

**PENGARUH AUGMENTASI PADA DETEKSI IMAGE MAKANAN KHAS KALIMANTAN BARAT MENGGUNAKAN METODE YOU ONLY LOOK ONCE (YOLO)**

**Idiel Anugrah<sup>1</sup>, Herry Sujaini<sup>2</sup>, Helen Sastypratiwi<sup>3</sup>**

<sup>#</sup>*Program Studi Informatika, Fakultas Teknik, Universitas Tanjungpura*

*Jl. Prof. Dr.H. Hadari Nawawi, Pontianak, Kalimantan Barat 78115*

<sup>1</sup>[d1041211046@student.untan.ac.id](mailto:d1041211046@student.untan.ac.id) <sup>2</sup>[hs@untan.untan.ac.id](mailto:hs@untan.untan.ac.id)

<sup>3</sup>[helensastypratiwi@informatics.untan.ac.id](mailto:helensastypratiwi@informatics.untan.ac.id)

**Abstrak (Indonesia)**

Kalimantan Barat memiliki beragam makanan khas yang mencerminkan kekayaan budaya dan tradisi masyarakatnya. Namun, dokumentasi visual mengenai makanan khas tersebut masih terbatas, sehingga diperlukan suatu sistem yang mampu mengenali dan mengklasifikasikan citra makanan secara otomatis. Penelitian ini bertujuan untuk mendeteksi gambar makanan khas Kalimantan Barat menggunakan metode YOLOv8n serta menganalisis pengaruh augmentasi data terhadap performa model deteksi objek. Dataset yang digunakan terdiri dari 15 kelas makanan khas Kalimantan Barat, dengan total ribuan gambar yang diperoleh melalui pengumpulan data melalui internet dan menggunakan ponsel. Penelitian dilakukan melalui enam skenario pelatihan berbeda dengan variasi teknik augmentasi, seperti flipping, rotasi, dan perubahan kecerahan. Model dilatih menggunakan Google Colab dengan konfigurasi 100 epoch, batch size 16, image size 640×640, dan mekanisme early stopping untuk mencegah overfitting. Hasil pengujian menunjukkan bahwa augmentasi data berpengaruh positif terhadap peningkatan performa model. Performa terbaik diperoleh pada skenario 6 dengan nilai *F1-score* sebesar 0.847, Precision 0.868, *Recall* 0.828, mAP50 0.89, dan mAP50–95 0.587 dengan jumlah dataset sebanyak 2.520 gambar. Skenario ini menunjukkan keseimbangan terbaik antara precision, *recall*, dan accuracy, sehingga dapat dikategorikan sebagai performa optimal dari keseluruhan pengujian. Dengan demikian, penelitian menunjukkan bahwa jumlah data yang lebih banyak menghasilkan performa model yang lebih baik. Semakin banyak jumlah dataset terutama jika dikombinasikan dengan augmentasi yang tepat, maka semakin tinggi pula potensi performa model deteksi objek. Namun, peningkatan performa tersebut bergantung pada kualitas data, keberagaman sampel, serta kesesuaian teknik augmentasi yang digunakan.

**Sejarah Artikel**

*Submitted: 7 Januari 2026*

*Accepted: 10 Januari 2026*

*Published: 11 Januari 2026*

**Kata Kunci**

*Budaya, Kalimantan Barat, makanan khas, pendekripsi gambar, pengolahan citra, YOLO.*

**I. PENDAHULUAN**

Kalimantan Barat merupakan salah satu provinsi terluas di Indonesia dengan luas wilayah sekitar 146.807 km<sup>2</sup>. Provinsi ini berbatasan langsung dengan Malaysia di utara dan barat, serta memiliki ibu kota Pontianak yang dilalui garis khatulistiwa[1]. Kekayaan budaya Kalimantan Barat tercermin dalam beragam makanan khas yang menjadi bagian penting dari identitas masyarakatnya. Namun, di era digital saat ini, dokumentasi makanan khas tersebut masih terbatas dan umumnya hanya tersedia dalam bentuk cetak, sehingga kurang mampu mendukung promosi wisata kuliner secara optimal. Kondisi ini dapat berdampak pada pelestarian budaya serta potensi ekonomi daerah.

Dalam pendekripsi gambar secara otomatis biasanya melibatkan algoritma kecerdasan buatan (*artificial intelligence*), khususnya dalam bidang *image processing* dan *deep learning*. Salah satu metode yang paling umum digunakan adalah *Convolutional Neural Network* (CNN) karena memiliki kemampuan tinggi dalam mengenali pola visual. Namun, seiring

