

## Identifikasi Kematangan Buah Menggunakan Teknik Deep Learning

Boldson Herdianto Situmorang<sup>1\*</sup>); Yessy Asri<sup>2</sup>

1. Program Studi Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Pakuan, Jl. Pakuan, RT.02/RW.06, Tegallega, Bogor Tengah, Kota Bogor, Jawa Barat 16129, Indonesia
2. Program Studi Sistem Informasi, Fakultas Telematika Energi, Institut Teknologi PLN Menara PLN, Jl. Lingkar Luar Barat, Duri Kosambi, Cengkareng, Jakarta Barat, DKI Jakarta 11750, Indonesia

\**Email: boldson.situmorang@unpak.ac.id*

Received: 17 September 2024 / Accepted: 23 September 2024 / Published: 11 Juli 2024

### ABSTRACT

Numerous recent research studies have explored the application of deep learning techniques for detection, identification, segmentation, and classification of fruits. By utilizing deep learning model architectures, such as Convolutional Neural Networks (CNNs), along with strategies like data augmentation, transfer learning, and ensemble learning, systems can automatically recognize fruit ripeness with high accuracy. The mechanism for identifying fruit ripeness with high precision can be achieved through the selection of appropriate pre-trained models, adjustment of top layers, training with suitable learning rates, application of data augmentation, fine-tuning, evaluation, and parameter tuning. This study aims to provide insights into fruit ripeness identification through the approaches of data augmentation, transfer learning, and ensemble learning, focusing on key aspects such as literature review, datasets, pre-trained models, and accuracy.

**Keywords:** Identification of Fruit Ripeness; Deep Learning; Data Augmentation, Transfer Learning, Ensemble Learning

### ABSTRAK

Banyak studi penelitian terkini telah mengeksplorasi penerapan teknik deep learning untuk deteksi, identifikasi, segmentasi, dan klasifikasi buah. Dengan penggunaan arsitektur model deep learning, seperti Convolutional Neural Networks (CNNs), dan strategi data augmentation, transfer learning dan ensemble learning, sistem dapat mengenali kematangan buah secara otomatis dengan akurasi yang tinggi. Mekanisme untuk mengidentifikasi kematangan buah dengan akurasi yang tinggi dapat dilakukan dengan pemilihan model pre-trained yang sesuai, penyesuaian lapisan teratas, pelatihan dengan learning rate yang sesuai, penerapan augmentasi data, fine-tuning, evaluasi, dan penyetelan parameter. Penelitian ini bertujuan untuk memberikan penjelasan tentang identifikasi kematangan buah melalui pendekatan data augmentation, transfer learning, dan ensemble learning dengan berfokus pada bagian-bagian seperti review penelitian, dataset, model pre-trained, dan akurasi.

**Kata kunci:** Identifikasi Kematangan Buah, Deep Learning, Data Augmentation, Transfer Learning, Ensemble Learning

## 1. PENDAHULUAN

Pertumbuhan populasi global dan pergeseran pola konsumsi telah meningkatkan permintaan akan buah-buahan yang berkualitas dan bermutu tinggi. Kematangan buah adalah faktor kunci yang menentukan kualitas, rasa, dan nilai gizi dari buah tersebut. Oleh karena itu, identifikasi kematangan buah merupakan aspek penting dalam industri pertanian, distribusi, dan pemasaran buah-buahan.

*Computer vision* adalah teknik baru dalam pangan dan pertanian yang memainkan peran penting dalam memecahkan masalah praktis penyortiran, penilaian, klasifikasi, dan pengenalan otomatis [1]. Salah satu pendekatan yang menjanjikan adalah menggunakan teknik *deep learning*, yang merupakan cabang dari kecerdasan buatan yang terinspirasi dari struktur dan fungsi jaringan saraf manusia. *Deep learning* telah terbukti efektif dalam memproses data kompleks dan mengekstraksi fitur-fitur yang relevan untuk pengambilan keputusan dibandingkan metode tradisional atau *machine learning* [2].

