

## **Klasifikasi Berat Itik Pedaging Berbasis *Convolutional Neural Network* dan *Internet of Things***

### **Classification of Broiler Duck Weight Based on Convolutional Neural Network and Internet of Things**

**Sindhu Hari Mukti<sup>1</sup>, Ardi Pujiyanta<sup>2</sup>, Abdul Fadlil<sup>3</sup>**

<sup>1,2,3</sup> Program Studi S2 Teknik Elektro, Fakultas Teknologi Industri, Universitas Ahmad Dahlan  
<sup>1,2,3</sup> Jl. Ringroad Selatan, Kragilan, Tamanan, Kec. Banguntapan, Kabupaten Bantul, Daerah Istimewa  
Yogyakarta 55191

email: \*<sup>1</sup>2308057019@webmail.uad.ac.id, <sup>2</sup>ardipujiyanta@tif.uad.ac.id, <sup>3</sup>fadlil@mti.uad.ac.id

---

#### **Informasi Artikel**

Dikirim, 16 Agustus 2025  
Diterima, 7 Desember 2025  
Diterbitkan, 17 Desember 2025

---

#### **Kata Kunci :**

Klasifikasi Itik, CNN,  
Vision Transformer, IoT, *Load Cell*

---

#### **Keyword :**

Duck Classification, CNN  
Vision Transformer, IoT  
Load Cell

---

#### **ABSTRAK**

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi berat itik pedaging secara otomatis menggunakan Convolutional Neural Network (CNN) yang terintegrasi dengan teknologi *Internet of Things* (IoT). Data citra itik diperoleh melalui kamera USB, yang kemudian diproses menggunakan model CNN dan Vision Transformer (ViT) untuk mengklasifikasikan berat itik ke dalam kategori kurus, sedang, dan gemuk. Sistem ini juga memanfaatkan sensor *load cell* untuk memberikan data bobot aktual sebagai referensi. Hasil pengujian menunjukkan bahwa model CNN memperoleh akurasi 85,1%, sementara model ViT mencapai akurasi 85,8%. Selain itu, sistem IoT memungkinkan hasil klasifikasi dapat dipantau secara *real-time* oleh peternak, meningkatkan efisiensi dalam manajemen penggemukan itik. Sistem ini berpotensi menjadi solusi non-invasif yang efektif dalam meningkatkan akurasi penentuan bobot itik di peternakan.

---

#### **ABSTRACT**

This study aims to develop an automated broiler duck weight classification system using Convolutional Neural Networks (CNN) integrated with Internet of Things (IoT) technology. Duck image data were captured using a USB camera and processed using CNN and Vision Transformer (ViT) models to classify the ducks into categories of thin, medium, and fat. The system also utilizes a load cell sensor to provide actual weight data as a reference. The test results showed that the CNN model achieved an accuracy of 85.1%, while the ViT model achieved an accuracy of 85.8%. Additionally, the IoT system allows for real-time monitoring of classification results by farmers, improving efficiency in duck fattening management. This system has the potential to serve as an effective non-invasive solution for improving the accuracy of weight determination in duck farming.

---

## **1. PENDAHULUAN**

Penelitian terkait klasifikasi berat hewan ternak berbasis pengolahan citra digital dan kecerdasan buatan semakin berkembang, seiring dengan meningkatnya kebutuhan akan sistem yang dapat mengklasifikasikan bobot ternak secara otomatis dan efisien. Dalam bidang peternakan itik pedaging, metode manual dalam mengklasifikasikan berat itik sering kali mengarah pada ketidakakuratan, karena peternak masih mengandalkan pengamatan fisik secara visual. Penggunaan timbangan digital memberikan hasil yang lebih akurat, namun terbatas dalam hal biaya dan ketersediaan alat. Sebagai alternatif, teknologi *Convolutional Neural Network* (CNN) telah diterapkan dalam berbagai bidang peternakan untuk mengklasifikasikan berat badan ternak secara otomatis berdasarkan citra tubuh hewan.

Pada penelitian sebelumnya, mengembangkan metode estimasi berat bebek menggunakan teknik pengolahan citra berbasis LabVIEW dan regresi linier. Penelitian ini menunjukkan keberhasilan estimasi berat bebek dengan menggunakan citra yang diambil dari kamera, namun masih bergantung pada pemrosesan

---

manual dan tidak otomatis [1]. Di sisi lain, mengembangkan aplikasi berbasis pengolahan citra digital untuk estimasi bobot sapi, yang dapat memberikan referensi penting dalam pengembangan sistem klasifikasi berbasis citra untuk itik pedaging. Hasilnya menunjukkan bahwa aplikasi ini dapat memberikan estimasi bobot dengan akurasi tinggi [2].

