

Deteksi dan Klasifikasi Kue Tradisional Indonesia Menggunakan YOLOv8

Detection and Classification of Traditional Indonesian Cakes Using YOLOv8

Arin Ayu Silvyani Mustofa¹⁾, Resty Wulanningrum²⁾, Julian Sahertian³⁾

^{1), 2), 3)} Program Studi Teknik Informatika, Fakultas Teknik, Universitas Nusantara PGRI Kediri
Jl Raya Telang, PO. BOX 2, Kamal, Bangkalan

Email : arinayu817@gmail.com¹⁾, restyw@unpkediri.ac.id²⁾, juliansahertian@unpkediri.ac.id³⁾

Abstrak

Kue tradisional Indonesia merupakan bagian dari warisan budaya yang memiliki kekayaan cita rasa, bentuk, dan nilai historis yang tinggi. Namun, kurangnya pengenalan terhadap jenis-jenis kue ini di kalangan generasi muda menyebabkan perlunya pendekatan baru dalam upaya pelestariannya. Penelitian ini bertujuan untuk mengembangkan sistem deteksi jenis kue tradisional berbasis pengolahan citra menggunakan algoritma YOLOv8. Lima jenis kue yang dikenali dalam penelitian ini adalah kue lumpur, kue lapis, kue wingko, kue dadar gulung, dan kue putu ayu. Dataset citra diperoleh melalui kombinasi pengambilan gambar langsung dan dataset publik, kemudian diberi label secara manual menggunakan platform Roboflow. Model dilatih menggunakan framework PyTorch dan dievaluasi berdasarkan metrik *precision*, *recall*, *F1-score*, dan *mean Average Precision (mAP)*. Hasil pengujian menunjukkan bahwa sistem mampu mencapai rata-rata *mAP* sebesar 89,9% dan *F1-score* sebesar 86,5%, dengan tingkat kesalahan klasifikasi yang cukup rendah. Temuan ini menunjukkan bahwa algoritma YOLOv8 bisa dibilang efektif dalam mendeteksi objek visual yang memiliki kemiripan tinggi, serta berpotensi besar untuk diterapkan dalam pelestarian budaya kuliner secara digital. Sistem ini juga dapat dikembangkan lebih lanjut sebagai media edukasi berbasis teknologi yang mendukung konservasi kekayaan kuliner lokal Indonesia.

Kata kunci: YOLOv8, Deteksi Objek, Kue Tradisional, Pengolahan Citra, Computer Vision

Abstract

Indonesian traditional cakes are part of the cultural heritage, characterized by their rich flavors, unique forms, and significant historical value. However, the lack of recognition among younger generations necessitates a new approach to preservation efforts. This study aims to develop an image processing-based detection system for traditional cake types using the YOLOv8 algorithm. The five types of cakes identified in this research are lumpur cake, lapis cake, wingko cake, dadar gulung cake, and putu ayu cake. The image dataset was obtained through a combination of direct image capture and public datasets, and was manually annotated using the Roboflow platform. The model was trained using the PyTorch framework and evaluated based on *precision*, *recall*, *F1-score*, and *mean Average Precision (mAP)* metrics. Experimental results show that the system achieved an average *mAP* of 89.9% and an *F1-score* of 86.5%, with a relatively low classification error rate. These findings indicate that the YOLOv8 algorithm is effective in detecting visually similar objects and holds significant potential for application in the digital preservation of culinary heritage. The system can also be further developed as a technology-based educational medium to support the conservation of Indonesia's local culinary wealth.

Keywords: YOLOv8, Object Detection, Cake Traditional, Image Processing, Computer Vision

1. PENDAHULUAN

Kue tradisional Indonesia merupakan warisan budaya yang mencerminkan keberagaman etnis, tradisi, dan kearifan lokal dari berbagai daerah di nusantara[1]. Setiap jenis kue memiliki ciri khas tersendiri, baik dari segi rasa, bentuk, bahan baku, hingga nilai sosial dan budaya yang melekat dalam penggunaannya[2]. Contohnya, Putu Ayu sering disajikan dalam acara adat, sementara Wingko dikenal sebagai oleh-oleh khas daerah tertentu. Lebih dari sekadar makanan, kue tradisional memegang peran penting sebagai simbol budaya dalam berbagai upacara dan perayaan. Sayangnya, dalam arus globalisasi dan modernisasi yang pesat, keberadaan kue tradisional semakin terpinggirkan[1]. Makanan cepat saji dan jajanan modern lebih menarik bagi

generasi muda karena kemudahan akses dan gaya hidup praktis. Hal ini mengakibatkan menurunnya minat terhadap kue tradisional, yang pada akhirnya mengancam kelestarian dan keberlanjutan pengetahuan kuliner lokal. Untuk itu, dibutuhkan upaya pelestarian yang tidak hanya bersifat konvensional, tetapi juga memanfaatkan teknologi digital sebagai media pelestarian yang adaptif terhadap perkembangan zaman[3]. Penelitian [3] menunjukkan bahwa metode *deep learning* dengan pendekatan transfer learning, khususnya menggunakan arsitektur *MobileNetV2*, mampu mengklasifikasi lima jenis jajanan tradisional Indonesia dengan akurasi mencapai 98%. Hal ini membuktikan bahwa teknologi kecerdasan buatan memiliki potensi besar dalam mendukung pelestarian kuliner melalui pendekatan visual berbasis citra. Namun, pendekatan berbasis deteksi objek secara langsung masih jarang digunakan. Oleh karena itu, penelitian ini dilakukan sebagai upaya modernisasi pelestarian budaya kuliner melalui teknologi deteksi visual berbasis YOLOv8, yang mampu mendeteksi dan mengklasifikasi objek kue secara akurat.