perkembangan teknologi, muncul deteksi objek yang lebih cepat dan akurat, yaitu *You Only Look Once* (YOLO). Metode YOLO (You Only Look Once) adalah metode deteksi yang banyak diminati karena mendukung kinerja sistem secara real-time [2]. YOLO terus mengalami pengembangan dan versi terbarunya yaitu YOLOv8 telah dibangun menggunakan *framework* PyTorch yang lebih fleksibel dan didukung penuh oleh GPU untuk percepatan komputasi[3]. Secara umum, YOLOv8 memiliki beberapa varian ukuran model yang menyesuaikan kebutuhan pengguna. Versi paling kecil adalah YOLOv8n (nano), yang sangat ringan dan cepat sehingga cocok untuk perangkat dengan kemampuan terbatas. Sebagai model teringan, YOLOv8n hanya memiliki 3,2 juta parameter dan 8,7 GFLOPs[4]. Lalu ada YOLOv8s (*small*), sedikit lebih besar dengan akurasi yang lebih baik namun tetap efisien. Selanjutnya, YOLOv8m (*medium*) memberikan keseimbangan antara kecepatan dan akurasi, sehingga banyak digunakan untuk eksperimen pada GPU kelas menengah. Untuk kebutuhan akurasi tinggi, tersedia YOLOv8l (*large*) dan YOLOv8x (*extra large*). Kedua versi ini lebih lambat karena ukurannya besar, tetapi memberikan hasil deteksi yang lebih presisi[5]. Oleh karena itu, penulis memilih metode YOLOv8n dalam penelitian ini karena versi yang ringan dalam kecepatan, akurasi, serta kemudahan integrasi dengan lingkungan pemrograman Python modern pada dataset yang masih minim.

Pemanfaatan teknologi kecerdasan buatan, khususnya dalam bidang image processing dan deep learning, dapat menjadi solusi untuk mendokumentasikan dan mengidentifikasi makanan khas secara otomatis. Salah satu metode yang banyak digunakan adalah Convolutional Neural Network (CNN), namun perkembangan terkini menghadirkan algoritma deteksi objek yang lebih cepat dan akurat, yaitu You Only Look Once (YOLO). Versi terbarunya, YOLOv8, dibangun menggunakan framework PyTorch dan mendukung komputasi GPU untuk hasil yang efisien. YOLOv8 memiliki beberapa varian, dan dalam penelitian ini digunakan YOLOv8n (nano) karena ringan, cepat, serta sesuai untuk dataset berukuran kecil.

Keberhasilan model YOLO sangat bergantung pada kualitas dan jumlah data latih. Keterbatasan data serta variasi kondisi gambar seperti pencahayaan, sudut, dan latar belakang sering kali menurunkan kemampuan model dalam melakukan generalisasi. Hal ini menjadi tantangan tersendiri dalam mendeteksi makanan khas Kalimantan Barat yang memiliki kemiripan visual antar kelas. Untuk mengatasinya, teknik data augmentation dapat digunakan guna memperbanyak dan memperkaya variasi dataset melalui transformasi seperti rotasi, flipping, dan perubahan pencahayaan.

Pada penelitian yang dilakukan oleh[6], dilakukan augmentasi untuk mencegah *underfitting*, sehingga menciptakan variasi citra yang lebih beragam. Terdapat 14 kombinasi variasi augmentasi seperti *flip*, rotasi, kecerahan, *noise*, dan *shear*. Menghasilkan mAP50 87.1% dan mAP50-95 sebesar 72.1%. Tingkat *precision* mencapai 86.2%, sementara *recall* sebesar 79.1%. Selama pelatihan, tercatat *box loss* sebesar 0.7313 dan *clasification loss* sebesar 0.4008.

Pada penelitian[7], Kekurangan dalam penelitian ini adalah saat dilakukan pengujian, model belum dapat mendeteksi kelas secara sempurna. Hal ini disebabkan karena peneliti tidak menggunakan teknik augmentasi untuk memperbanyak dataset saat training, sehingga dataset yang digunakan untuk pelatihan tidak memiliki variasi yang cukup. Berdasarkan hasil pengujian yang telah dilakukan dari awal hingga akhir, grafik yang didapat cukup ideal. Saat pengujian dapat dilihat nilai evaluasinya untuk mengukur performa model dengan nilai *accuracy*, *recall* dan *specificity*, yaitu 0.75, 0.763 dan 0.732.

Pada penelitian[8] dalam penelitiannya yang berjudul Implementasi Algoritma You Only Look Once (YOLO) untuk Mendeteksi Bahasa Isyarat SIBI. Pada penelitian ini dilakukan augmentasi untuk menambahkan data agar bervariasi bentuk datanya. Pada penelitian ini, peneliti menggunakan augmentasi rotation, grayscale, brightness, dan cutout. Hasil penelitian menunjukkan bahwa algoritma YOLO dapat mendeteksi gesture alfabet bahasa isyarat SIBI

dengan pengujian *Confusion Matrix* mendapatkan performa yang cukup baik, ditunjukkan dengan hasil F1 -score pada kelompok 1, kelompok 2, kelompok 3, dan kelompok 4 sebesar 90.90%, 97.1%, 90.90%, dan 83.8%.

Salah satu solusi yang dapat diterapkan untuk mengatasi keterbatasan data adalah dengan melakukan augmentasi data. Teknik ini memungkinkan penambahan variasi pada dataset melalui transformasi seperti flipping, rotasi, dan perubahan pencahayaan, yang diterapkan secara acak pada citra untuk mensimulasikan kondisi lingkungan yang berbeda[9]. Dengan augmentasi, jumlah data dapat ditingkatkan dan variasi kondisi nyata dapat lebih terwakili dalam dataset[10].

Berdasarkan hal tersebut, penelitian ini bertujuan untuk menganalisis perbandingan performa model YOLOv8n sebelum dan sesudah dilakukan data augmentation pada gambar makanan khas Kalimantan Barat. Hasil analisis diharapkan dapat menunjukkan pengaruh augmentasi terhadap peningkatan akurasi, presisi, dan kemampuan generalisasi model dalam mendeteksi objek secara otomatis.