Banyak penelitian terkini telah mengeksplorasi penerapan teknik *deep learning* untuk deteksi, identifikasi, segmentasi, dan klasifikasi buah. Melalui penggunaan algoritma yang kompleks dan pengolahan data yang canggih, teknik-teknik ini mampu mengatasi tantangan dalam pengenalan visual buah-buahan yang berubah seiring waktu. Keakuratan identifikasi buah tergantung pada beberapa faktor, termasuk kualitas gambar buah yang dikumpulkan, jumlah dan jenis fitur yang diekstraksi, penyeleksian fitur klasifikasi optimal, dan pemilihan pengklasifikasi yang digunakan [3].

Penelitian-penelitian sebelumnya telah menunjukkan beragam pendekatan dan metodologi dalam penggunaan teknik *deep learning* untuk identifikasi kematangan buah. Salah satu contoh pendekatan yang popular adalah penggunaan *Convolutional Neural Networks* (CNNs), yang telah terbukti efektif dalam mengekstraksi fitur-fitur penting dari citra buah. CNNs dapat meningkatkan kinerja *computer vision* dalam mengklasifikasikan dan mengidentifikasi produk pertanian [4]. Arsitektur *deep learning* adalah sebuah rangkaian lapisan konvolusional dengan fungsi aktivasi, meliputi *pooling layers*, *fully connected*, dan *softmax* [5]. Lapisan-lapisan tersebut mempunyai kemampuan untuk mengekstrak fitur dari citra masukan (*input*), mempelajari, dan akhirnya memprediksi keluaran (*output*).

Banyak penelitian menggunakan model CNNs cerdas atau model *pre-trained* seperti AlexNet, ResNet50, GoogleNet, VGG16, VGG19, InceptionV3, InceptionResNetV2, DenseNet121, DenseNet169, DenseNet201, Xception, MobileNet, MobileNetV2, EfficientNetB0 CGG19, ResNet50V2, ResNet50, ResNet101, ResNet101V2, ResNet152V2, dan ResNet152 [6]. Selain CNNs, beberapa penelitian juga menggabungkan teknik-teknik lain seperti *data augmentation*, *transfer learning*, dan *ensemble learning* untuk meningkatkan akurasi dan ketahanan model dalam mengenali kematangan buah.

Dalam konteks ini, penelitian ini bertujuan untuk memberikan penjelasan tentang identifikasi kematangan buah melalui pendekatan *data augmentation*, *transfer learning* dan *ensemble learning*. Melalui analisis yang komprehensif, diharapkan dapat diperoleh pemahaman yang lebih baik tentang kelebihan, kekurangan, dan potensi pengembangan teknologi ini dalam industri pertanian dan distribusi buah-buahan.

## 2. METODE/PERANCANGAN PENELITIAN

Pada bagian ini akan membahas penerapan teknik *deep learning* menggunakan *data augmentation*, *transfer learning*, dan *ensemble learning* dengan berfokus pada bagian-bagian seperti review penelitian, dataset, model *pre-trained*, dan akurasi.

## 2.1. Data Augmentation

Dalam pengembangan sistem identifikasi kematangan buah menggunakan *deep learning*, jumlah dan variasi dalam dataset *training* dapat mempengaruhi kinerja dan generalisasi model [2]. Namun, seringkali sulit untuk mengumpulkan dataset yang cukup besar dan beragam untuk mencakup semua kemungkinan variasi dalam kematangan buah. Untuk mengatasi masalah ini, teknik *data augmentation* menjadi pendekatan yang penting dalam meningkatkan variasi data pelatihan tanpa perlu mengumpulkan data baru secara manual.