Kemajuan teknologi, khususnya dalam bidang kecerdasan buatan dan pengolahan citra digital, menawarkan solusi potensial dalam mengenalkan kembali kue tradisional kepada masyarakat[4]. Teknologi deteksi objek berbasis algoritma seperti YOLO (*You Only Look Once*) memungkinkan sistem untuk mengenali berbagai objek dalam gambar secara otomatis dan cepat[5]. YOLOv8, versi terbaru dari algoritma ini, menawarkan peningkatan signifikan dalam akurasi dan efisiensi melalui arsitektur modern yang mampu menangani variasi objek secara lebih andal fitur yang sangat cocok untuk mengklasifikasikan beragam bentuk kue tradisional[6],[7].

Penelitian ini menerapkan YOLOv8 untuk mendeteksi lima jenis kue tradisional Indonesia: Dadar Gulung, Lapis, Lumpur, Putu Ayu, dan Wingko. Dataset dikumpulkan dari berbagai sumber, kemudian dianotasi menggunakan *Roboflow* untuk membangun data berkualitas tinggi. Lima varian model YOLOv8 diuji dan dievaluasi menggunakan metrik seperti *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *mAP@50*[8]. Hasilnya menunjukkan bahwa YOLOv8x memiliki performa terbaik. Penelitian ini tidak hanya membuktikan efektivitas model dalam konteks budaya lokal, tetapi juga membuka jalan bagi pengembangan aplikasi edukatif berbasis AI untuk mendukung pelestarian kuliner tradisional Indonesia secara interaktif dan berkelanjutan.

2. DASAR TEORI

Kecerdasan Buatan (*Artificial Intelligence/AI*) merupakan bidang ilmu komputer yang bertujuan untuk menciptakan sistem yang dapat meniru kemampuan berpikir dan belajar manusia[9]. Salah satu cabangnya adalah pembelajaran mendalam (*Deep Learning*), yang menggunakan jaringan saraf tiruan berlapis-lapis untuk mengenali pola dan fitur kompleks dalam data, terutama citra[4],[10],[11]. Teknologi ini sangat efektif dalam pengolahan gambar, termasuk dalam deteksi objek (*object detection*), yaitu proses menemukan dan mengklasifikasikan objek-objek spesifik dalam sebuah gambar beserta lokasinya. Salah satu algoritma deteksi objek yang populer adalah YOLO (*You Only Look Once*), yang dikenal karena kecepatannya dan kemampuannya melakukan deteksi secara *real-time* dalam satu proses pemindaian gambar secara menyeluruh.

YOLOv8 merupakan versi terbaru dari algoritma YOLO yang membawa peningkatan dari segi arsitektur dan akurasi. Dengan *backbone CSPDarknet*, penggunaan *PANet* untuk penggabungan fitur spasial, dan *decoupled head* untuk klasifikasi serta regresi *bounding box* secara terpisah, YOLOv8 mampu mendeteksi objek dengan lebih baik di berbagai kondisi visual[12],[13]. Algoritma ini hadir dalam beberapa varian, mulai dari YOLOv8n (*nano*) hingga YOLOv8x (*extra-large*), yang dapat disesuaikan dengan kebutuhan komputasi dan performa. Untuk mengevaluasi kinerja deteksi objek, digunakan metrik seperti *Precision*, *Recall*, *F1-Score*, dan *Mean Average Precision* (mAP), terutama *mAP@0.5* yang mengukur seberapa baik model mengidentifikasi objek dengan ambang batas *Intersection over Union* (IoU) sebesar 0.5. Kombinasi teknologi ini menjadi dasar penting dalam pengembangan sistem deteksi otomatis kue tradisional yang diangkat dalam penelitian ini.

3. METODOLOGI PENELITIAN

3.1 Data Preparation

Data yang digunakan dalam penelitian ini merupakan gambar-gambar kue tradisional Indonesia yang terdiri dari lima kelas: Dadar Gulung, Lapis, Lumpur, Putu Ayu, dan Wingko. Total sebanyak 150 gambar digunakan, dengan masing-masing kelas terdiri dari kurang lebih 30 gambar. Gambar diperoleh dari berbagai sumber *online* dan pengambilan manual menggunakan kamera ponsel. Gambar-gambar tersebut kemudian dianotasi menggunakan platform *Roboflow* dengan metode *bounding box* untuk setiap jenis kue. Selanjutnya, dilakukan proses *augmentasi* guna meningkatkan keragaman data dan mencegah *overfitting*[14]. *Augmentasi* dilakukan dengan teknik seperti *flipping*, *rotating*, *zooming*, dan penyesuaian pencahayaan. Ukuran seluruh citra diubah menjadi 640×640 piksel untuk menyamakan skala input ke dalam model YOLOv8. Jumlah data dalam penelitian ini lebih sedikit dibandingkan dengan dataset sekunder pada penelitian [2], yang menggunakan 3.250-3.900 dari 13 kelas kue. Meskipun demikian, dataset yang digunakan telah melalui proses *augmentasi* dan anotasi yang cermat guna memastikan kualitas pelatihan tetap optimal.

