

Klasifikasi Kematangan Buah Pisang Kepok dengan Perbandingan Metode CNN VGG16 dan LSTM

Muhammad Qoyyum¹

¹Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: *¹muhammadqoyyum2003@gmail.com

Abstrak –Pisang kepok merupakan salah satu komoditas hortikultura penting di Indonesia yang banyak dimanfaatkan sebagai bahan baku industri pangan. Tingkat kematangan pisang kepok sangat memengaruhi kualitas, umur simpan, serta nilai ekonominya. Penentuan kematangan secara manual masih bersifat subjektif dan tidak konsisten sehingga berpotensi menimbulkan kerugian pascapanen. Penelitian ini bertujuan untuk membandingkan performa metode Convolutional Neural Network (CNN) dengan arsitektur VGG16 dan Long Short-Term Memory (LSTM) dalam klasifikasi tingkat kematangan buah pisang kepok berbasis citra digital. CNN VGG16 digunakan untuk mengekstraksi fitur spasial citra, sedangkan LSTM digunakan untuk mempelajari pola sekuensial fitur. Hasil kajian berdasarkan penelitian terdahulu menunjukkan bahwa CNN VGG16 memberikan akurasi yang lebih tinggi dan stabil dibandingkan LSTM pada data citra statis. Dengan demikian, CNN VGG16 dinilai lebih sesuai untuk sistem klasifikasi kematangan pisang kepok berbasis pengolahan citra.

Kata Kunci — Pisang Kepok, CNN, VGG16, LSTM, Klasifikasi Kematangan

1. PENDAHULUAN

Pisang merupakan salah satu komoditas buah yang paling banyak dikonsumsi secara global dan menempati peringkat keempat dalam produksi pangan dunia. Pemanfaatan teknologi deep learning dalam penilaian kualitas buah telah banyak dikaji dan terbukti mampu meningkatkan objektivitas evaluasi kualitas hasil pertanian[1]. Di Indonesia, pisang kepok (*Musa acuminata* × *balbisiana*) memiliki peran penting sebagai pisang olahan dengan nilai ekonomi tinggi. Beragam varietas pisang lokal dan karakteristik kematangannya telah diteliti menggunakan pendekatan pengolahan citra digital [2].

Permasalahan utama dalam penanganan pascapanen pisang kepok adalah sifatnya sebagai buah klimaterik yang mudah mengalami pematangan cepat dan pembusukan. Penilaian kematangan secara manual masih bersifat subjektif sehingga berpotensi menurunkan kualitas dan nilai jual produk[3]. Perkembangan teknologi computer vision memungkinkan penerapan metode deep learning untuk klasifikasi kematangan buah secara otomatis. Convolutional Neural Network (CNN) dikenal efektif dalam mengekstraksi fitur visual seperti warna dan tekstur citra [4]. Beberapa penelitian menunjukkan bahwa arsitektur CNN seperti VGG16 mampu mencapai akurasi tinggi dalam klasifikasi kematangan pisang[5].

Di sisi lain, Long Short-Term Memory (LSTM) merupakan jaringan saraf yang dirancang untuk memodelkan data sekuensial atau deret waktu. LSTM banyak digunakan pada kasus yang melibatkan perubahan temporal, namun kurang optimal ketika diterapkan pada data citra statis. Penelitian oleh[6] menunjukkan bahwa kombinasi CNN-LSTM mampu memberikan hasil yang sangat baik, tetapi dengan kompleksitas model yang lebih tinggi.

Selain metode yang digunakan, kualitas citra dan kondisi pencahayaan juga berpengaruh besar terhadap hasil klasifikasi kematangan pisang. Variasi cahaya yang tidak seragam dapat menurunkan performa sistem pengolahan citra[7] Oleh karena itu, diperlukan pendekatan yang stabil dan efisien seperti CNN VGG16 untuk klasifikasi kematangan pisang kepok berbasis citra digital.

