonomi, sosial, dan budaya. Jakarta: Penerbit BRIN.
- Yuan Y, Chen X. 2024. Vegetable and fruit freshness detection based on deep features and principal component analysis. *Current Research in Food Science*. 8:100656. <https://doi.org/10.1016/j.crfs.2023.100656>.