3.2 Split Data

Setelah seluruh data gambar selesai dianotasi, dataset dibagi menjadi tiga subset utama: *training set* (70%), *validation set* (20%), dan *testing set* (10%). Tujuan pembagian ini adalah untuk memisahkan data yang digunakan dalam proses pelatihan, evaluasi selama pelatihan, dan pengujian akhir model secara objektif. Proses pembagian dilakukan secara otomatis menggunakan platform *Roboflow*, yang menjamin distribusi kelas tetap merata di setiap subset, menghindari duplikasi data, serta menjaga keseimbangan jumlah objek antar kelas. *Roboflow* juga menghasilkan struktur dataset yang kompatibel dengan arsitektur YOLO, termasuk file konfigurasi, direktori gambar, dan label dalam format .txt. Dataset hasil split ini kemudian diunduh dan digunakan dalam pelatihan model deteksi objek, dengan struktur yang rapi dan terkelola untuk mendukung kemampuan generalisasi model terhadap data baru.


3.3 Modeling

Pada penelitian ini, model YOLOv8 digunakan tanpa melakukan modifikasi pada arsitektur aslinya. Struktur dasar YOLOv8 dipertahankan sesuai dengan arsitektur yang diusulkan dalam literatur, sementara penyesuaian hanya dilakukan pada parameter pelatihan untuk mengoptimalkan kinerja model, seperti pemilihan *optimizer*, nilai *learning rate*, *batch size*, *image size*, serta varian model YOLOv8 yang digunakan[15].

YOLOv8 adalah algoritma deteksi objek *real-time* yang merupakan versi terbaru dari rangkaian algoritma YOLO, yang memiliki empat komponen utama, yaitu *Input*, *Backbone*, *Feature Enhancement (Neck)*, *Decoupling Head (Head)*. *Backbone network* berfungsi sebagai komponen utama untuk melakukan ekstraksi fitur dari gambar input[11]. YOLOv8 menggunakan kombinasi teknologi *CSPNet* dan *Darknet53* untuk mendapatkan peta fitur yang kaya. Setelah itu, fitur ini diproses menggunakan modul *Spatial Pyramid Pooling Fast (SPPF)*, yang memungkinkan pengambilan informasi pada berbagai skala dan meningkatkan representasi fitur.

Bagian *Neck* berfungsi sebagai penghubung antara *backbone* dan *head*. Komponen ini meningkatkan kualitas dan kekayaan peta fitur dengan menambahkan beberapa lapisan konvolusi serta mengimplementasikan *Feature Pyramid Network (FPN)* dan *Path Aggregation Network (PAN)*. Selain itu, bagian *Neck* menghilangkan operasi konvolusi setelah *up-sampling* untuk efisiensi yang lebih baik, sesuai dengan arsitektur YOLOv8. Komponen *Head* merupakan bagian terakhir dari arsitektur yang bertugas melakukan prediksi *bounding box* dan klasifikasi objek berdasarkan fitur yang telah diproses. *Head* pada YOLOv8 menggunakan pendekatan *decoupled head*, yang memisahkan proses klasifikasi dan regresi *bounding box* agar masing-masing dapat dioptimalkan secara independen.

3.3.1 Bounding box



Gambar 1 Bounding Box

[Gambar 1](#) menunjukkan ilustrasi *bounding box* yang digunakan untuk menentukan posisi dan ukuran objek dalam citra. Koordinat tengah (b_x , b_y) dihitung menggunakan fungsi sigmoid dan posisi grid, sedangkan lebar (b_w) dan tinggi (b_h) diperoleh dari hasil eksponensial prediksi model dan ukuran *anchor box*. Proses ini penting untuk mengarahkan model dalam memberikan prediksi lokasi objek secara akurat, yang menjadi dasar dalam evaluasi keberhasilan deteksi pada YOLOv8.

$$b_x = \sigma(t_x) + c_x \quad \text{..... (1)}$$

$$b_y = \sigma(t_y) + c_y \quad \text{..... (2)}$$

$$b_w = P_w e^{t_w} \quad \text{..... (3)}$$

$$b_h = P_h e^{t_h} \quad \text{..... (4)}$$

[Persamaan \(1\)](#), [\(2\)](#), [\(3\)](#) dan [\(4\)](#) di atas, menunjukkan bahwa t_x , t_y , t_w , t_h adalah nilai output jaringan untuk posisi dan ukuran *bounding box*. c_x , c_y adalah koordinat grid sel pada fitur map. P_w , P_h adalah ukuran *anchor box*. σ adalah fungsi *sigmoid*.

3.3.2 Fungsi Loss

Model menggunakan gabungan beberapa fungsi *loss* untuk mengoptimalkan prediksi *bounding box* dan klasifikasi, yaitu *Distribution Focal Loss* (DFL), yang meningkatkan ketepatan regresi *bounding box* dengan menghitung distribusi prediksi, seperti [persamaan \(5\)](#) di bawah:

$$DFL(S_1, S_{1+1}) = -((y_{1+1} - y) \log S_1 + (y - y_1) \log S_{1+1}) \quad \text{..... (5)}$$

Complete Intersection over Union (CIOU) Loss, yang memperhitungkan jarak antara pusat prediksi dan ground truth, ukuran, serta aspek rasio *bounding box*, dimana ditunjukkan pada [persamaan \(6\)](#), [\(7\)](#) dan [\(8\)](#) di bawah:

$$CIOU = IOU - \frac{\rho^2(b, b_{gt})}{c^2} - \alpha v \quad \text{..... (6)}$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w_{gt}}{h_{gt}} - \arctan \frac{w}{h} \right)^2 \quad \text{..... (7)}$$

$$\alpha = \frac{v}{1 - IOU + v} \quad \text{..... (8)}$$

3.3.3 Parameter Pelatihan

Model dilatih selama 150 epoch menggunakan dataset yang telah diberi label melalui *Roboflow*. Selama pelatihan, sistem mencatat peningkatan stabil pada metrik akurasi dan penurunan nilai *loss*. [Tabel 1](#) adalah ringkasan parameter utama selama proses pelatihan:

Tabel 1 Tabel Parameter

Parameter	Nilai
Jumlah <i>Epoch</i>	150
Ukuran Gambar	640 x 640 piksel
<i>Batch Size</i>	16
<i>Learning Rate</i>	0.01
Total Gambar Pelatihan	315 (5 kelas x 63)
Total Gambar Validasi	30 (5 kelas x 6)
Total Gambar Uji	15 (5 kelas x 3)


Dalam proses pelatihan model YOLOv8, digunakan sejumlah parameter yang telah disesuaikan untuk mengoptimalkan kinerja deteksi objek terhadap gambar kue tradisional. Jumlah *epoch* yang digunakan adalah sebanyak 150, yang berarti model dilatih sebanyak 150 kali melewati seluruh data pelatihan. Jumlah *epoch* yang relatif tinggi ini bertujuan untuk memberikan kesempatan bagi model dalam menyerap pola visual yang kompleks pada masing-masing jenis kue, serta meningkatkan kemampuan generalisasi model.

Ukuran gambar yang digunakan sebagai input ke dalam model adalah 640×640 piksel, yang merupakan ukuran standar pada arsitektur YOLOv8 dan cukup optimal untuk menjaga keseimbangan antara detail visual dan efisiensi pemrosesan. *Batch size* ditetapkan sebesar 16, yang berarti dalam satu iterasi pelatihan, model akan memproses 16 gambar sekaligus. Nilai batch size ini dipilih agar dapat memanfaatkan kapasitas GPU secara efisien tanpa mengorbankan stabilitas proses pelatihan[16].

Nilai *learning rate* yang digunakan adalah 0.01, yang berfungsi sebagai parameter pengendali kecepatan model dalam memperbarui bobot selama proses training. *Learning rate* ini cukup agresif, namun masih berada dalam rentang yang stabil sehingga memungkinkan konvergensi yang lebih cepat, terutama pada dataset yang tidak terlalu besar. Adapun total data yang digunakan dalam pelatihan terdiri dari 315 gambar untuk training (masing-masing kelas sebanyak 63 gambar), 30 gambar untuk validasi (masing-masing kelas 6 gambar), dan 15 gambar untuk pengujian (masing-masing kelas 3 gambar). Pembagian ini dirancang untuk menjaga proporsi yang representatif antar kelas, sekaligus memastikan bahwa model dapat dilatih dan diuji secara adil terhadap kelima kelas kue yang diteliti.

3.4 Evaluation

Evaluasi dilakukan dengan menggunakan *confusion matrix multiclass* seperti pada [gambar 2](#) untuk mengukur kinerja klasifikasi terhadap lima kelas kue tradisional, yaitu Dadar Gulung, Lapis, Lumpur, Putu Ayu, dan Wingko, serta satu kelas tambahan yaitu *background*. *Confusion matrix* ini menyajikan jumlah prediksi yang benar (*True Positive*) dan salah (*False Positive*, *False Negative*) untuk masing-masing kelas, sehingga dapat dianalisis kesalahan prediksi antar kelas (*misclassifications*). Dari matrix tersebut, diperoleh metrik evaluasi seperti precision, recall, dan F1-score untuk setiap kelas, serta nilai rata-rata (*macro average*) sebagai gambaran umum performa model. Evaluasi ini sangat penting karena memberikan pemahaman komprehensif terhadap performa model pada tiap-tiap kelas, bukan hanya akurasi keseluruhan.



Gambar 2 Evaluasi Confusion Matrix Multi Class

Precision mengukur seberapa akurat model dalam mendeteksi objek, yaitu berapa banyak objek yang benar-benar terdeteksi dibandingkan dengan seluruh objek yang diprediksi, seperti [persamaan \(9\)](#).

$$Precision = \frac{TP}{TP+FP} \quad (9)$$

Recall mengukur seberapa banyak objek yang sebenarnya ada dalam gambar dapat terdeteksi oleh model, seperti [persamaan \(10\)](#).

$$Recall = \frac{TP}{TP+FN} \quad \dots (10)$$

F1-score adalah rata-rata harmonis antara *precision* dan *recall*, yang memberikan gambaran yang lebih seimbang tentang kinerja model, seperti [persamaan \(11\)](#).

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad \dots (11)$$

mAP (*mean Average Precision*) mengukur akurasi model secara keseluruhan dengan menghitung rata-rata akurasi pada berbagai *level threshold* [16]. Langkah-langkah untuk menghitung mAP yaitu menghitung *Average Precision* (AP) untuk setiap kelas objek berdasarkan *precision-recall curve*. AP dinyatakan dengan, seperti [persamaan \(12\)](#):

$$AP = \int_0^1 P(R) dR \quad \dots (12)$$

Rata-rata dari semua AP untuk semua kelas objek menghasilkan mAP dengan N adalah jumlah kelas, seperti [persamaan \(13\)](#).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad \dots (13)$$

Dalam penelitian ini, metrik evaluasi tersebut digunakan untuk mengukur efektivitas model YOLOv8 dalam mendeteksi kue tradisional dari citra yang diberikan. Dengan menggunakan *precision*, *recall*, *F1-score*, dan mAP, performa model dapat dianalisis secara komprehensif untuk memastikan bahwa model bekerja dengan akurat dan efisien