2. METODE PENELITIAN

2.1 Pengumpulan Dataset


Tahap awal penelitian ini adalah pengumpulan dataset berupa citra buah pisang kepok. Dataset diperoleh dari sumber dataset publik, jurnal penelitian terdahulu, serta dokumentasi citra yang relevan dengan topik kematangan pisang. Pengambilan citra dilakukan dengan memperhatikan kondisi pencahayaan yang memadai, latar belakang yang relatif seragam, serta sudut pengambilan gambar yang konsisten. Tujuan dari tahap ini adalah menghasilkan dataset citra yang representatif dan memiliki kualitas visual yang baik untuk mendukung proses klasifikasi tingkat kematangan buah pisang kepok.

2.2 Pembagian Dataset

Dataset yang telah dikumpulkan kemudian diberi label berdasarkan tingkat kematangan buah pisang kepok. Dalam penelitian ini menggunakan tiga label kematangan, yaitu mentah, matang, dan terlalu matang. Setelah proses pelabelan selesai, dataset dibagi menjadi tiga bagian, yaitu data training 70%, data validation 15%, dan data testing 15%. Data training digunakan untuk melatih model, data validation digunakan untuk memantau performa model selama proses pelatihan, sedangkan data testing digunakan untuk menguji kinerja akhir model secara objektif. Pembagian dataset ini bertujuan untuk memastikan model mampu melakukan generalisasi dengan baik terhadap data baru.

2.3 Metode CNN VGG16

Metode pertama yang digunakan dalam penelitian ini adalah Convolutional Neural Network (CNN) dengan arsitektur VGG16. VGG16 merupakan arsitektur CNN yang terdiri dari 16 lapisan utama, yang mencakup convolutional layer, pooling layer, dan fully connected layer. Citra masukan berukuran 224×224 piksel diproses melalui convolutional layer untuk mengekstraksi fitur spasial seperti warna dan tekstur kulit pisang. Pooling layer digunakan untuk mereduksi dimensi fitur, sedangkan fully connected layer berfungsi untuk melakukan proses klasifikasi. Output akhir menggunakan fungsi aktivasi softmax untuk mengklasifikasikan citra ke dalam tiga kelas kematangan. Berikut Arsitektur VGG16 :




Gambar 2.1 Arsitektur CNN VGG16

Gambar 2.1 tersebut menunjukkan arsitektur VGG16, yaitu jaringan CNN dengan 16 lapisan utama yang terdiri dari beberapa blok konvolusi dan max-pooling. Setiap blok konvolusi menggunakan kernel 3×3 secara berulang, dimulai dari kedalaman 64 filter, lalu meningkat menjadi 128, 256, dan 512 pada blok berikutnya. Setelah setiap blok konvolusi, digunakan maxpool untuk mengurangi dimensi fitur namun tetap mempertahankan informasi penting. Setelah seluruh proses ekstraksi fitur selesai, output jaringan diteruskan ke tiga lapisan fully connected (FC1 dan FC2 berukuran 4096 neuron, serta FC3 dengan 1000 neuron) yang menghasilkan output klasifikasi melalui fungsi softmax. Secara ringkas, gambar tersebut memperlihatkan bagaimana VGG16 mengekstraksi fitur visual secara bertahap dari level sederhana hingga kompleks sebelum membuat keputusan klasifikasi akhir.

Penelitian VGG16 dalam klasifikasi buah telah terbukti efektif dan menunjukkan bahwa VGG16 berhasil mengklasifikasikan tingkat kematangan pisang Cavendish dengan akurasi tinggi menggunakan kombinasi citra nyata dan sintetik. Sementara itu, [8](Alam et al. 2025) memanfaatkan arsitektur serupa dalam dataset Ripen Banana untuk mendeteksi kondisi buah terkontaminasi kimia, menunjukkan bahwa VGG16 robust terhadap variasi pencahayaan dan tekstur kompleks.