## II. METODE PENELITIAN

Bagian ini menjelaskan langkah-langkah dalam melakukan penelitian.

### A. Jenis Data

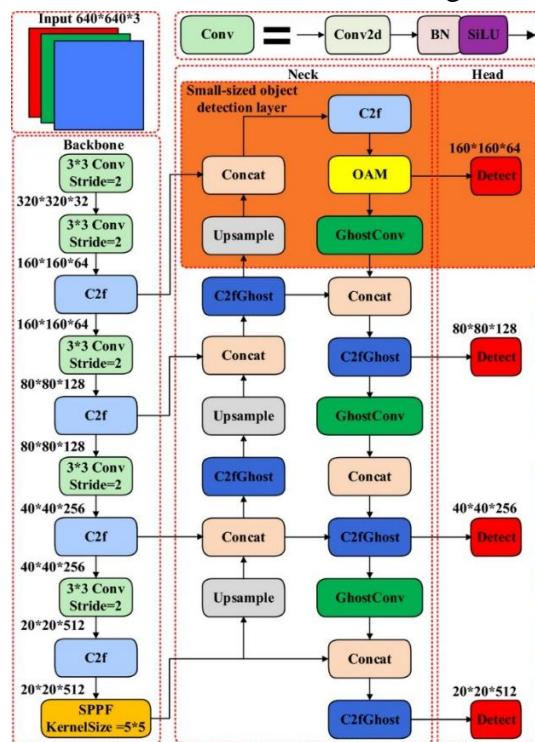
Untuk mendeteksi makanan khas Kalimantan Barat yang semua datanya adalah makanan khas Kalimantan Barat. Dasar pengambilan data ini berdasarkan buku yang berjudul Wisata Kuliner Kalimantan Barat yang diterbitkan oleh[11]. Pada makanan khas Kalimantan Barat yang paling populer di pencarian internet pada tanggal 22 Januari 2025 dengan volume pencarian 100 ribu ke atas adalah Kue Kote, Kue Serabi, Kue Dange, Bubur Padas, Ikan Asam Pedas, Rujak Ebi, Lokok-Lokok, Rendang Pisang, Bubur Gunting, Merke, Pisang Goreng Srikaya, Kerupuk Kulit Ikan Basah, Kue Bingke, Sambal Udang Tempoyak, dan Ayam Pansuh.

### B. Cara Pengumpulan Data

Dalam penelitian ini, dataset yang digunakan berupa gambar makanan khas Kalimantan Barat yang diperoleh dari dua sumber utama, yaitu melalui pencarian di media internet dan hasil pengambilan secara langsung menggunakan kamera ponsel.

### C. Metode Analisis Dataset

YOLO dibangun berdasarkan arsitektur *Convolutional Neural Network* (CNN). You Only Look Once (YOLO) memiliki arsitektur yang terdiri dari 24 lapisan konvensional. Lapisan-lapisan ini berfungsi untuk mengekstrak fitur dari gambar, yang digunakan untuk memprediksi probabilitas dan koordinat objek. Setelah proses ekstraksi fitur, metode YOLO menggunakan dua lapisan fully connected yang berfungsi untuk memprediksi probabilitas kelas serta menentukan koordinat objek yang terdeteksi. Dengan demikian, YOLO tidak hanya mengenali objek pada sebuah gambar, tetapi juga menetapkan posisi dan ukurannya, prosesnya melibatkan beberapa tahap dan berfokus pada ketepatan identifikasi secara real-time. Hal ini membuat YOLO menjadi algoritma yang cepat, efisien, dan andal dalam melakukan deteksi objek pada gambar[12].



Gambar 1 Arsitektur YOLOv8n

Berdasarkan gambar 1 arsitektur YOLOv8n diawali dengan input citra berukuran 640x640x3 (RGB). Citra ini kemudian melewati serangkaian lapisan konvolusi awal untuk mengecilkan ukuran sekaligus menambah jumlah saluran fitur. Proses ini bertujuan agar informasi penting dari gambar bisa ditangkap dengan lebih efisien.

Pada bagian Backbone, YOLOv8n menggunakan blok utama yaitu C2f, Conv, dan SPPF (Spatial Pyramid Pooling Fast). Blok C2F yang berfungsi mengekstraksi fitur spasial dan semantik dari citra. Setiap kali ukuran *feature map* diperkecil melalui konvolusi dengan stride 2, jumlah channel meningkat, sehingga model mampu menyimpan informasi yang lebih kompleks. Backbone juga dilengkapi dengan SPPF yang menggunakan kernel berukuran 5x5 untuk memperluas area tangkapan (receptive field) sehingga model mampu memahami konteks spasial dari berbagai ukuran objek. Hasil akhir backbone berupa peta fitur berukuran 20x20x512.