4. PENGUJIAN DAN PEMBAHASAN

4.1 Data Preparation

Pada spesifikasi parameter pelatihan model diuraikan dalam Tabel 1 untuk memberikan gambaran menyeluruh tentang konfigurasi yang digunakan dalam penelitian ini. Tabel tersebut mencatat bahwa model dilatih selama 150 epoch, yang menunjukkan jumlah iterasi penuh dataset melalui jaringan untuk mengoptimalkan performa deteksi. Ukuran gambar input ditetapkan pada resolusi 640 x 640 piksel, yang merupakan standar untuk memastikan kompatibilitas dengan arsitektur YOLOv8 sekaligus menjaga keseimbangan antara detail visual dan efisiensi komputasi. *Batch size* sebesar 16 dipilih untuk mengelompokkan data selama pelatihan, memungkinkan pembaruan bobot model yang stabil. *Learning rate* ditetapkan pada 0.01, yang mengatur laju pembelajaran model dalam menyesuaikan bobot jaringan berdasarkan kesalahan prediksi. Dataset pelatihan terdiri dari 315 citra, yang mewakili lima kelas kue tradisional (masing-masing 63 citra per kelas), sementara dataset validasi dan uji masing-masing berisi 30 citra (6 citra per kelas) dan 15 citra (3 citra per kelas). Pembagian ini mencerminkan proporsi 70:30 untuk pelatihan dan pengujian, yang bertujuan untuk memastikan generalisasi model terhadap data baru. Parameter-parameter ini dirancang secara cermat untuk mendukung pelatihan model yang efektif, sehingga menghasilkan performa deteksi yang optimal dalam mengenali kue tradisional Indonesia.

4.2 Split Data

Sebelum proses pelatihan model dilakukan, data terlebih dahulu melalui tahap persiapan yang meliputi anotasi dan pembagian dataset. Pembagian data ini bertujuan untuk memisahkan antara data yang digunakan untuk melatih model, memvalidasi performa selama pelatihan, dan menguji akurasi akhir model terhadap data yang belum pernah dilihat sebelumnya.



Gambar 3 Split Data Menggunakan Roboflow

Seperti yang ditunjukkan pada [Gambar 3](#), dataset yang digunakan terdiri dari 354 total gambar, yang kemudian dibagi menjadi tiga bagian, data training sebanyak 309 (sudah termasuk *augmentasi data*), data validasi sebanyak 30 gambar, dan data testing sebanyak 15 gambar.

4.3 YOLOv8

Penelitian ini melakukan eksperimen terhadap lima varian model YOLOv8, yaitu: YOLOv8n (*nano*), YOLOv8s (*small*), YOLOv8m (*medium*), YOLOv8l (*large*), dan YOLOv8x (*extra large*). Masing-masing model dilatih menggunakan dataset kue tradisional yang terdiri dari lima kelas: Dadar Gulung, Lapis, Lumpur, Putu Ayu, dan Wingko. Evaluasi dilakukan menggunakan lima metrik utama: *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *mAP@50*.

Setiap metrik memberikan gambaran yang berbeda mengenai performa model. *Accuracy* menunjukkan tingkat ketepatan klasifikasi secara umum. *Precision* menggambarkan seberapa tepat model dalam mengidentifikasi kelas tertentu. *Recall* mengukur seberapa banyak objek dari kelas tertentu berhasil dikenali. *F1-Score* adalah rata-rata harmonik antara *precision* dan *recall*, dan *mAP@50* adalah nilai rata-rata *precision* ketika *Intersection over Union (IoU)* lebih dari 0.5, yang merupakan metrik utama dalam deteksi objek :

Tabel 2 Evaluasi YOLOv8s

Evaluasi Menggunakan Model YOLOv8s					
Kelas	Accuracy	Precision	Recall	F1-Score	mAP@50
Dadar Gulung	93.77	87.53	100	93.35	99.5
Lapis	64.19	78.38	50	61.05	51.44
Lumpur	93.93	92.53	95.34	93.91	98.25
Putu Ayu	97.04	94.08	100	96.95	99.5
Wingko	87.4	89.08	85.71	87.36	90.9

Model YOLOv8s pada [tabel 2](#) menunjukkan performa yang sangat baik untuk kelas Putu Ayu dan Dadar Gulung, dengan nilai recall 100% dan mAP mendekati sempurna. Namun, pada kelas Lapis, performanya menurun drastis, terlihat dari nilai recall hanya 50% dan mAP yang rendah.

Tabel 3 Evaluasi YOLOv8n

Evaluasi Menggunakan Model YOLOv8n					
Kelas	Accuracy	Precision	Recall	F1-Score	mAP@50
Dadar Gulung	94.7	89.4	100	94.4	99.5
Lapis	71.24	90.35	52.13	66.11	59.77
Lumpur	90.97	85.8	96.15	90.68	97.59

Putu Ayu	93.33	86.66	100	92.85	99.5
Wingko	79.11	79.65	78.57	79.11	86.3

Pada [tabel 3](#), YOLOv8n memiliki keseimbangan antara *precision* dan *recall* yang cukup baik di semua kelas, dengan performa tertinggi tetap pada kelas Dadar Gulung dan Putu Ayu.