Penelitian terkait penerapan CNN dalam klasifikasi citra untuk estimasi bobot ternak juga semakin banyak dilakukan. Menggunakan CNN untuk klasifikasi bobot ayam broiler [3]. Penerapan CNN juga pernah dilakukan untuk mengklasifikasikan jenis daging mentah. Meskipun penggunaan CNN terbukti efektif, studi ini masih terbatas pada spesifik hewan dan jenis klasifikasi tertentu, yang membuka peluang untuk menerapkan teknologi ini pada itik pedaging [4].

Di sisi lain, sistem berbasis *Internet of Things (IoT)* telah terbukti dapat meningkatkan efisiensi dalam memantau kondisi ternak secara *real-time*. Pengembangan sistem pakan otomatis untuk budidaya udang vaname berbasis IoT dan pengolahan citra digital, yang menunjukkan bagaimana IoT dapat terintegrasi dengan sistem klasifikasi untuk memudahkan peternak dalam memantau berat udang secara otomatis [5]. Penerapan teknologi IoT untuk diagnosis penyakit tanaman padi berbasis citra digital dan *transfer learning*, yang menginspirasi penelitian ini untuk mengintegrasikan IoT dengan pengolahan citra dalam sistem klasifikasi bobot itik pedaging [6].

Penelitian lain yang relevan dilakukan dengan cara mengembangkan sistem analisis regresi berbasis citra digital untuk evaluasi mutu buah jeruk selama penyimpanan [7]. Objek kajian dalam penelitian lainnya adalah citra daun padi yang merepresentasikan berbagai kondisi kesehatan dan jenis penyakit daun padi yang umum terjadi pada lahan pertanian. Metode yang digunakan berupa pengembangan sistem diagnosis otomatis berbasis pengenalan citra dengan model CNN menggunakan arsitektur *EfficientNetB0* melalui pendekatan pembelajaran transfer. Model dilatih dan diuji menggunakan himpunan data citra daun padi yang telah divalidasi oleh pakar pertanian, kemudian diintegrasikan ke dalam aplikasi seluler yang memanfaatkan layanan *Firebase* [8]. Selain itu, beberapa penelitian lain juga mengembangkan sistem berbasis pengolahan citra digital untuk identifikasi prediksi bobot buah [9], dan *computer vision* digunakan untuk mengambil fitur dan regresi linear untuk memprediksi ukuran berat dan panjang ikan dan sayuran [10].

Dalam kajian penggunaan pengolahan citra untuk estimasi bobot sapi dan padi menunjukkan pentingnya metode *deep learning* dan deteksi objek untuk memperoleh akurasi yang tinggi dalam klasifikasi berat badan hewan ternak, termasuk itik pedaging [11]. Pengkajian pengolahan citra digital untuk klasifikasi jenis tumbuhan dengan menggunakan CNN, yang dapat dijadikan referensi untuk aplikasi teknologi ini pada klasifikasi bobot itik pedaging [12].

Dengan kemajuan teknologi terkini, terdapat peningkatan penerapan sensor pencitraan yang menyediakan data citra sederhana, waktu nyata, non-destruktif, dan murah untuk prediksi cepat sifat benih berbasis citra dalam program pemuliaan tanaman [13]. Selain itu, adanya suatu sistem otomatis yang dapat mendeteksi kesegaran daging akan sangat membantu dalam mengatasi permasalahan sulitnya deteksi kesegaran daging. Kesegaran daging dapat dikategorikan antara lain daging segar, setengah segar dan tidak segar. Penggunaan model *machine learning* untuk mendeteksi kesegaran daging dapat membantu memecahkan permasalahan tersebut [14]. Metode tradisional, perhitungan formula, dan perkiraan visual manusia semuanya dapat digunakan untuk menentukan berat sapi. Teknologi Informasi dan Komputasi dapat digunakan untuk membantu memberikan solusi alternatif untuk masalah ini, seperti menggunakan pemrosesan citra digital untuk mengidentifikasi ukuran tubuh sapi yang sebenarnya [15].