*Data augmentation* bermanfaat untuk memperluas variasi dalam dataset *training*, membantu mencegah overfitting, lebih efisien dan hemat biaya untuk meningkatkan jumlah dan variasi dalam dataset *training* [7]. Teknik *data augmentation* meliputi:

1. Rotasi: Dengan memutar citra buah dalam berbagai sudut, dapat meningkatkan variasi dalam posisi buah dalam citra. Ini membantu model untuk belajar dengan lebih baik dalam mengenali buah yang mungkin memiliki orientasi yang berbeda.
2. Pergeseran: Pergeseran citra secara horizontal atau vertikal memungkinkan untuk menciptakan variasi dalam posisi buah dalam bingkai citra. Hal ini berguna untuk mempersiapkan model terhadap variasi dalam komposisi citra.
3. Pemutaran: Pemutaran citra dapat menciptakan variasi dalam orientasi buah, memungkinkan model untuk belajar mengidentifikasi buah yang miring atau terbalik.
4. Perubahan skala: Memperbesar atau memperkecil citra buah dapat membantu dalam memperkenalkan variasi dalam ukuran buah. Hal ini berguna untuk mempersiapkan model terhadap variasi dalam ukuran buah.
5. Pencitraan Cermin: Melakukan pencitraan cermin pada citra menciptakan citra simetris, yang dapat membantu dalam meningkatkan variasi dalam data *training*.

Aherwadi et al. [8] menggunakan dua dataset citra buah pisang. Dataset pertama merupakan citra buah pisang yang diambil sendiri menggunakan kamera dari sudut dan arah yang berbeda; berisi citra pisang mentah, matang, dan terlalu matang, dengan masing-masing kategori sebanyak 700 citra. Dataset kedua tersedia di Kaggle, sebanyak 1312 citra pisang dan pisang merah (Fruit) berukuran 100 x 100 x 3. Pertama-tama ukuran citra pisang yang diambil sendiri diubah menjadi 227 x 227 piksel dan 112 x 112 piksel, dan Fruit 360 dataset telah diubah menjadi 100 x 100. Teknik *deep learning* berbasis CNN dan AlexNet digunakan untuk membangun model dari *dataset custom*, *augmented custom*, dan *Fruit 360* dataset. AlexNet mencapai akurasi *training* 98.18% dan akurasi validasi 81.75% untuk dataset asli (227 x 227 piksel). *Augmented* dataset (112 x 112 piksel) mencapai akurasi *training* 99.80% dan akurasi validasi 99.44%. *Fruit 360* dataset (100 x 100 x 3 piksel) mencapai akurasi *training* 100% dan akurasi validasi 89.84%.

## 2.2. Transfer Learning

*Transfer learning* telah menjadi pendekatan yang popular dan efektif dalam mengidentifikasi kematangan buah menggunakan teknik *deep learning*. *Transfer learning* memungkinkan penyaluran pengetahuan dari model yang telah dilatih sebelumnya pada dataset yang besar ke model yang baru untuk tugas identifikasi kematangan buah, bahkan ketika dataset yang tersedia terbatas. Proses *transfer learning* dalam konteks pengidentifikasiannya kematangan buah dapat diuraikan sebagai berikut [9]:

1. Pemilihan Model Dasar: Langkah pertama adalah memilih model dasar yang telah dilatih sebelumnya. Model ini umumnya sudah dilatih pada dataset yang besar dan beragam

untuk tugas pengenalan objek umum.

2. Penyesuaian Model: Kemudian, lapisan-lapisan atas dari model dasar tersebut disesuaikan dengan dataset target, yaitu dataset yang berisi citra-citra buah dengan label kematangan. Biasanya, lapisan-lapisan ini akan disesuaikan agar lebih cocok dengan karakteristik visual dari buah-buahan yang sedang dipelajari.
3. Pengaturan Hyperparameter: Hyperparameter seperti *learning rate*, ukuran *batch*, dan jumlah iterasi pembelajaran (*epoch*) disesuaikan untuk memastikan bahwa model yang dihasilkan dapat belajar dengan baik dari dataset target.
4. Pelatihan Model: Model yang telah disesuaikan kemudian dilatih menggunakan dataset target. Selama proses pelatihan, parameter-parameter model *di-update* dengan menggunakan teknik optimasi seperti stokastik gradien turun (*stochastic gradient descent*) atau varian-varian lainnya.
5. Evaluasi Model: Setelah pelatihan selesai, model dievaluasi menggunakan dataset validasi atau uji yang berbeda untuk mengukur kinerjanya dalam mengidentifikasi tingkat kematangan buah. Metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score* dapat digunakan untuk menilai kinerja model.
6. *Fine-Tuning* Tambahan (Opsional): Opsionalnya, *fine tuning* tambahan dapat dilakukan dengan membuka beberapa lapisan tambahan dari model dasar dan melatih seluruh atau sebagian besar model dengan laju pembelajaran yang lebih rendah.