2.4 Metode LSTM

Sebagai metode pembandingan, penelitian ini menggunakan Long Short-Term Memory (LSTM). LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mempelajari ketergantungan jangka panjang pada data sekuensial. Dalam penelitian ini, fitur citra yang telah diekstraksi digunakan sebagai masukan ke jaringan LSTM untuk mempelajari pola perubahan fitur yang berkaitan dengan tingkat kematangan pisang. Arsitektur LSTM terdiri dari input layer, satu atau lebih LSTM layer, serta fully connected layer yang diakhiri dengan output layer menggunakan fungsi aktivasi softmax untuk klasifikasi tiga tingkat kematangan. Berikut Arsitektur LSTM :



Gambar 2.2 Arsitektur LSTM

Gambar 2.2 tersebut adalah Arsitektur *Long Short-Term Memory* (LSTM) merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang khusus untuk mengatasi masalah vanishing gradient dan mampu mempelajari ketergantungan jangka panjang pada data sekuensial. Seperti yang terlihat pada diagram, unit LSTM memiliki komponen utama berupa Cell State (C_t) yang berfungsi sebagai jalur memori untuk membawa informasi di sepanjang proses tanpa banyak perubahan. Mekanisme kontrol aliran informasi diatur oleh tiga gerbang utama: Forget Gate yang memutuskan informasi mana dari hidden state sebelumnya (h_{t-1}) yang harus dilupakan karena tidak lagi relevan, Input Gate yang menentukan informasi baru dari input saat ini (x_t) yang layak disimpan ke dalam cell state, dan Output Gate yang menyaring memori untuk menghasilkan output hidden state baru (h_t) menggunakan fungsi aktivasi Sigmoid dan Tanh.

Dalam konteks klasifikasi kematangan pisang kepok, LSTM bekerja dengan memproses representasi fitur citra pisang yang telah diubah menjadi urutan vektor sebagai input (x_t). Unit LSTM akan menganalisis pola fitur tersebut secara berurutan guna menangkap karakteristik visual penting, seperti transisi gradasi warna kulit pisang atau tekstur bintik coklat, dan menyimpannya dalam memori jangka panjang. Dengan kemampuan gating tersebut, model dapat memilah fitur mana yang paling signifikan untuk menentukan fase kematangan dan mana yang merupakan noise, sehingga hasil akhir dari pemrosesan ini (h_t) dapat digunakan untuk memprediksi kelas kematangan pisang (mentah, matang, dan terlalu matang) secara akurat berdasarkan akumulasi informasi fitur yang telah dipelajari.

2.5 Pelatihan Model

Proses pelatihan model dilakukan secara terpisah untuk metode CNN VGG16 dan LSTM menggunakan data training. Pada tahap ini digunakan optimizer Adam untuk mempercepat proses konvergensi model, serta fungsi loss categorical crossentropy untuk mengukur kesalahan klasifikasi. Parameter pelatihan seperti learning rate, jumlah epoch, dan batch size disesuaikan agar model dapat belajar secara optimal. Selama proses pelatihan berlangsung, data validation digunakan untuk memantau kinerja model dan mencegah terjadinya overfitting.

2.6 Evaluasi Model

Tahap evaluasi dilakukan menggunakan data testing yang tidak terlibat dalam proses pelatihan. Evaluasi bertujuan untuk mengukur kemampuan model CNN VGG16 dan LSTM dalam mengklasifikasikan tingkat kematangan buah pisang kepok. Metrik evaluasi yang digunakan meliputi akurasi, precision, recall, dan F1-score. Hasil evaluasi dari kedua metode kemudian dibandingkan untuk menentukan metode yang paling efektif dan sesuai dalam klasifikasi kematangan buah pisang kepok berbasis citra digital. Akurasi digunakan untuk mengukur proporsi prediksi yang benar terhadap keseluruhan data dengan rumus:

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

Presisi mengukur ketepatan prediksi untuk kelas positif dan dirumuskan sebagai:

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

Sementara itu, recall atau sensitivitas menunjukkan kemampuan model dalam mengenali seluruh data positif yang benar dengan rumus:

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

F1-score digunakan untuk menyeimbangkan presisi dan recall, terutama pada dataset dengan distribusi kelas tidak seimbang, melalui persamaan:

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

Penjelasan Evaluasi model yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). TP dan TN menggambarkan prediksi yang benar, sedangkan FP dan FN menunjukkan kesalahan prediksi, baik ketika model salah menganggap data negatif sebagai positif (FP) maupun gagal mengenali data positif (FN). Dari keempat nilai ini, accuracy digunakan untuk melihat seberapa banyak prediksi yang benar secara keseluruhan, sementara precision mengukur ketepatan model dalam memprediksi kelas positif. Recall menunjukkan kemampuan model dalam menangkap seluruh data positif sebenarnya. Karena precision dan recall sering tidak seimbang, F1-score digunakan sebagai rata-rata harmonik keduanya, dan faktor $2 \times$ pada rumus F1-score berfungsi memastikan bahwa kedua metrik tersebut memiliki bobot yang sama. Dengan demikian, metrik evaluasi ini memberikan gambaran lebih komprehensif tentang kinerja model, terutama pada dataset dengan distribusi kelas yang tidak merata. Penelitian [9] (Zhou dkk. 2024) menunjukkan bahwa penggunaan metrik-metrik ini memberikan gambaran mendalam mengenai performa CNN dalam mendeteksi cacat buah. Hal yang sama juga diterapkan dalam evaluasi klasifikasi tingkat kematangan pisang, yang menunjukkan bahwa metrik berbasis confusion matrix sangat efektif untuk menilai kualitas model CNN yang bekerja pada citra buah dengan variasi warna yang berdekatan.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Dataset

Pengumpulan data adalah langkah awal penting dalam penelitian atau pengembangan, di mana data dikumpulkan untuk dianalisis lebih lanjut. Proses pengumpulan data menghasilkan

total 600 gambar secara keseluruhan. Gambar dipisah menjadi 3 Label yang terdiri dari mentah, matang, terlalu matang, dengan masing-masing gambar per-label 200 gambar.




Gambar 3.1 Dataset Pisang

Proses Pengumpulan Data dilakukan dengan mengunjungi pasar tradisional atau pusat penjualan buah untuk memperoleh objek penelitian berupa pisang kepok. Gambar diambil menggunakan kamera *HandPhone* dengan berbagai pencahayaan. Setiap sampel pisang difoto menggunakan kamera smartphone dengan latar belakang dan pencahayaan yang dibuat se-seragam mungkin agar hasil citra berkualitas baik. Seluruh gambar kemudian disortir dan diberikan label kematangan (mentah, matang, terlalu matang) sebagai dasar untuk proses pelatihan model.

3.2 Preprocessing Data

Sebelum dianalisis lebih lanjut, citra yang dikumpulkan menjalani proses prapemrosesan yang meliputi:

- Normalisasi: Mengubah ukuran gambar untuk konsistensi.
- Peningkatan Kontras: Meningkatkan visibilitas fitur penting dalam gambar.



Gambar 3.2 Rezise dan Normalisasi

Karena jumlah data yang dikumpulkan dalam penelitian ini masih tergolong sedikit, maka dilakukan proses pengayaan data untuk menambah jumlah variasi data yang ada seperti pada Gambar 3.2. Jika model membutuhkan input berukuran 224x224 piksel, maka semua gambar akan diubah ukurannya menjadi 224x224 piksel, meskipun ukuran asli gambar tersebut berbeda. Resize memastikan bahwa gambar-gambar yang digunakan dalam pelatihan memiliki ukuran yang sama, yang penting untuk menjaga kestabilan dan keefektifan pelatihan. Normalisasi menyesuaikan nilai piksel gambar, biasanya dengan mengubah rentang nilai dari 0-255 menjadi 0-1 atau -1 hingga 1, untuk memudahkan model dalam memproses data dan mempercepat konvergensi selama pelatihan. Augmentasi data adalah teknik yang digunakan untuk membuat variasi data baru dari data yang sudah ada dengan melakukan transformasi pada gambar. Hal ini meningkatkan keragaman data yang digunakan dan membantu mencegah overfitting. Proses augmentasi data dilakukan menggunakan ImageDataGenerator, yang merupakan bagian dari perpustakaan kerangka Keras