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi bobot itik pedaging berbasis CNN yang terintegrasi dengan IoT, dengan harapan dapat memberikan kontribusi dalam memperkenalkan teknologi modern untuk meningkatkan efisiensi dan akurasi dalam manajemen peternakan itik, serta mempermudah peternak dalam pengambilan keputusan yang lebih cepat dan tepat.


## 2. METODE PENELITIAN

### 2.1. Objek Penelitian


Objek penelitian ini adalah itik pedaging yang dipelihara dalam rentang bobot 600–1500 gram, yang mewakili fase pertumbuhan menuju panen. Pemilihan rentang bobot ini didasarkan pada karakteristik pertumbuhan itik pedaging yang biasanya dipelihara selama 35–45 hari dengan berat rata-rata panen 1,2 sampai 1,5 kg.

Data penelitian diperoleh dengan mengambil citra tubuh itik menggunakan kamera USB yang dipasang di area penimbangan dan mengukur bobot aktual itik menggunakan sensor *load cell* sebagai data label *ground truth*. Kamera yang digunakan berjumlah dua buah, jarak yang telah ditentukan kamera dari depan objek

berjarak 80 cm, dan kamera dari atas objek berjarak 90 cm. Sistem klasifikasi bobot ini mengklasifikasikan itik ke dalam tiga kategori bobot yaitu : kurus, sedang, dan gemuk. Desain alat penimbang dapat dilihat pada Gambar 1 dan Gambar 2



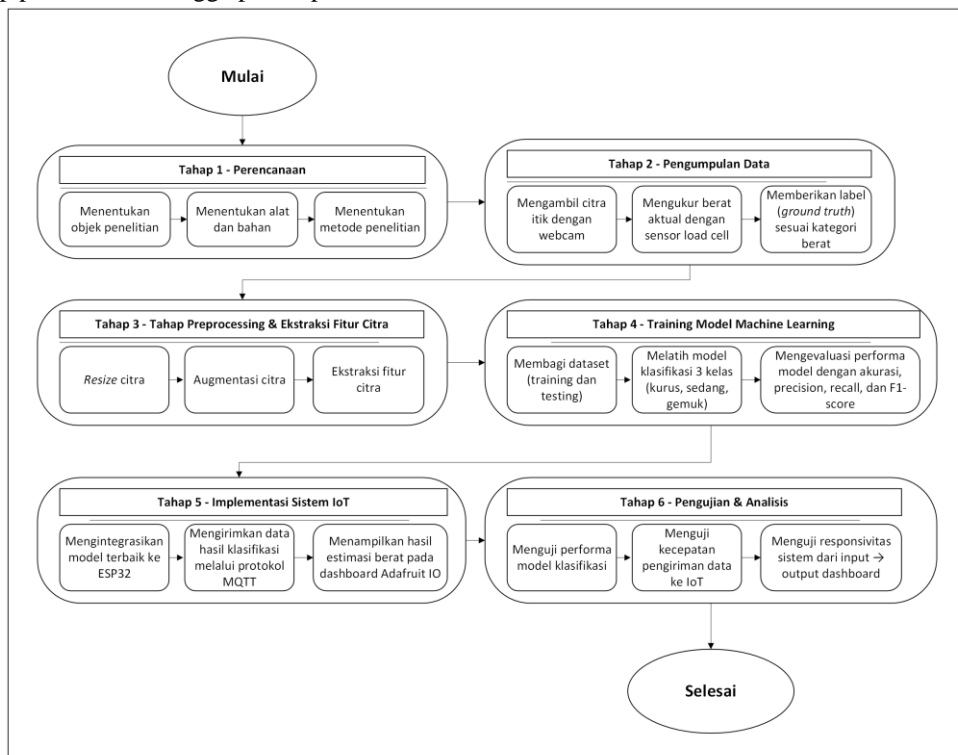
Gambar 1. Desain Alat Penimbang dan Kamera Tampak Samping



Gambar 2. Desain Alat Penimbang dan Kamera Tampak Depan

## 2.2. Pra-Pemrosesan

Untuk memberikan gambaran menyeluruh mengenai alur pelaksanaan penelitian, dibuatlah diagram alir metodologi seperti pada Gambar 3. Diagram ini memvisualisasikan urutan tahapan yang dilaksanakan mulai dari tahap perencanaan hingga penutup.