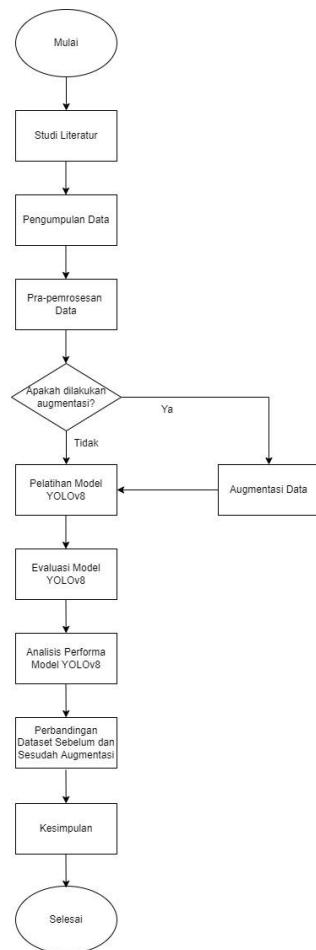
Setelah itu, bagian Neck berfungsi untuk menggabungkan informasi dari berbagai level fitur (*multi-scale feature fusion*). Mekanisme ini penting agar YOLOv8n dapat mendeteksi objek dengan ukuran yang berbeda, baik kecil maupun besar. Neck menggunakan kombinasi upsample, concatenation, serta blok C2fGhost dan GhostConv yang dirancang lebih efisien dalam menghasilkan representasi fitur. Selain itu, terdapat *Object Attention Module* (OAM) yang membantu memperkuat perhatian model pada objek kecil agar tidak terlewat dalam proses deteksi.

Pada bagian Head, YOLOv8n menggunakan pendekatan *anchor-free*. Artinya, model tidak lagi bergantung pada *anchor box* seperti versi YOLO sebelumnya, melainkan langsung memprediksi koordinat *bounding box*, skor kepercayaan (*confidence score*), dan probabilitas kelas objek. Head ini menghasilkan *output* pada tiga hingga empat skala berbeda: peta fitur berukuran 160x160, 80x80, 40x40, dan 20x20, masing-masing bertugas mendeteksi objek dengan ukuran berbeda (kecil, sedang, besar, hingga sangat besar).

Akhirnya, bagian *output* menghasilkan *bounding box* beserta informasi kelas objek dan tingkat kepercayaannya. Dengan desain ini, YOLOv8n mampu melakukan deteksi secara real-

time dengan kecepatan tinggi, efisiensi komputasi yang baik, serta akurasi yang cukup kompetitif, meskipun ukuran model relatif kecil dibanding varian YOLOv8 lainnya.

Adapun tahapan penelitian dapat diperhatikan pada gambar 2.



## *Gambar 2 Metode Penelitian*

#### A. *Studi Literatur*

Pada penelitian ini peneliti melakukan studi literatur dengan melakukan pencarian terkait deteksi dan klasifikasi objek menggunakan algoritma YOLO dengan input gambar. Studi literatur dilakukan untuk menemukan masalah dan informasi yang relevan untuk referensi dalam melakukan penelitian.

### *B. Pengumpulan Data*

Data yang digunakan berupa citra makanan khas Kalimantan Barat yang diperoleh dari dua sumber utama, yaitu hasil pencarian di media internet dan pengambilan langsung menggunakan kamera ponsel. Pengumpulan data difokuskan pada 15 jenis makanan paling populer dengan rata-rata pencarian daring di atas 100.000, agar dataset yang dibangun relevan dan representatif terhadap objek penelitian.

Tahap pengumpulan gambar menjadi krusial karena kualitas dataset sangat memengaruhi kinerja model deteksi objek. Gambar yang dikumpulkan harus sesuai dengan kelas masing-masing dan mencakup variasi kondisi seperti sudut, pencahayaan, latar belakang, serta kualitas kamera. Selain itu, dilakukan penyaringan untuk menghapus gambar buram, duplikat, atau tidak representatif guna memastikan data latih yang bersih dan berkualitas.

### C. Pra-Pemrosesan Data

Sebelum digunakan dalam proses pelatihan dan evaluasi, data melalui tahap pra-pemrosesan yaitu, tindakan yang sangat penting untuk menjamin mutu data. Jika data tidak diolah dengan benar, hal ini akan menyebabkan akurasi yang rendah dan prediksi yang kurang optimal. Oleh karena itu, penggunaan teknik preprocessing yang sesuai sangat dibutuhkan untuk memaksimalkan kemampuan generalisasi model[13].

Tahap awal pra-pemrosesan data dimulai dengan mengunggah dataset utama penelitian, kemudian mendefinisikan kelas yang merepresentasikan kategori objek yang akan dideteksi. Selanjutnya dilakukan proses annotation, yaitu memberi label dan bounding box pada setiap objek agar model dapat belajar mengenali pola visual dari masing-masing kategori.

Dataset kemudian dibagi menjadi tiga bagian yaitu training set untuk melatih model, validation set untuk mengevaluasi kinerja dan mencegah overfitting, serta testing set yang digunakan secara terpisah untuk menguji performa akhir model.

Agar proses pelatihan berjalan lebih efisien dan model dapat memproses gambar secara konsisten, dilakukan tahap resize pada semua gambar. Ukuran ditetapkan menjadi  $640 \times 640$  piksel, sesuai dengan standar input YOLOv8n. Penyeragaman dimensi ini penting untuk mempercepat perhitungan komputasi, menjaga proporsi data tetap seragam, serta meningkatkan stabilitas proses pelatihan.