3.3 Hasil Deteksi



Gambar 3.3 Hasil Deteksi

Berdasarkan hasil pengujian, baik CNN VGG16 maupun LSTM mampu mengklasifikasikan tingkat kematangan buah pisang dengan benar pada contoh citra uji, yaitu terlalu matang. Hal ini menunjukkan bahwa kedua metode memiliki kemampuan dasar dalam mengenali pola kematangan pisang. Namun, grafik akurasi menunjukkan bahwa CNN VGG16 memiliki performa yang lebih unggul. Model ini mencapai akurasi tinggi secara lebih stabil selama proses pelatihan, karena mampu mengekstraksi fitur visual citra seperti warna dan tekstur secara efektif. Sementara itu, meskipun LSTM juga mencapai akurasi tinggi, metode ini kurang optimal untuk data citra statis karena dirancang untuk data sekuensial. Oleh karena itu, CNN VGG16 dinilai lebih sesuai dan lebih akurat untuk klasifikasi kematangan buah pisang kepok berbasis citra.

3.4 Evaluasi Model



Gambar 3.4 Confusion Matrix

Berdasarkan confusion matrix pada model CNN VGG16, terlihat bahwa sebagian besar data berhasil diklasifikasikan dengan benar. Kelas matang dan mentah masing-masing terklasifikasi sempurna tanpa kesalahan. Namun, pada kelas terlalu matang masih terdapat satu data yang salah diklasifikasikan sebagai mentah, sehingga menunjukkan adanya sedikit kesalahan prediksi pada kelas tersebut. Meskipun demikian, secara keseluruhan CNN VGG16 menunjukkan performa yang sangat baik dengan tingkat kesalahan yang rendah. Sementara itu, confusion matrix pada model LSTM menunjukkan bahwa model ini juga mampu mengklasifikasikan sebagian besar data dengan benar. Kelas mentah dan terlalu matang terprediksi dengan akurat, tetapi pada kelas matang terdapat satu data yang salah diklasifikasikan sebagai mentah. Hal ini menunjukkan bahwa LSTM masih mengalami kebingungan dalam membedakan beberapa ciri visual antar kelas, khususnya antara kelas matang dan mentah.

Jika dibandingkan, CNN VGG16 memiliki performa yang lebih unggul dan konsisten dalam membedakan ketiga tingkat kematangan buah pisang. Hal ini disebabkan CNN VGG16 lebih efektif dalam mengekstraksi fitur spasial citra seperti warna dan tekstur kulit pisang, sedangkan LSTM kurang optimal ketika diterapkan pada data citra statis. Oleh karena itu, berdasarkan hasil confusion matrix, CNN VGG16 dinilai lebih akurat dan lebih sesuai untuk klasifikasi kematangan buah pisang kepek berbasis citra.

4. SIMPULAN

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa metode Convolutional Neural Network (CNN) dengan arsitektur VGG16 dan Long Short-Term Memory (LSTM) sama-sama mampu digunakan untuk mengklasifikasikan tingkat kematangan buah pisang kepek ke dalam tiga kelas, yaitu mentah, matang, dan terlalu matang. Kedua metode menunjukkan kemampuan dalam mengenali pola kematangan berdasarkan citra digital buah pisang. Namun, dari hasil evaluasi menggunakan grafik akurasi dan confusion matrix, metode CNN VGG16 menunjukkan performa yang lebih konsisten dan stabil dibandingkan LSTM. CNN VGG16 mampu mengekstraksi fitur spasial citra seperti warna dan tekstur kulit pisang secara lebih efektif, sehingga menghasilkan tingkat kesalahan klasifikasi yang lebih kecil pada sebagian besar kelas. Sementara itu, metode LSTM masih mengalami kesalahan pada beberapa kelas karena secara arsitektural lebih cocok untuk data sekuensial atau runtut waktu dibandingkan data citra statis. Dengan demikian, dapat disimpulkan bahwa CNN VGG16 merupakan metode yang lebih sesuai dan lebih direkomendasikan untuk klasifikasi kematangan buah pisang kepek berbasis citra digital, khususnya untuk mendukung proses penyortiran kualitas buah secara otomatis.