Tabel 4 Evaluasi Yolov8m

Evaluasi Menggunakan Model Yolov8m					
Kelas	Acuracy	Precision	Recall	F1-Score	mAP@50
Dadar Gulung	96.23	92.45	100	96.08	99.5
Lapis	59.68	73.36	46	56.55	53.32
Lumpur	91.25	90.2	92.31	91.24	96.82
Putu Ayu	98.08	96.17	100	98.05	99.5
Wingko	72.93	95.86	50	65.72	73.92

Pada [tabel 4](#), Model ini mencatat nilai *precision* tertinggi namun mengalami penurunan signifikan pada kelas Lapis dan Wingko, yang terlihat dari nilai *recall* yang rendah.

Tabel 5 Evaluasi Yolov8l

Evaluasi Menggunakan Model Yolov8l					
Kelas	Acuracy	Precision	Recall	F1-Score	mAP@50
Dadar Gulung	93	86.01	100	92.48	99.5
Lapis	56.96	63.93	50	56.11	57.24
Lumpur	88.72	88.99	88.46	88.72	92.92
Putu Ayu	96.62	93.23	100	96.5	99.5
Wingko	74.75	99.51	50	66.56	77.16

Performa YOLOv8l pada [tabel 5](#) cukup stabil namun tidak terlalu menonjol, terutama pada kelas Lapis yang terus mengalami kelemahan pada semua model.

Tabel 6 Evaluasi Yolov8x


Evaluasi Menggunakan Model Yolov8x					
Kelas	Acuracy	Precision	Recall	F1-Score	mAP@50
Dadar Gulung	91.5	83	100	90.71	99.5
Lapis	67.66	79.76	55.56	65.4	58.21
Lumpur	88.22	82.94	93.5	87.9	95.62
Putu Ayu	92.1	84.2	100	91.42	99.5
Wingko	93.47	86.93	100	93.01	96.88

Pada [tabel 6](#), YOLOv8x menjadi model dengan performa terbaik secara keseluruhan, terlihat dari *F1-score* dan mAP@50 yang tinggi, serta keseimbangan *precision* dan *recall* di semua kelas.

Tabel 7 Rata-Rata Evaluasi Yolov8

Rata-rata Evaluasi Semua Varian YOLOv8					
Model	Acuracy	Precision	Recall	F1-Score	mAP@50
Yolov8s	87.3	88.3	64.2	87.3	87.9
Yolov8n	85.9	86.4	85.4	85.9	88.5
Yolov8m	83.6	89.6	77.7	83.2	84.6
Yolov8l	82	86.3	77.7	81.8	85.3
Yolov8x	86.7	83.4	89.8	86.5	89.9


Dari [tabel 7](#), terlihat bahwa model YOLOv8x memiliki performa terbaik secara keseluruhan, dengan mAP@50 sebesar 89.9% dan nilai *F1-score* tertinggi. Hal ini menandakan bahwa YOLOv8x memiliki keseimbangan sangat baik antara ketepatan dan kelengkapan deteksi, meskipun memiliki ukuran model yang lebih besar dan membutuhkan komputasi lebih tinggi.



Gambar 4 Plot Label

[Gambar 4](#) menyajikan empat visualisasi utama yang memberikan gambaran statistik dan spasial dari *bounding box* pada dataset pelatihan kue tradisional. *Histogram* jumlah instansi per kelas menunjukkan ketidakseimbangan anotasi, di mana kelas Lapis memiliki jumlah terbanyak, sedangkan Dadar Gulung paling sedikit. Ketimpangan ini dapat memengaruhi performa model terhadap kelas dengan data terbatas. Visualisasi tumpukan *bounding box* memperlihatkan bahwa sebagian besar objek berada di tengah gambar dan berukuran seragam, menunjukkan pengambilan gambar yang konsisten secara frontal, yang menguntungkan proses pembelajaran model. Distribusi koordinat tengah *bounding box* juga terkonsentrasi di sekitar titik tengah (0.4–0.6), memperkuat temuan bahwa objek dominan berada di pusat gambar dengan sedikit variasi posisi. Terakhir, distribusi ukuran *bounding box* menunjukkan keragaman dimensi, dengan mayoritas objek berukuran sedang, yang penting untuk meningkatkan kemampuan model dalam mendeteksi objek pada berbagai skala.


Analisis lebih lanjut terhadap klasifikasi dilakukan melalui *confusion matrix*, yang memberikan informasi mengenai distribusi hasil prediksi terhadap masing-masing kelas. Gambar berikut menggambarkan detailnya:



Gambar 5 Plot Confusion Matrix


Confusion matrix pada [Gambar 5](#) memperlihatkan evaluasi performa model YOLOv8x terhadap data uji yang terdiri dari lima kelas kue tradisional dan satu kelas *background*. Model menunjukkan akurasi tinggi pada kelas Lumpur dengan 24 prediksi benar, menandakan fitur visual kue ini dikenali dengan baik. Kelas Lapis juga tampil baik dengan 10 prediksi benar, meskipun terdapat dua kesalahan prediksi terhadap *background*, yang mungkin disebabkan oleh kemiripan pola visual. Sebaliknya, Dadar Gulung memiliki akurasi terendah dengan hanya 3 prediksi benar, mengindikasikan kesulitan model dalam membedakan kelas ini dari objek lain atau latar belakang, kemungkinan akibat data pelatihan yang terbatas atau kurang representatif. Kelas Wingko menunjukkan hasil yang cukup baik dengan 14 prediksi benar, namun masih mengalami kesalahan klasifikasi ke *background* dan Putu Ayu. Selain itu, terdapat kasus di mana

latar belakang diprediksi sebagai objek, khususnya Lapis dan Lumpur, yang menandakan model belum sepenuhnya mampu menyaring elemen non-objek. Secara keseluruhan, hasil ini menunjukkan performa deteksi yang solid pada beberapa kelas, namun juga menyoroti perlunya peningkatan dalam penanganan kelas minoritas dan pengelolaan *noise* latar belakang.