### D. Augmentasi Data

Tahap data augmentation dilakukan untuk menambah jumlah dan variasi data dalam dataset agar model tidak hanya belajar dari struktur data yang terbatas. Teknik ini juga digunakan untuk menyeimbangkan proporsi antar kelas, mengurangi risiko overfitting, serta meningkatkan akurasi model pada proses inferensi[14].

Dalam penelitian ini diterapkan beberapa bentuk augmentasi, yaitu flipping horizontal dan vertikal, rotasi  $90^\circ$  searah dan berlawanan arah jarum jam, rotasi bounding box antara  $-15^\circ$  hingga  $+15^\circ$ , serta modifikasi kecerahan antara  $-15\%$  hingga  $+15\%$ .

Flipping membantu model mengenali objek dari berbagai orientasi, rotasi memperkuat kemampuan generalisasi terhadap posisi objek yang bervariasi, sedangkan modifikasi kecerahan mensimulasikan perbedaan pencahayaan di kondisi nyata. Kombinasi teknik ini menjadikan dataset lebih beragam dan mendukung pembelajaran model yang lebih robust.

### E. Pelatihan Model YOLOv8n

Tahapan ini terdiri atas dua fase, yaitu fase pelatihan dan fase validasi. Pada fase pelatihan, model dilatih menggunakan training set dengan parameter: 100 epochs, patience 10, batch size 16, image size  $640 \times 640$ , dan optimizer “auto”. Model mengekstraksi gambar acak dari data latih, mendeteksi objek untuk menghasilkan bounding box dan kelas, lalu menghitung loss function dengan membandingkan hasil prediksi terhadap anotasi yang benar. Nilai loss tersebut digunakan oleh optimizer untuk menyesuaikan bobot model, sehingga kesalahan berkurang pada iterasi berikutnya.

Pada fase validasi, model dievaluasi menggunakan validation set dengan proses serupa. Hasil deteksi dibandingkan dengan anotasi sebenarnya untuk menghitung nilai presisi dan menilai kinerja model selama pelatihan, guna memastikan tidak terjadi overfitting.

### F. Evaluasi Model YOLOv8n

Tahap pengujian dilakukan dengan membandingkan enam skenario data augmentation menggunakan data validasi untuk menilai performa model YOLOv8n dalam mendeteksi 15 jenis makanan khas Kalimantan Barat, yaitu Kue Kote, Kue Serabi, Kue Dange, Bubur Padas, Ikan Asam Pedas, Rujak Ebi, Lokok-Lokok, Rendang Pisang, Bubur Gunting, Merke, Pisang Goreng Srikaya, Kerupuk Kulit Ikan Basah, Kue Bingke, Sambal Udang Tempoyak, dan Ayam Pansuh.

Adapun skenario pengujian yang digunakan sebagai berikut:

- a. Skenario 1: Dataset asli tanpa augmentation.
- b. Skenario 2: Flipping horizontal dan vertikal.
- c. Skenario 3: Rotasi 90° searah dan berlawanan arah jarum jam.
- d. Skenario 4: Rotasi bounding box antara  $-15^\circ$  dan  $+15^\circ$ .
- e. Skenario 5: Modifikasi kecerahan bounding box antara  $-15\%$  hingga  $+15\%$ .
- f. Skenario 6: Kombinasi seluruh augmentasi (flipping, rotasi 90°, rotasi bounding box, dan modifikasi kecerahan).

Evaluasi performa model deteksi objek dilakukan untuk menilai akurasi dan kualitas deteksi pada berbagai skenario dunia nyata. Parameter utama yang digunakan adalah akurasi deteksi, yang diukur berdasarkan nilai confidence score yang dihasilkan oleh model untuk setiap objek yang terdeteksi. Nilai confidence score menunjukkan tingkat keyakinan model terhadap hasil deteksi, yang kemudian dianalisis secara statistik untuk menggambarkan performa masing-masing model[15].

#### G. Analisis Performa YOLOv8n

Pada tahapan ini, dilakukan perhitungan untuk mengetahui hasil dari algoritma YOLOv8n dalam mendeteksi gambar makanan khas Kalimantan Barat. Adapun parameter yang dihitung untuk mengetahui performa model pada enam skenario tersebut antara lain, nilai Confusion Matrix, F1-Score, Precision, Recall, mAP50, dan mAP50-95.

#### H. Perbandingan

Tahap ini membahas perbandingan hasil analisis performa model YOLOv8n terhadap enam skenario dataset yang digunakan. Setiap skenario merepresentasikan variasi penerapan data augmentation untuk mengetahui pengaruhnya terhadap kemampuan deteksi model.

### III. ANALISIS DAN HASIL

#### A. Pengumpulan Data

Proses pengumpulan data pada dataset yang digunakan berbentuk citra makanan khas Kalimantan Barat yang diperoleh melalui media internet dan pengambilan gambar menggunakan kamera ponsel. Keseluruhan dataset terdiri dari 15 jenis makanan dan 1.050 data gambar yang berhasil dikumpulkan.