Gambar 3. Diagram Alur Penelitian

### 2.3. Alat dan Bahan

Untuk membangun dan menguji sistem estimasi berat itik berbasis pengolahan citra, digunakan sejumlah alat dan bahan yang mencakup perangkat keras (*hardware*) dan perangkat lunak (*software*). Rincian lengkap alat dan bahan yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Alat dan Bahan Penelitian

No	Komponen <i>Hardware</i>	Kegunaan
1	Mini PC	Untuk memproses data citra dan mengelola sistem IoT
2	ESP32 Devkit	Mengontrol sensor dan komunikasi data ke sistem IoT.
3	Sensor Load Cell 5Kg	Mengukur berat itik secara langsung.
4	Amplifier HX711	Menguatkan sinyal dari sensor <i>load cell</i> ke ESP32.
5	Dua Kamera USB	Mengambil citra tubuh itik dari berbagai sudut.
6	LCD Oled	Menampilkan status sistem atau hasil pengukuran.
7	Box Akrilik	Tempat untuk melindungi dan merapikan perangkat elektronik.
8	Holo Stainless Tempat Sensor Loadcell	Dudukan kuat dan stabil untuk meletakkan sensor <i>load cell</i> dan itik.

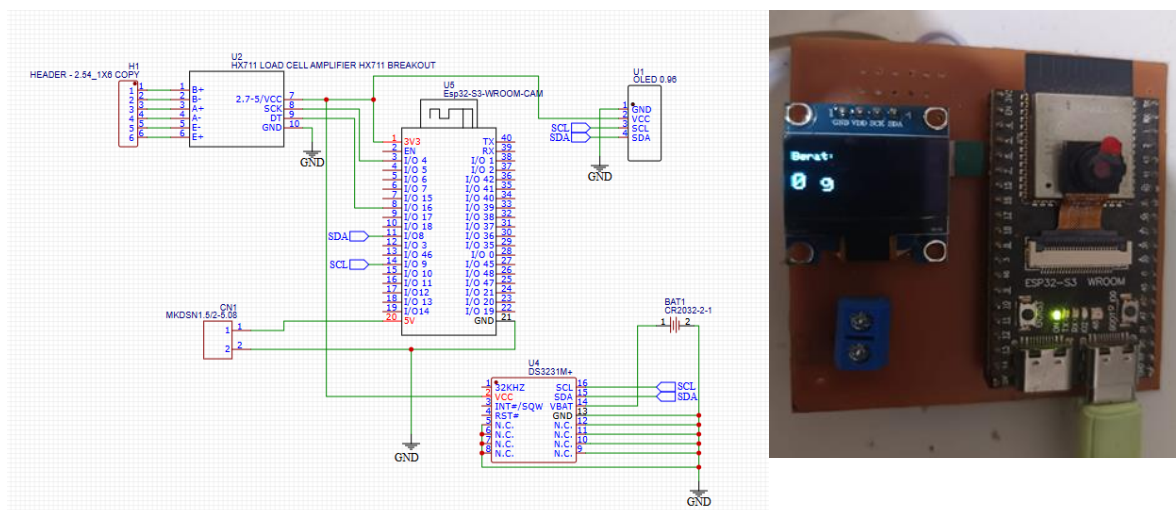
Setelah seluruh komponen perangkat keras dirancang dan disusun sesuai dengan fungsinya masing-masing, sistem ini juga memerlukan dukungan dari perangkat lunak untuk mengelola, dan menampilkan data yang diperoleh dari proses akuisisi. Beberapa *software* yang digunakan untuk mendukung penelitian diperlihatkan pada Tabel 2. *Software* yang digunakan.

Tabel 2. *Software* Pendukung

No	Software Pendukung	Kegunaan
1	Windows	OS
2	Python	Pemrograman pengolahan citra
3	Arduino IDE	Pemrograman ESP32
4	Roboflow	pelabelan dan pelatihan model citra.
5	Adafruit io	menampilkan data secara <i>real-time</i> .

### 2.4. Perancangan Sistem

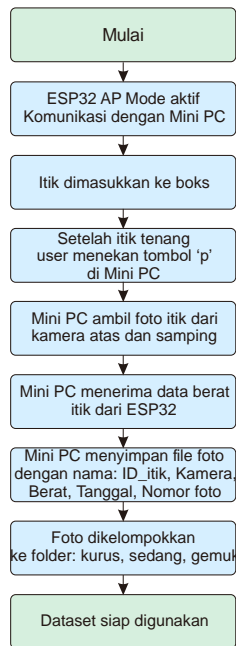
Perancangan sistem klasifikasi berat itik pedaging berbasis CNN dan IoT dimulai ketika itik dimasukkan ke dalam boks pengukuran. Sensor *load cell* yang terhubung dengan ESP32 secara otomatis membaca bobot itik, kemudian menampilkannya melalui layar OLED. Informasi bobot yang terukur ini sekaligus digunakan untuk memberi label pada citra yang diambil, sehingga dataset dapat langsung dikelompokkan ke dalam kategori kurus, sedang, atau gemuk.