Begum dan Hazarika [9] menerapkan *transfer learning* untuk mengklasifikasikan 625 citra tomat ke dalam kelas kematangannya. Tomat secara otomatis diklasifikasikan ke dalam kelas yaitu belum matang, matang sebagian, dan matang. Beberapa model *pre-trained transfer learning* yaitu VGG16, VGG19, InceptionV3, ResNet101, dan ResNet152 diimplementasikan untuk menyelesaikan tugas klasifikasi yang ditergetkan. Selama pelatihan, lapisan arsitektur yang ada dibekukan sementara pengklasifikasi tambahan ditambahkan untuk melatih dataset yang telah disiapkan. Dari percobaan terlihat bahwa VGG19 memberikan kinerja terbaik dengan akurasi klasifikasi sebesar 97,37% pada epoch 50 dan ukuran batch 32. Hal ini membuktikan bahwa *transfer learning* menjadi solusi yang tepat dalam memecahkan masalah terkait identifikasi kematangan buah. Bhole dan Kumar [10] menggunakan teknik *transfer learning* dan model *pre-trained SqueezeNet* pada sistem pemilahan dan *grading* mangga untuk mengklasifikasikannya menjadi tiga kelas (Kelas Extra, Kelas-I, dan Kelas-II) dengan parameter ukuran, kematangan, dan grade. Hasil pengujian pada dataset RGB menunjukkan akurasi masing-masing parameter ukuran, kematangan, dan grade 90.67%, 96,27, dan 93.33%, dengan waktu *training* 30.31, 30.55, dan 30.03 menit. Sedangkan pada dataset Thermal menunjukkan akurasi 91.2%, 94.4%, dan 92.25% dengan waktu *training* 7.3, 7.21, dan 7.38 menit. Ashtiani et al. [11] menggunakan CNNs dengan pendekatan *transfer learning* dan model *pre-trained DenseNet*, InceptionV3, ResNet18, ResNet50, dan AlexNet untuk klasifikasi buah murbei dengan *genotype* putih dan hitam, jumlah citra sebanyak 2000 (masing-masing *genotype* 1000 citra). AlexNet dan ResNet18 menunjukkan kinerja terbaik dengan akurasi masing-masing 98.32% dan 98.65%. ResNet18 mampu mengklasifikasikan kedua *genotype* (murbei putih dan murbei hitam) dan kematangannya dari 600 citra buah dalam waktu 2.36 menit dengan akurasi 98.03%.