Pemilihan kelas makanan dilakukan melalui data pencarian daring pada tanggal 22 Januari 2025, dengan kriteria jumlah volume pencarian di atas 100 ribu. Dari hasil tersebut, ditetapkan 15 kelas makanan populer, yaitu Kue Kote, Kue Serabi, Kue Dange, Bubur Padas, Ikan Asam Pedas, Rujak Ebi, Lokok-Lokok, Rendang Pisang, Bubur Gunting, Merke, Pisang Goreng Srikaya, Kerupuk Kulit Ikan Basah, Kue Bingke, Sambal Udang Tempoyak, dan Ayam Pansuh.

#### B. Pra-Pemrosesan Data

Pra-pemrosesan data dilakukan untuk menyiapkan dataset sebelum proses pelatihan model YOLOv8n. Tahapan ini meliputi unggah dataset, pembuatan kelas, pelabelan objek, pembagian data, dan resize gambar, yang seluruhnya dilakukan menggunakan Roboflow.

##### a. Upload Dataset

Sebanyak 1.050 citra makanan khas Kalimantan Barat diunggah ke Roboflow agar dataset terorganisir dalam satu sistem terpusat. Proses ini memudahkan pengaturan kelas, anotasi, serta menjaga konsistensi data sebelum labeling dilakukan.

##### b. Pembuatan Kelas Dataset

Kelas dibuat sesuai kategori makanan, seperti Ayam Pansuh, Bubur Padas, dan lainnya. Tiap kelas memiliki nama (*class name*) dan warna (*color*) untuk mempermudah identifikasi visual. Pembuatan kelas ini memastikan model dapat mengenali objek sesuai kategori yang telah ditetapkan.

c. Proses Pelabelan

Pelabelan dilakukan dengan menambahkan bounding box pada objek makanan dalam setiap citra. Tahapan ini penting agar model dapat mengenali posisi dan ukuran objek serta belajar membedakan antara objek dan latar belakang.

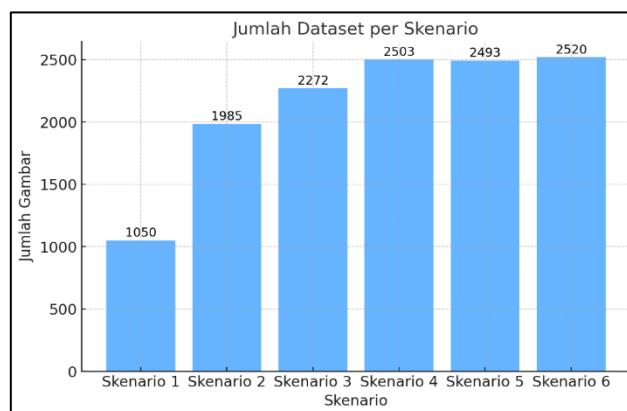
d. Pembagian Dataset

Dataset dibagi menjadi tiga bagian, yaitu 70% data latih, 20% data validasi, dan 10% data uji. Pembagian ini bertujuan agar evaluasi model lebih objektif serta menghindari overfitting dan underfitting.

e. Resize Gambar

Seluruh citra diubah ke ukuran  $640 \times 640$  piksel sesuai kebutuhan arsitektur YOLOv8n. Resize dilakukan untuk menyeragamkan ukuran citra, mengurangi beban komputasi, dan meningkatkan efisiensi pelatihan model.

*C. Augmentasi Data*



Gambar 3 Perbandingan Jumlah Dataset Pada Enam Skenario

Pada gambar 3, proses augmentasi data dilakukan menggunakan perangkat lunak Roboflow dengan tujuan meningkatkan jumlah data latih, memperluas variasi sampel, dan menyeimbangkan distribusi kelas. Langkah ini penting agar model YOLOv8n tidak hanya belajar dari data terbatas, tetapi juga mampu melakukan generalisasi terhadap berbagai kondisi nyata. Dalam penelitian ini, setiap citra pada dataset latih diolah untuk menghasilkan tiga variasi baru melalui beberapa teknik augmentasi, yaitu flipping horizontal dan vertikal, rotasi  $90^\circ$  searah dan berlawanan arah jarum jam, rotasi bounding box antara  $-15^\circ$  hingga  $+15^\circ$ , serta modifikasi kecerahan antara  $-15\%$  hingga  $+15\%$ . Kombinasi teknik ini membantu model mengenali objek dari berbagai orientasi, sudut pandang, dan kondisi pencahayaan yang berbeda, sehingga meningkatkan kemampuan deteksi secara keseluruhan.

Setelah proses augmentasi, dataset sebanyak 1.050 gambar dibagi secara otomatis oleh Roboflow menjadi tiga bagian, yaitu 70% untuk data latih, 20% untuk data validasi, dan 10% untuk data uji. Pembagian dilakukan secara acak dengan tetap menjaga keseimbangan distribusi kelas agar hasil evaluasi model tetap objektif. Data latih digunakan untuk melatih model dalam mengenali pola visual, data validasi untuk mengevaluasi kinerja selama pelatihan dan mencegah overfitting, sedangkan data uji digunakan untuk menilai performa akhir model pada data baru yang belum pernah dilihat sebelumnya.

Hasil augmentasi menunjukkan adanya peningkatan signifikan pada jumlah dataset di setiap skenario, mulai dari 1.050 gambar pada Skenario 1 hingga mencapai 2.520 gambar pada Skenario 6. Peningkatan ini mencerminkan keberhasilan proses augmentasi dalam memperluas variasi data dan memperkaya representasi visual, sehingga mendukung peningkatan akurasi dan ketahanan model YOLOv8n dalam mendeteksi makanan khas Kalimantan Barat pada berbagai kondisi pencahayaan, orientasi, dan sudut pengambilan gambar.