Gambar 4. Skematik Penimbang Berat Itik Menggunakan Sensor *Load Cell*



Gambar 5. Pengambilan Foto Itik Sebagai Dataset Model di Kandang Peternak



Gambar 6. Flowchart Proses Pengambilan Dataset Itik Pedaging

File folder		
Bebek Gemuk	09/08/2025 11:33	File folder
Bebek Kurus	09/08/2025 10:10	File folder
Bebek Sedang	09/08/2025 11:33	File folder

Gambar 7. Isi Folder Dataset yang Digunakan Untuk Klasifikasi

Image	
Image ID	
Dimensions	640 x 360
Width	640 pixels
Height	360 pixels
Horizontal resolution	96 dpi
Vertical resolution	96 dpi
Bit depth	24
Compression	
Resolution unit	
Color representation	
Compressed bits/pixel	

Gambar 8. Metadata Citra Itik dengan Resolusi 640 X 360 Piksel

Tabel 3. Distribusi Dataset Citra Itik

No	Kelas Bobot	Rentang Bobot (gram)	Jumlah Citra
1	Kurus	600-900	90
2	Sedang	901-1200	361
3	Gemuk	1201-1500	219

Tabel 3 menunjukkan distribusi jumlah citra untuk masing-masing kelas bobot itik. Dari data yang terkumpul, kelas *sedang* memiliki jumlah citra terbanyak, diikuti oleh kelas *gemuk*, dan kelas *kurus* memiliki jumlah citra paling sedikit. Distribusi ini memberikan gambaran awal mengenai representasi setiap kelas dalam dataset yang digunakan untuk pelatihan dan pengujian model.

Tabel 4 menunjukkan pembagian dataset ke dalam tiga kelompok utama, yaitu data *training*, *validasi*, dan *pengujian*. Sebelum digunakan dalam pelatihan, seluruh citra terlebih dahulu melalui tahapan preprocessing dan augmentasi guna meningkatkan kualitas serta keragaman data. Pada tahap preprocessing, dilakukan auto-orientasi untuk menyamakan arah citra, serta resize dengan metode stretch ke resolusi  $640 \times 640$  piksel agar sesuai dengan format input model. Selanjutnya, proses augmentasi diterapkan untuk memperkaya variasi citra dan meningkatkan kemampuan generalisasi model. Teknik augmentasi yang digunakan meliputi flip horizontal, rotasi  $90^\circ$  baik searah maupun berlawanan arah jarum jam, rotasi acak antara  $-15^\circ$  hingga  $+15^\circ$ , serta penambahan efek blur hingga 2.5 piksel.

Tabel 4. Dataset Model klasifikasi ResNet50

Jenis Dataset	Jumlah Citra
Training	1407
Validasi	134
Pengujian	67

Tabel 5. Hasil Pengujian Klasifikasi ResNet50

Itik	Prediksi	Kelas DataSet	Kelas Prediksi	Konfidance	Berat (gr)
1	TP	GEMUK	GEMUK	64	1328
2	TP	GEMUK	GEMUK	86	1399
3	TP	GEMUK	GEMUK	86	1459
4	TP	SEDANG	SEDANG	89	1048
5	TP	SEDANG	SEDANG	55	1199
6	TP	GEMUK	GEMUK	93	1458
7	TP	GEMUK	GEMUK	99	1315
8	TF	GEMUK	KURUS	84	1339
9	TP	GEMUK	GEMUK	99	1437
10	TP	GEMUK	GEMUK	79	1299
11	TN	GEMUK	SEDANG	79	1320
12	TP	SEDANG	SEDANG	75	1022
13	TP	GEMUK	GEMUK	98	1457
14	TP	KURUS	KURUS	99	819
15	TP	KURUS	KURUS	100	651
16	TP	KURUS	KURUS	99	613
17	TP	KURUS	KURUS	97	873
18	TP	KURUS	KURUS	93	848
19	TN	SEDANG	KURUS	82	1027
20	TP	SEDANG	SEDANG	53	1096
21	TP	SEDANG	SEDANG	62	1092
22	TP	SEDANG	SEDANG	86	1018
23	TP	SEDANG	SEDANG	100	977
24	TP	SEDANG	SEDANG	99	982
25	TP	SEDANG	SEDANG	100	991
26	TP	SEDANG	SEDANG	100	924
27	TP	SEDANG	SEDANG	100	1078
28	TP	SEDANG	SEDANG	100	1052
29	TP	SEDANG	SEDANG	100	1079
30	TP	SEDANG	SEDANG	100	1107