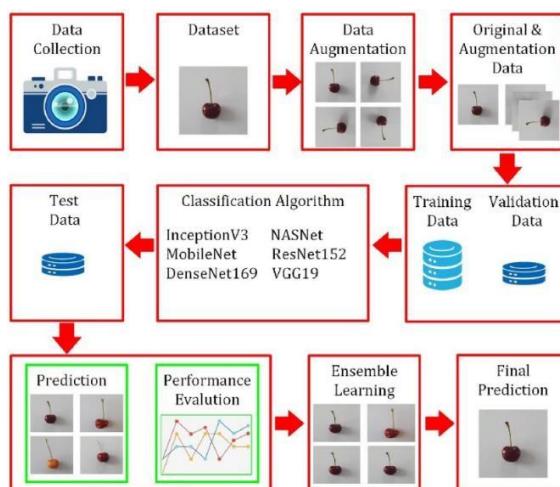
### 2.3. Ensemble Learning

*Ensemble learning* merupakan teknik yang menggabungkan *output* dari beberapa model pembelajaran mesin (*machine learning*) untuk meningkatkan kinerja dan stabilitas prediksi [12]. Dalam konteks identifikasi kematangan buah, dapat mengadaptasi pendekatan *ensemble learning* untuk mengatasi variasi yang kompleks dalam penampilan buah dan untuk meningkatkan akurasi identifikasi. Proses *ensemble learning* dalam konteks pengidentifikasi kematangan buah dapat

diuraikan sebagai berikut:

1. Pemilihan Arsitektur Model Dasar: Pertama-tama, memilih beberapa arsitektur model *deep learning* yang berbeda sebagai model dasar untuk *ensemble*. Arsitektur yang dipilih termasuk *Convolutional Neural Networks* (CNNs), yang terkenal karena kemampuannya dalam mengekstraksi fitur-fitur penting dari citra.
2. Pelatihan Model Dasar: Setiap model dasar dilatih secara terpisah menggunakan dataset citra buah yang telah diannotasi dengan label kematangan. Pelatihan dilakukan dengan menggunakan teknik optimasi yang sesuai dan mempertimbangkan parameter-parameter yang telah ditentukan sebelumnya.
3. Kombinasi *Output* Model: Setelah pelatihan selesai, output dari setiap model dasar digunakan untuk membentuk *ensemble*. Ada beberapa pendekatan yang mungkin digunakan untuk menggabungkan *output* model, seperti mengambil rata-rata prediksi, mengambil mode dari prediksi, atau menggunakan model meta-learner untuk menggabungkan prediksi dari model-model dasar.
4. Evaluasi dan Validasi: *Ensemble* yang dihasilkan kemudian dievaluasi menggunakan dataset validasi yang terpisah untuk mengukur kinerjanya dalam mengidentifikasi kematangan buah. Metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score* digunakan untuk menilai kinerja *ensemble*.
5. *Fine-Tuning* dan Optimisasi: Opsionalnya, *ensemble* dapat diperbaiki dengan melakukan *fine-tuning* dan optimisasi tambahan. Hal ini mungkin melibatkan parameter-parameter model atau penggunaan teknik *ensemble learning* yang lebih canggih, seperti penggunaan algoritma *boosting* atau *bagging*.

Kayaalp [13] menunjukkan keefektifan metode *ensemble learning* pada klasifikasi spesies buah ceri yang terdiri dari 3570 citra dari tujuh spesies ceri berbeda. Beberapa model *pre-trained transfer learning* yaitu VGG19, InceptionV3, ResNet152, DenseNet169, MobileNet, dan NasNet diimplementasikan untuk menyelesaikan tugas klasifikasi yang ditergetkan. Hasil pelatihan dengan datatambahan, diperoleh hasil terbaik dari model DenseNet169 dengan akurasi 99,57%. Dua model *deep learning* (DenseNet169 dan NASNet) dengan hasil terbaik ditransfer ke *ensemble learning* dan diperoleh tingkat akurasi 100% dengan model Maximum Voting. Arsitektur sistem yang digunakan dalam penelitian Kyaalp disajikan pada Gambar 1. Beberapa perbandingan penelitian yang telah menerapkan teknik *deep learning* dalam mengidentifikasi kematangan buah ditunjukkan pada Tabel 1.