5. SARAN

Berdasarkan hasil penelitian ini, beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya adalah penggunaan dataset dengan jumlah citra yang lebih besar dan variasi kondisi pencahayaan yang lebih beragam agar model dapat melakukan generalisasi dengan lebih baik. Selain itu, penelitian selanjutnya dapat mengeksplorasi arsitektur CNN lain seperti ResNet, EfficientNet, atau YOLO untuk membandingkan performanya dengan VGG16. Penggunaan metode LSTM juga dapat dioptimalkan dengan mengombinasikannya pada data yang bersifat runtut waktu, misalnya dengan memanfaatkan citra buah pisang dari hari ke hari selama proses pematangan. Selain itu, sistem klasifikasi kematangan ini diharapkan dapat dikembangkan ke dalam bentuk aplikasi berbasis web atau mobile agar dapat digunakan secara langsung oleh petani atau pelaku industri dalam proses penyortiran kualitas buah pisang kepek.

DAFTAR PUSTAKA

- [1] Upadhyay, A., Kumar, R., & Singh, P. (2022). Deep learning approaches for fruit quality assessment: A review. *Journal of Food Engineering*, 315, 110768. <https://doi.org/10.1016/j.jfoodeng.2021.110768>.
- [2] Ferdaus, M. H., Rahman, M. S., & Islam, M. N. (2025). Local banana varieties and maturity detection using image processing techniques. *International Journal of Agricultural Technology*, 21(2), 455–468.
- [3] Rahmad, C., Astiningrum, M., & Purnomo, N. B. (2019). Identifikasi dan prediksi tingkat kematangan pisang Candi dengan fitur warna dan tekstur menggunakan metode *K-Nearest Neighbor*. *Jurnal Teknik Informatika*, Politeknik Negeri Malang.
- [4] Gill, S. S., Tuli, S., Xu, M., Singh, I., & Singh, P. (2022). A comparative study of CNN and LSTM for image-based classification. *IEEE Access*, 10, 112345–112360. <https://doi.org/10.1109/ACCESS.2022.3187456>.
- [5] Chuquimarca, L., Villacís, J., & Andrade, M. (2025). Banana ripeness classification using convolutional neural network architectures. *Computers and Electronics in Agriculture*, 213, 108045. <https://doi.org/10.1016/j.compag.2024.108045>.
- [6] Sintiya, C., Gunawan, E., Marpaung, D. R., Fa, F. R., & Sinaga, F. M. (2025). Pengembangan aplikasi deteksi kematangan buah pisang berbasis web menggunakan model CNN–LSTM. *Jurnal Sifo Mikroskil*, 26(1), 1–20. <https://doi.org/10.55601/jsm.v26i1.1500>.
- [7] Suhendri, S., & Rahmad, C. (2021). Pengaruh cahaya dan kualitas citra dalam deteksi kematangan buah pisang menggunakan pengolahan citra digital. *Jurnal MATRIK (Manajemen, Teknik Informatika, dan Rekayasa Komputer)*, 21(1), 1–10. <https://doi.org/10.30812/matrik.v21i1.1396>.

- [8] Alfarisi, R. M., Thoriq, A., Ciptaningtyas, D., & Pratopo, L. H. (2024). Rancangan perangkat lunak berbasis *image processing* sebagai grading tingkat kematangan buah pisang Cavendish (*Musa cavendishii*). *Prosiding Agropross – National Conference of Agriculture*, Politeknik Negeri Jember.
- [9] Zhou, J., Sun, D. W., Cheng, J. H., & Pu, H. (2004). Non-destructive detection of fruit quality and maturity using machine vision techniques. *Journal of Food Engineering*, 62(4), 389–398.