Tabel 6. Hasil Pengujian Klasifikasi Vision Transformer (ViT)

Itik	Prediksi	Kelas DataSet	Kelas Prediksi	Confidance	Berat (gr)
1	TP	GEMUK	GEMUK	97	1328
2	TP	GEMUK	GEMUK	86	1399
3	TP	GEMUK	GEMUK	95	1459
4	TP	SEDANG	SEDANG	56	1048
5	TP	SEDANG	SEDANG	95	1199
6	TP	GEMUK	GEMUK	87	1458
7	TP	GEMUK	GEMUK	96	1315
8	TF	GEMUK	KURUS	68	1339
9	TP	GEMUK	GEMUK	97	1437
10	TP	GEMUK	GEMUK	95	1299
11	TP	GEMUK	GEMUK	94	1320
12	TP	SEDANG	SEDANG	95	1022
13	TP	GEMUK	GEMUK	85	1457
14	TP	KURUS	KURUS	98	819
15	TP	KURUS	KURUS	98	651
16	TP	KURUS	KURUS	98	613
17	TP	KURUS	KURUS	98	873
18	TP	KURUS	KURUS	98	848
19	TF	SEDANG	KURUS	68	1027
20	TF	SEDANG	KURUS	93	1096
21	TF	SEDANG	KURUS	86	1092
22	TP	SEDANG	SEDANG	88	1018
23	TP	SEDANG	SEDANG	99	977
24	TP	SEDANG	SEDANG	98	982
25	TP	SEDANG	SEDANG	99	991
26	TP	SEDANG	SEDANG	99	924
27	TP	SEDANG	SEDANG	99	1078
28	TP	SEDANG	SEDANG	99	1052
29	TP	SEDANG	SEDANG	99	1079
30	TP	SEDANG	SEDANG	99	1107

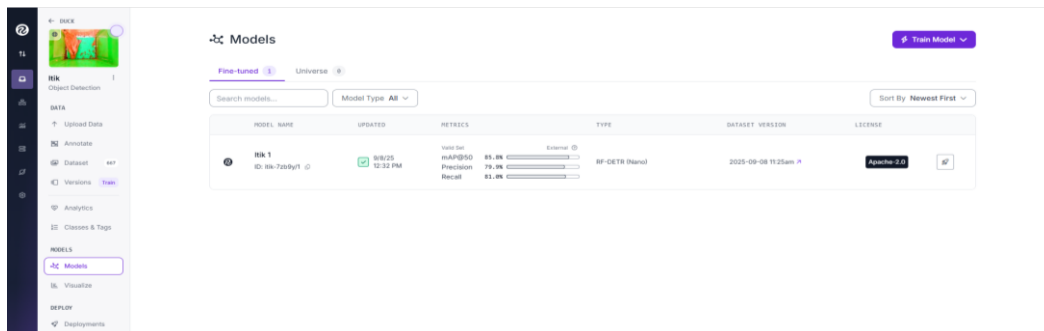
### 2.5. Pembuatan Model Deteksi dan Model Klasifikasi

Pada penelitian ini digunakan dua model yang berbeda, yaitu model deteksi objek dan model klasifikasi. Model deteksi objek berfungsi untuk memastikan keberadaan itik di dalam citra hasil tangkapan kamera, sedangkan model klasifikasi digunakan untuk menentukan kategori berat itik, yaitu kurus, sedang, atau gemuk.

Proses pelatihan dilakukan menggunakan Roboflow dengan tahap preprocessing berupa *resize* citra ke ukuran 640×640 piksel, *auto-orient*, dan penyesuaian kontras menggunakan *adaptive equalization*. Untuk memperkaya variasi data dilakukan augmentasi berupa *horizontal flip*, rotasi antara  $-15^\circ$  hingga  $+15^\circ$ , perubahan saturasi  $\pm 25\%$ , perubahan kecerahan  $\pm 15\%$ , serta penambahan *blur* hingga 2.5 piksel. Dataset dibagi menjadi tiga bagian, yaitu 87% untuk data latih, 8% untuk validasi, dan 5% untuk pengujian.