Gambar 6 Plot Grafik Precision Recall

Gambar 6 menampilkan kurva *Precision-Recall* (PR) hasil evaluasi model YOLOv8x terhadap lima kelas kue tradisional. Kurva ini merepresentasikan hubungan antara *precision* (ketepatan) dan *recall* (kelengkapan) dalam proses deteksi objek, dengan garis tebal biru tua menunjukkan rata-rata performa seluruh kelas yang menghasilkan $mAP@0.5$ sebesar 0.899. Model menunjukkan performa deteksi yang sangat baik untuk kelas Dadar Gulung dan Putu Ayu, dengan *precision* dan *recall* mendekati 0.995, menandakan kemampuan deteksi yang akurat dan konsisten. Kelas Wingko dan Lumpur juga tampil kuat, masing-masing mencapai $mAP@0.5$ sebesar 0.969 dan 0.956, dengan kurva mendekati bentuk ideal. Sebaliknya, kelas Lapis menunjukkan performa paling rendah, dengan $mAP@0.5$ hanya 0.582 dan penurunan *precision* yang signifikan setelah *recall* > 0.5, mengindikasikan kesulitan model dalam mengenali objek kelas ini secara tepat. Hasil ini menunjukkan bahwa secara umum model memiliki kemampuan deteksi yang sangat baik, meskipun masih perlu peningkatan pada kelas dengan performa rendah seperti Lapis.




Gambar 7 Plot Grafik Loss

Pada **gambar 7** menunjukkan grafik metrik dan *loss* selama proses pelatihan selama 150 *epoch*. Terlihat penurunan bertahap pada *train/box_loss*, *train/cls_loss*, dan *train/dfl_loss* yang mengindikasikan model berhasil belajar dengan baik. Selain itu, tren peningkatan yang stabil pada *precision*, *recall*, dan $mAP@50$ dari data validasi menandakan bahwa model tidak mengalami *overfitting* dan memiliki kemampuan generalisasi yang baik.

4.4 Visualisasi Hasil Deteksi

Untuk mengilustrasikan performa sistem secara visual, dilakukan uji coba dengan gambar uji acak. Model berhasil mengenali dan memberikan *bounding box* beserta label kelas dengan *confidence score* di atas 70%. Gambar berikut memperlihatkan contoh hasil deteksi pada citra uji:



Gambar 8 Tangkapan Layar Hasil Deteksi

Berdasarkan eksperimen dan visualisasi yang ditunjukkan pada Gambar 8, terlihat bahwa model YOLOv8x mampu mendeteksi objek kue tradisional secara akurat, ditandai dengan keberhasilan dalam menandai objek seperti Putu Ayu dan Lumpur dengan nilai *confidence* yang tinggi, yakni di atas 0.90. Gambar 8 menampilkan hasil *bouding box* berwarna berbeda untuk setiap kelas kue, lengkap dengan label dan nilai *confidence score*, seperti “Putu Ayu 0.89” dan “Lumpur 0.96”. Visualisasi ini menguatkan hasil evaluasi metrik sebelumnya, bahwa model dapat mengenali bentuk dan pola khas dari objek kue dengan cukup presisi. Namun demikian, beberapa kesalahan klasifikasi masih ditemukan, terutama pada kelas dengan bentuk yang mirip atau pencahayaan tidak merata. *Confusion matrix* menunjukkan adanya kesalahan prediksi pada kelas Lapis yang kadang tertukar dengan Lumpur atau Wingko. Kurva *precision-recall* memperlihatkan bahwa performa deteksi pada kelas Lapis berada di bawah rata-rata. Hal ini menegaskan bahwa kualitas data pelatihan dan keberagaman citra sangat memengaruhi kinerja model. Secara keseluruhan, model YOLOv8 menunjukkan hasil yang sangat menjanjikan untuk implementasi pada sistem edukasi atau klasifikasi berbasis gambar makanan tradisional[7]. Dengan peningkatan jumlah data, teknik *augmentasi* lanjutan, dan perbaikan anotasi, performa model dapat ditingkatkan lebih lanjut

5. KESIMPULAN

Penelitian ini berhasil menerapkan algoritma YOLOv8 untuk mendeteksi lima jenis kue tradisional Indonesia: Dadar Gulung, Lapis, Lumpur, Putu Ayu, dan Wingko. Lima varian model YOLOv8 (n, s, m, l, dan x) dievaluasi menggunakan metrik seperti *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *mAP@50*. Hasil menunjukkan bahwa YOLOv8x memberikan performa terbaik, dengan *mAP@50* sebesar 89,9% dan *F1-Score* tertinggi, serta mampu mendeteksi objek dengan kompleksitas visual tinggi secara konsisten. Namun, kelas Lapis menjadi tantangan terbesar, yang menunjukkan perlunya perbaikan distribusi dan kualitas data latih. Evaluasi visual melalui *confusion matrix*, distribusi *bouding box*, dan kurva *precision-recall* turut memperkuat pemahaman terhadap performa model dan arah pengembangan lebih lanjut. Secara keseluruhan, YOLOv8 terutama varian x terbukti efektif untuk tugas deteksi objek dalam domain kue tradisional, dan membuka peluang pengembangan menuju aplikasi edukatif maupun sistem informasi makanan berbasis kecerdasan buatan.