**D. Pelatihan Model YOLOv8n**

**TABEL I**  
**HASIL AKHIR EPOCH**

NO	Skenario	Epoch yang direncanakan	Epoch berhenti
1	Skenario1	100	41
2	Skenario2	100	51
3	Skenario3	100	39
4	Skenario4	100	24
5	Skenario5	100	29
6	Skenario6	100	47

Sebagai contoh, pada Skenario 2, proses pelatihan berhenti pada epoch ke-51 meskipun jumlah epoch yang direncanakan adalah 100. Hal ini menunjukkan bahwa model telah mencapai performa terbaiknya sebelum batas maksimum epoch. Mekanisme Early Stopping menghentikan pelatihan secara otomatis setelah 10 epoch berturut-turut tidak menunjukkan peningkatan nilai validasi, seperti mean Average Precision (mAP) atau penurunan validation loss. Dengan demikian, model pada Skenario 2 dianggap telah mencapai titik konvergensi, di mana pelatihan tambahan tidak lagi meningkatkan performa secara signifikan.

Secara keseluruhan, hasil pada tabel I menunjukkan bahwa mekanisme Early Stopping bekerja secara efektif dalam menentukan waktu penghentian pelatihan yang optimal. Pendekatan ini tidak hanya menghemat waktu komputasi, tetapi juga membantu mencegah terjadinya overfitting, sehingga model yang dihasilkan berada pada kondisi terbaiknya.

**E. Evaluasi Model YOLOv8n**

Pada tahapan ini, dilakukan pengujian menggunakan data testing untuk mengetahui hasil model YOLOv8n dalam mendeteksi citra makanan khas Kalimantan Barat pada masing-masing skenario.



*Gambar 4 Hasil Testing YOLOv8n*

Berdasarkan gambar 4, proses pengujian model dilakukan dengan menggunakan data testing. Tujuan dari pengujian ini adalah untuk menilai seberapa baik model dapat mendeteksi objek secara akurat pada data baru yang tidak digunakan selama proses pelatihan maupun validasi.

**F. Analisis Performa Model YOLOv8n**

**TABEL II**  
PERBANDINGAN PERFORMA ENAM SKENARIO

Skenario	<i>F1-score</i>	Precision	Recall	mAP50	mAP50-95
1	0.601	0.553	0.659	0.67	0.44
2	0.795	0.813	0.778	0.863	0.632
3	0.831	0.832	0.831	0.893	0.639
4	0.814	0.868	0.767	0.888	0.587
5	0.814	0.892	0.75	0.869	0.563
6	0.847	0.868	0.828	0.89	0.587

Dari hasil analisis pada tabel II dapat disimpulkan bahwa peningkatan jumlah data tidak selalu berbanding lurus dengan peningkatan performa model YOLOv8n. Meskipun jumlah gambar bertambah dari 1.050 pada Skenario 1 menjadi 2.520 pada Skenario 6, nilai metrik seperti F1-score, Precision, Recall, mAP50, dan mAP50-95 tidak menunjukkan peningkatan. Pada Skenario 6 menunjukkan performa paling optimal secara keseluruhan, dengan *F1-score* tertinggi sebesar 0,847, precision 0,868, dan *recall* 0,828, yang menandakan keseimbangan yang baik antara ketepatan dan kelengkapan deteksi. Nilai mAP50 sebesar 0,89 juga menunjukkan akurasi deteksi yang tinggi, meskipun nilai mAP50-95 0,587, sedikit lebih rendah dibandingkan Skenario 3. Hal ini mengindikasikan bahwa meskipun kualitas lokalisasi bounding box pada berbagai threshold IoU masih dapat ditingkatkan, secara keseluruhan Skenario 6 mampu memberikan performa deteksi yang paling stabil dan konsisten.

**IV. KESIMPULAN**

Berdasarkan hasil penelitian berjudul “Pengaruh Augmentasi Pada Deteksi Image Otomatis pada Makanan Khas Kalimantan Barat Menggunakan *Metode You Only Look Once* (YOLO)”, dapat disimpulkan bahwa metode YOLOv8n mampu mendeteksi citra makanan khas Kalimantan Barat secara efektif dan efisien. Penelitian ini melibatkan enam skenario pelatihan dengan variasi jumlah data dan teknik augmentasi. Hasil pengujian menunjukkan bahwa augmentasi data berperan penting dalam meningkatkan performa model, khususnya dalam kemampuan generalisasi terhadap data uji. Secara umum, performa terbaik diperoleh pada skenario 6 dengan nilai *F1-score* sebesar 0.847, Precision 0.868, *Recall* 0.828, mAP50 0.89, dan mAP50-95 0.587. Skenario ini menunjukkan keseimbangan terbaik terhadap metrik yang digunakan, sehingga dapat dikategorikan sebagai performa optimal dari keseluruhan pengujian. Dengan demikian, hasil penelitian menunjukkan bahwa jumlah data yang lebih banyak menghasilkan performa model yang lebih baik. Semakin banyak jumlah dataset, terutama jika dikombinasikan dengan augmentasi yang tepat, maka semakin tinggi pula potensi performa model deteksi objek. Namun, peningkatan performa tersebut bersifat tidak linear dan sangat bergantung pada kualitas data, keberagaman sampel, serta kesesuaian teknik augmentasi yang digunakan.