**Gambar 1.** Blok Diagram Klasifikasi Ceri

**Tabel 1.** Perbandingan Penelitian dengan Metode *Deep Learning*

<b>Tahun dan Ref.</b>	<b>Buah</b>	<b>Jumlah Citra</b>	<b>Teknik</b>	<b>Hasil Pengujian</b>
2022 [8]	Pisang	2,460	CNNs, augmentasi data, AlexNet	Akurasi <i>training</i> 98.18% dan akurasi validasi 81.75% untuk dataset asli (227 x 227 piksel), akurasi <i>training</i> 99.80% dan akurasi validasi 99.44% untuk <i>augmented</i> dataset (112 x 112 piksel), akurasi <i>training</i> 100% dan akurasi validasi 89.84% untuk Fruit 36 dataset (100 x 100 x 3 piksel).
2022 [9]	Tomat	625	CNNs, <i>transfer learning</i> , VGG16, VGG19, InceptionV3, ResNet101, ResNet152	VGG19: Akurasi 96.05% (epoch 25), 97.37% (epoch 50), batch 32; waktu klasifikasi 29 detik(per epoch)
2020 [10]	Mangga	1500	CNNs, <i>transfer learning</i> , SqueezeNet	Akurasi ukuran, kematangan, dan grade: 90.67%, 96.27, dan 93.33% (epoch 5), dengan waktu <i>training</i> 30.31, 30.55, dan 30.03 menit untuk dataset RGB. Sedangkan pada dataset Thermal menunjukkan akurasi 91.2%, 94.4%, dan 92.25% (epoch 10), dengan waktu <i>training</i> 7.3, 7.21, dan 7.38 menit.
2021[11]	Murbei	2000	CNNs, <i>transfer learning</i> , DenseNet, InceptionV3, ResNet18, ResNet50, AlexNet	AlexNet: Akurasi tes 98.32% (epoch 42), loss 0.0559, waktu klasifikasi 1 menit ResNet18: Akurasi tes 98.65% (epoch 33), loss 0.0871, waktu klasifikasi 1.2 menit
2024 [13]	Ceri	3570	CNNs, <i>ensemble learning</i> , VGG19, InceptionV3, ResNet152, DenseNet169, MobileNet, dan NasNet	DenseNet169: Akurasi <i>training</i> 93,82% (epoch 67), akurasi validasi 93,82 (epoch 53), akurasi tes 99.57%. NasNet: Akurasi <i>training</i> 98.61% (epoch 53), akurasi validasi 98.85% (epoch 29), akurasi tes 98.56%. Dua model <i>deep learning</i> (DenseNet169 dan NASNet) dengan hasil terbaik ditransfer ke <i>ensemble learning</i> dan diperoleh tingkat akurasi 100% dengan model Maximum Voting.

### 3. HASIL DAN PEMBAHASAN

Secara tradisional, *computer vision* dan teknik pengolahan citra, menggunakan fitur-fitur sebagai masukan untuk identifikasi kematangan buah. Untuk melakukan identifikasi dari citra pada dataset secara lebih baik, augmentasi data dilakukan pada citra dengan metode yang berbeda. Augmentasi data dapat meningkatkan variasi dalam dataset pelatihan, sehingga membantu model *pre-trained* untuk belajar lebih baik [14]. Teknik augmentasi yang dapat diterapkan seperti rotasi, pergeseran, dan *flipping* pada citra buah. Setelah dilakukan augmentasi data, dataset dibagi menjadi

tiga peruntukan yaitu pelatihan, validasi, dan pengujian dengan mengaplikasikannya pada beberapa model *pre-trained* [8].

Pada *transfer learning*, dipilih model *pre-trained* yang sesuai dengan dataset sumbernya sebagai pengekstrak fitur. Model yang telah dilatih pada dataset yang lebih mirip dengan dataset target dapat memberikan hasil yang lebih baik [15].

Dataset citra buah yang telah diannotasi dengan label kematangan harus sesuai dengan format masukan yang diterima oleh model *pre-trained*. Dataset citra buah diolah dengan melakukan normalisasi nilai piksel, penyesuaian skala warna, dan transformasi lainnya untuk memastikan konsistensi dan kualitas data masukan [8][14].

Lapisan-lapisan teratas dari model *pre-trained* disesuaikan agar sesuai dengan tugas identifikasi kematangan buah. Lapisan-lapisan ini harus mampu mengekstraksi fitur-fitur yang relevan dengan kematangan buah. Lapisan teratas dapat dihapus dan ditambahkan lapisan-lapisan baru yang sesuai dengan tugas identifikasi kematangan buah.