#### a. Pembuatan Model Deteksi Objek

Ditunjukkan Gambar 9 model deteksi objek yang digunakan adalah RF-DETR Nano. Model ini menghasilkan keluaran berupa posisi *bounding box* dan nilai *confidence score*. Apabila nilai *confidence* lebih dari 0,6 maka citra hasil deteksi diteruskan ke tahap klasifikasi, sedangkan jika kurang dari 0,6 maka dianggap itik tidak terdeteksi.



Gambar 9. Hasil Pelatihan Model Deteksi Objek

Hasil pelatihan menunjukkan bahwa model mampu mencapai performa yang cukup baik, dengan nilai mAP@50 sebesar 85,8%, precision 79,9%, dan recall 81,0%. Nilai precision menunjukkan tingkat ketepatan model dalam mengidentifikasi objek itik secara benar, sedangkan recall menunjukkan kemampuan model untuk mendeteksi seluruh objek itik yang ada pada citra. Nilai mAP (mean *Average Precision*) digunakan sebagai indikator keseluruhan performa model dalam mendeteksi objek dengan akurasi spasial yang baik.



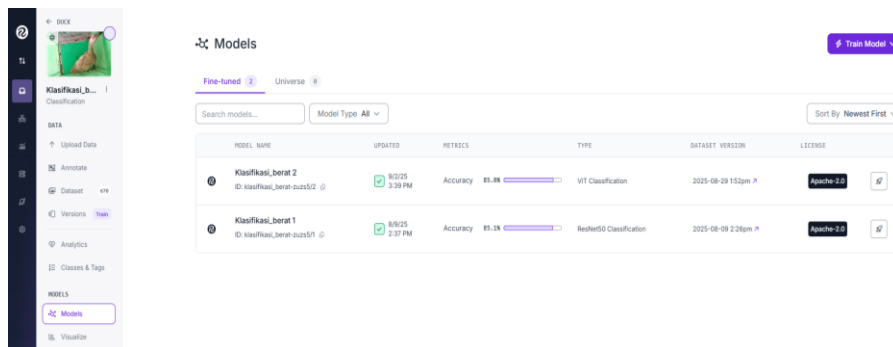
Gambar 10. Pengujian Model RF-DETR (Nano) untuk Deteksi Objek Itik

#### b. Pembuatan Model Klasifikasi Objek

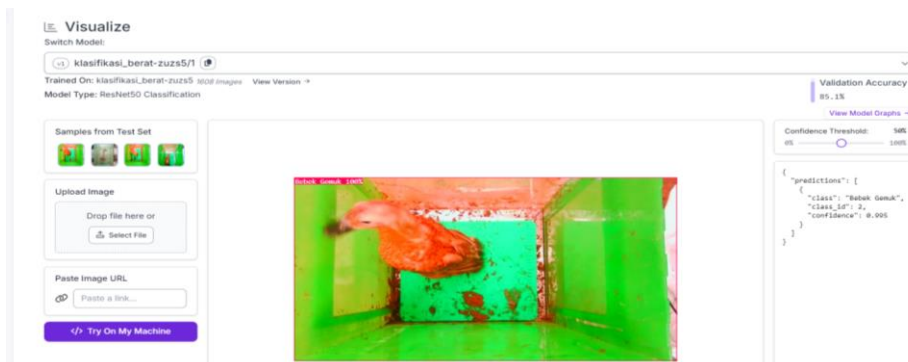
Setelah objek itik berhasil terdeteksi, citra kemudian diproses ke tahap klasifikasi bobot. Pada penelitian ini digunakan dua arsitektur berbeda sebagai pembandingan, yaitu:

- CNN ResNet50, yang memanfaatkan lapisan konvolusi berlapis-lapis untuk mengekstraksi fitur citra secara hierarkis.
- Vision Transformer (ViT), yang memanfaatkan mekanisme *self-attention* untuk memahami representasi global dari citra.