DAFTAR PUSTAKA

- [1] S. Arifah, E. R. Swedia, and M. R. D. Septian, "Analisis Perbandingan Algoritma Clustering Dalam Melakukan Segmentasi Warna Pada Citra Jajan Tradisional," *Sebatik*, vol. 27, no. 1, pp. 70-76, 2023, <https://doi.org/10.46984/sebatik.v27i1.2273>

- [2] D. Sumarlie, C. Lubis, and T. Handhayani, "Pengenalan Kue Tradisional Indonesia Menggunakan Algoritma Convolutional Neural Network," *Comput. J. Comput. Sci. Inf. Syst.*, vol. 6, no. 2, pp. 164-171, 2023, <https://doi.org/10.24912/computatio.v6i2.21098>
- [3] R. Faturrahman, Y. S. Hariyani, and S. Hadiyoso, "Klasifikasi Jajanan Tradisional Indonesia berbasis Deep Learning dan Metode Transfer Learning," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 4, pp. 945-957, 2023, <https://doi.org/10.26760/elkomika.v11i4.945>
- [4] E. Syahrudin, E. Utami, and A. D. Hartanto, "Enhanced Yolov8 with OpenCV for Blind-Friendly Object Detection and Distance Estimation," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 8, no. 2, pp. 199-207, 2024, doi: 10.29207/resti.v8i2.5529. <https://doi.org/10.29207/resti.v8i2.5529>
- [5] E. Syahrudin, E. Utami, and A. D. Hartanto, "Object Detection with YOLOv8 and Enhanced Distance Estimation Using OpenCV for Visually Impaired Accessibility," *Int. J. Informatics Vis.*, vol. 9, no. 2, pp. 575-584, 2025, <https://doi.org/10.62527/joiv.9.2.2826>
- [6] M. F. Golfantara, "Penggunaan Algoritma Yolo V8 Untuk Identifikasi Rempah-Rempah," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3S1, pp. 3867-3873, Oct. 2024, <https://doi.org/10.23960/jitet.v12i3S1.5211>
- [7] I. P. Sary, S. Andromeda, and E. U. Armin, "Performance Comparison of YOLOv5 and YOLOv8 Architectures in Human Detection using Aerial Images," *Ultim. Comput. J. Sist. Komput.*, vol. 15, no. 1, pp. 8-13, 2023, <https://doi.org/10.31937/sk.v15i1.3204>
- [8] R. R. Putra, Maimunah, and D. Sasongko, "Implementasi Algoritma YOLO V8 (You Only Look Once) Dalam Deteksi Penyakit Daun Durian," *Build. Informatics, Technol. Sci.*, vol. 6, no. 3, p. 1517-1526, 2024, doi: 10.28989/avitec.v6i1.2067. <https://doi.org/10.28989/avitec.v6i1.2067>
- [9] A. Rachmatullah Pratama and A. F. Cobantoro, "Klasifikasi Citra Pneumonia Menggunakan Arsitektur Convolutional Neural Network (Cnn) Pneumonia Image Classificati on Using Convolutinal Neural Network (Cnn) Architecture," *J. Ilm. NERO*, vol. 8, no. 2, p. 2023, 2023, <https://doi.org/10.21107/nero.v8i2.18992>
- [10] A. K. Aziz, L. Novamizanti, and S. A. Wibowo, "Perancangan dan Implementasi Deep Learning untuk Deteksi Kesegaran Ikan Beku pada Aplikasi FishQ menggunakan YOLOv8," *J. Nas. SAINS dan Tek.*, vol. 2, no. 2, pp. 1-6, 2024, <https://doi.org/10.25124/jnst.v2i2.8746>
- [11] W. Songpan, T. Chaianunporn, K. Lomthaisong, and S. Keithmaleesatti, "Automated classification in turtles genus Malayemys using ensemble multiview image based on improved YOLOv8 with CNN," *Sci. Rep.*, vol. 14, no. 1, pp. 1-10, 2024, <https://doi.org/10.1038/s41598-024-76431-9>
- [12] R. Pusparina A and R. Rahmadewi, "Deteksi Objek Berbasis Yolov8 Untuk Mendukung," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 3188-3195, 2025, <https://doi.org/10.36040/jati.v9i2.13257>
- [13] A. Padia et al., "Object Detection and Classification Framework for Analysis of Video Data Acquired from Indian Roads," *Sensors*, vol. 24, no. 19, pp. 1-21, 2024, <https://doi.org/10.3390/s24196319>
- [14] P. G. S. Naik, S. M. Kenchol, S. P. Jakalannanavar, and R. M S, "Object Detection Using FasterRCNN , YOLOV7 & YOLOV8," *Indiana J. Multidiscip. Res.*, vol. 4, no. 3, pp. 136-141, 2024, <https://doi.org/10.5281/zenodo.12674762>
- [15] M. R. Sholahuddin et al., "Optimizing YOLOv8 for Real-Time CCTV Surveillance: A Trade-off Between Speed and Accuracy," *J. Online Inform.*, vol. 8, no. 2, pp. 261-270, 2023, <https://doi.org/10.15575/join.v8i2.1196>
- [16] J. Jeri and Z. S. Hidayat, "Penentuan Ukuran Batch Optimal Untuk Pelatihan Yolov8 Dalam Pendeteksian Objek Pada Kendaraan Otonom Determination of Optimal Batch Size For Yolov8," *J. Ilm. NERO*, vol. 9, no. 1, pp. 35-48, 2024, <https://doi.org/10.21107/nero.v9i1.27462>