Selanjutnya, melatih model dengan menggunakan dataset citra buah yang telah diproses menggunakan teknik *transfer learning*. *Learning rate* yang sesuai ditentukan selama pelatihan model. *Learning rate* yang terlalu tinggi dapat menyebabkan model tidak konvergen, sedangkan *learning rate* yang terlalu rendah dapat memperlambat konvergensi [16].

Setelah melakukan pelatihan awal dengan lapisan-lapisan teratas yang disesuaikan, dapat dilakukan *fine-tuning* pada beberapa lapisan lain dari model *pre-trained* sehingga memungkinkan model untuk lebih baik menyesuaikan dengan dataset target.

Setelah pelatihan selesai, lakukan evaluasi terus-menerus terhadap model menggunakan *confusion matrix* (akurasi, presisi, *recall*, dan *F1-score*) dan melakukan penyetelan parameter jika diperlukan. Evaluasi dapat menggunakan dataset validasi untuk memonitor kinerja model selama pelatihan dan menyesuaikan hyperparameter seperti *learning rate*, ukuran *batch*, dan *epoch* [16].

Dalam pelatihan model, pelatihan secara otomatis dihentikan jika nilai *loss* validasi tidak dapat ditingkatkan [13]. Pendekatan *ensemble learning* dapat digunakan dengan menggabungkan beberapa model hasil *transfer learning* sehingga dapat meningkatkan akurasi dan ketahanan model.

#### 4. KESIMPULAN DAN SARAN

Penerapan *deep learning* untuk identifikasi kematangan buah merupakan pendekatan yang menjanjikan dalam industri pertanian dan distribusi buah-buahan. Melalui penggunaan teknik-teknik seperti *data augmentation*, *transfer learning*, dan *ensemble learning* dapat meningkatkan akurasi dan efisiensi dalam mengidentifikasi kematangan buah secara otomatis.

Mekanisme untuk mengidentifikasi kematangan buah dengan akurasi yang tinggi dapat dilakukan dengan pemilihan model *pre-trained* yang sesuai, penyesuaian lapisan teratas, pelatihan dengan *learning rate* yang sesuai, penerapan augmentasi data, *fine-tuning*, evaluasi, dan penyetelan parameter. Pemilihan model *deep learning* yang sesuai, seperti CNNs, dan penyesuaian lapisan-lapisan teratas model *pre-trained* dapat membantu dalam mengekstraksi fitur-fitur penting dari citra buah untuk identifikasi kematangan. Penggunaan augmentasi data memperluas variasi dalam dataset pelatihan, sedangkan *finetuning* dan penyetelan parameter memungkinkan model untuk menyesuaikan dengan dataset target.

Selain itu, penerapan *ensemble learning* memungkinkan untuk menggabungkan *output* dari beberapa model yang berbeda, meningkatkan akurasi dan ketahanan model dalam mengenali kematangan buah. Dengan demikian, integrasi teknik-teknik *deep learning* yang canggih dapat membawa dampak positif dalam meningkatkan efisiensi dan produktivitas dalam industri pertanian serta meningkatkan kualitas produk buah-buahan yang dihasilkan.

Dengan terus melakukan penelitian dan pengembangan dalam bidang ini, diharapkan dapat menghadirkan solusi-solusi yang semakin inovatif dan efektif dalam menghadapi tantangan identifikasi kematangan buah di masa depan.