**REFERENSI**

- [1] M. Rofik, N. P. Lestari, dan R. Septianda, “Pertumbuhan Ekonomi, Upah Minimum dan Tingkat Pengangguran di Kalimantan Barat,” *J. Inov. Ekon.*, vol. 3, no. 02, hal. 45–51, 2018, doi: 10.22219/jiko.v3i02.7167.
- [2] J. Jtik, J. Teknologi, D. I. Mulyana, dan R. F. Putra, “Optimasi Deteksi Objek Dengan Segmentasi dan Data Augmentasi Pada Hewan Siput Beracun Menggunakan Algoritma You Only Look Once ( YOLO ),” vol. 8, no. 1, 2024.
- [3] Richo, “Analisis Keandalan YOLOv8m untuk Deteksi Varian Produk Kemasan Kotak

- pada Sistem Manajemen Kesediaan Stock,” vol. 2, hal. 124–131, 2024.
- [4] A. R. Mufita dan F. Utaminingrum, “Deteksi Arah Pergerakan Kepala untuk Navigasi pada Kursi Roda Pintar Menggunakan Kombinasi Metode Berbasis YOLOv8N,” vol. 9, no. 2, hal. 1–5, 2025.
- [5] A. Ayu, S. Mustofa, R. Wulanningrum, dan J. Sahertian, “Deteksi dan Klasifikasi Kue Tradisional Indonesia Menggunakan Detection and Classification of Traditional Indonesian Cakes Using,” vol. 10, no. 1, 2025.
- [6] N. Charibaldi, “PENERAPAN OBJECT DETECTION MENGGUNAKAN DEEP LEARNING YOLOV8 UNTUK MENGIDENTIFIKASI SAMPAH ANORGANIK ( MAKSIMAL SEPULUH OBJEK ) DALAM SATU CITRA IMPLEMENTATION OF OBJECT DETECTION USING DEEP LEARNING YOLOV8 TO IDENTIFY FIVE TYPES OF INORGANIC WASTE ( MAXIMUM TEN OBJECTS ) IN,” vol. 12, no. 1, hal. 195–202, 2025, doi: 10.25126/jtiik.2025129012.
- [7] A. Auliya, T. Dewi, Y. Oktarina, dan M. N. Noer, “Implementasi Pengolahan Citra Menggunakan Metode YOLO pada Security Robot dibidang Pertanian,” *J. Appl. Smart Electr. Netw. Syst.*, vol. 3, no. 02, hal. 43–48, 2022, doi: 10.52158/jasens.v3i02.508.
- [8] B. K. Pratama, Sri Lestanti, dan Yusniarsi Primasari, “Implementasi Algoritma You Only Look Once (YOLO) untuk Mendeteksi Bahasa Isyarat SIBI,” *ProTekInfo(Pengembangan Ris. dan Obs. Tek. Inform.)*, vol. 11, no. 2, hal. 7–14, 2024, doi: 10.30656/protekinfo.v11i2.9105.
- [9] M. Vicko, P. Ardiansyah, J. Sahertian, dan R. Heri, “Penerapan Algoritma YOLO dalam Sistem Klasifikasi Kendaraan,” vol. 9, hal. 1151–1157, 2025.
- [10] D. Masa, S. Panen, dan T. Sayuran, “PENERAPAN ALGORITMA YOLOV8 DALAM DETEKSI WAKTU PANEN TANAMAN PAKCOY BERBASIS WEBSITE,” vol. 7, no. 4, hal. 2489–2495, 2023.
- [11] dan P. Dinas Kepemudaan, Olahraga, *WISATA KULINER KALBAR*. Pontianak, 2022. [Daring]. Tersedia pada: <https://disporapar.kalbarprov.go.id/file/7t3Gf7THadtQj2uR8ETQ.pdf>
- [12] D. Deteksi, D. A. N. Klasifikasi, P. Tidur, Y. You, O. Look, dan K. Kunci, “EVALUASI PERFORMA ALGORITMA YOLOV8 DALAM DETEKSI DAN KLASIFIKASI POSISI TIDUR Abstrak”.
- [13] S. Mujilahwati, M. Sholihin, dan R. Wardhani, “Optimasi Hyperparameter TensorFlow dengan Menggunakan Optuna di Python: Study Kasus Klasifikasi Dokumen Abstrak Skripsi,” *J. Media Inform. Budidarma*, vol. 5, no. 3, hal. 1084, 2021, doi: 10.30865/mib.v5i3.3090.
- [14] B. Meilita dan W. Yustanti, “Sistem Deteksi Penyakit Kulit Kucing Menggunakan Algoritma You Only Look Once ( YOLO ) v8,” vol. 05, no. 02, hal. 178–188, 2024.
- [15] A. P. Hadi, R. E. Siregar, P. Wilmar, B. Indonesia, D. Objek, dan D. Learning, “Evaluasi Performa Yolov8 Dalam Deteksi Objek Di Depan Kendaraan Dengan Variasi Kondisi Lingkungan,” vol. 13, hal. 1755–1773, 2024.