**DAFTAR PUSTAKA**

- [1] G. Vrbančič and V. Podgorelec, “Transfer learning with adaptive fine-tuning,” *IEEE Access*, vol. 8, no. December, pp. 196197–196211, 2020, doi: 10.1109/ACCESS.2020.3034343.
- [2] S. Dargan, M. Kumar, M. R. Ayyagari, and G. Kumar, “A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning,” *Arch. Comput. Methods Eng.*, vol. 27, no. 4, pp. 1071–1092, 2020, doi: 10.1007/s11831-019-09344-w.
- [3] wang xuemei, “Fruit classification method based on deep learning,” pp. 1–6, 2022, doi: 10.4108/eai.20-12-2021.2315013.
- [4] Y. Hendrawan *et al.*, “Classification of large green chilli maturity using deep learning,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 924, no. 1, 2021, doi: 10.1088/1755-1315/924/1/012009.
- [5] M. H. M. Noor and A. O. Ige, *A Survey on Deep Learning and State-of-the-arts Applications*, vol. 3270. 2024.
- [6] Y. I. Sulistya, E. T. Br Bangun, and D. A. Tyas, “CNN Ensemble Learning Method for Transfer learning: A Review,” *Ilk. J. Ilm.*, vol. 15, no. 1, pp. 45–63, 2023, doi: 10.33096/ilkom.v15i1.1541.45-63.
- [7] T. B. Shahi, C. Sitaula, A. Neupane, and W. Guo, “Fruit classification using attention-based MobileNetV2 for industrial applications,” *PLoS One*, vol. 17, no. 2 February, pp. 1–21, 2022, doi: 10.1371/journal.pone.0264586.
- [8] N. Aherwadi, U. Mittal, J. Singla, N. Z. Jhanjhi, A. Yassine, and M. S. Hossain, “Prediction of Fruit Maturity, Quality, and Its Life Using Deep Learning Algorithms,” *Electron.*, vol. 11, no. 24, 2022, doi: 10.3390/electronics11244100.
- [9] N. Begum and M. K. Hazarika, “Maturity detection of tomatoes using transfer learning,” *Meas. Food*, vol. 7, no. March, p. 100038, 2022, doi: 10.1016/j.meafoo.2022.100038.
- [10] V. Bhole and A. Kumar, “Mango Quality Grading using Deep Learning Technique: Perspectives from Agriculture and Food Industry,” *SIGITE 2020 - Proc. 21st Annu. Conf. Inf. Technol. Educ.*, no. October, pp. 180–186, 2020, doi: 10.1145/3368308.3415370.
- [11] S. H. Miraei Ashtiani, S. Javanmardi, M. Jahanbanifard, A. Martynenko, and F. J. Verbeek, “Detection of mulberry ripeness stages using deep learning models,” *IEEE Access*, vol. 9, pp. 100380–100394, 2021, doi: 10.1109/ACCESS.2021.3096550.
- [12] S. Y. Kim, S. J. Hong, E. Kim, C. H. Lee, and G. Kim, “Application of ensemble neural-network method to integrated sugar content prediction model for citrus fruit using Vis/NIR spectroscopy.,” *J. Food Eng.*, vol. 338, 2023, doi: 10.1016/j.jfoodeng.2022.111254.
- [13] K. Kayaalp, “A deep ensemble learning method for cherry classification,” *Eur. Food Res. Technol.*, vol. 250, no. 5, pp. 1513–1528, 2024, doi: 10.1007/s00217-024-04490-3.
- [14] M. Rodriguez, F. Pastor, and W. Ugarte, “Classification of fruit ripeness grades using a convolutional neural network and data augmentation,” *Conf. Open Innov. Assoc. Fruct*, vol. 2021-Janua, 2021, doi: 10.23919/FRUCT50888.2021.9347597.
- [15] V. Bhole and A. Kumar, “A transfer learning-based approach to predict the shelf life of fruit,” *Intel. Artif.*, vol. 24, no. 67, pp. 102–120, 2021, doi: 10.4114/intartif.vol24iss67pp102-120.
- [16] M. Fakhriansyah, L. D. Fathimahhayti, and S. Gunawan, “Klasifikasi Tingkat Kematangan

Buah Nanas Menggunakan Metode Deep Learning” *G-Tech J. Teknol. Terap.*, vol. 6, no. 2, pp. 295– 305, 2022, [Online]. Available: <https://ejournal.uniramalang.ac.id/index.php/g-tech/article/view/1823/1229>.