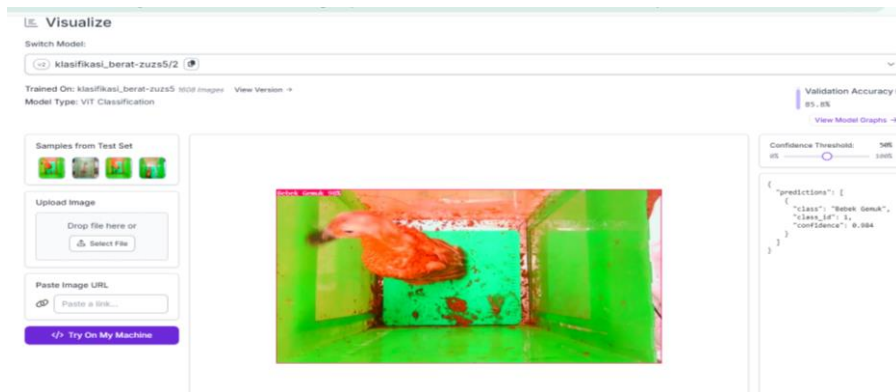
Gambar 11 berikut menyajikan hasil pelatihan kedua model tersebut berdasarkan akurasi yang dicapai setelah melalui proses augmentasi dan normalisasi dataset di platform Roboflow.



Gambar 11. Hasil Pelatihan Model Klasifikasi Objek



Gambar 12. Hasil Visualisasi Klasifikasi ResNet50



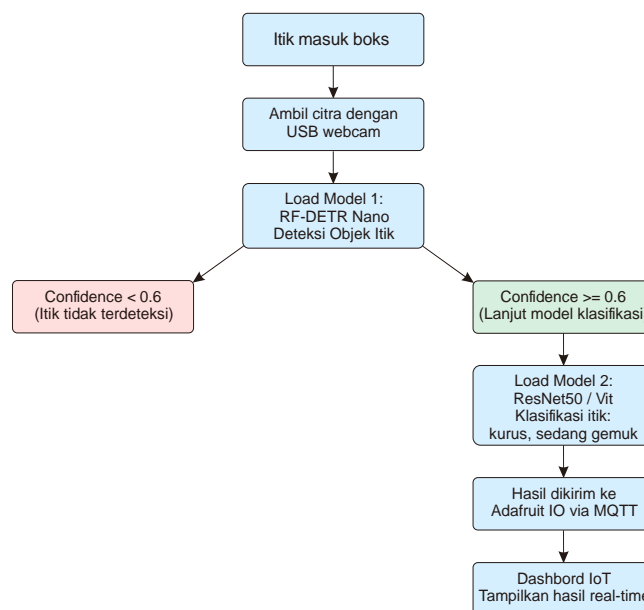
Gambar 13. Hasil Visualisasi Klasifikasi ViT

Hasil pelatihan menunjukkan bahwa model ResNet50 memperoleh akurasi sebesar 85,1%, sedangkan model ViT memperoleh akurasi sedikit lebih tinggi yaitu 85,8%. Perbandingan ini penting karena memberikan gambaran performa dua pendekatan yang berbeda: ResNet50 dengan arsitektur berbasis CNN yang unggul dalam ekstraksi fitur spasial lokal, dan Vision Transformer yang memanfaatkan mekanisme self-attention untuk menangkap dependensi global antar patch citra.

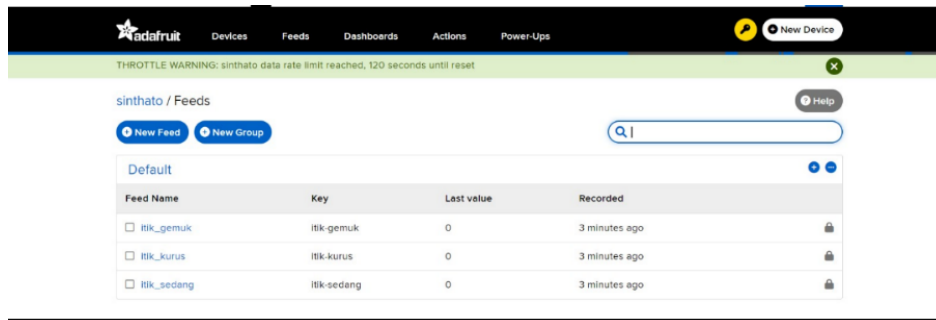
## 2.6. Validasi Pengujian Performa

Pengujian sistem dilakukan untuk mengevaluasi kinerja keseluruhan sistem dalam klasifikasi bobot itik pedaging dan memantau hasilnya secara *real-time*. Beberapa tahapan pengujian yang dilakukan adalah sebagai berikut:

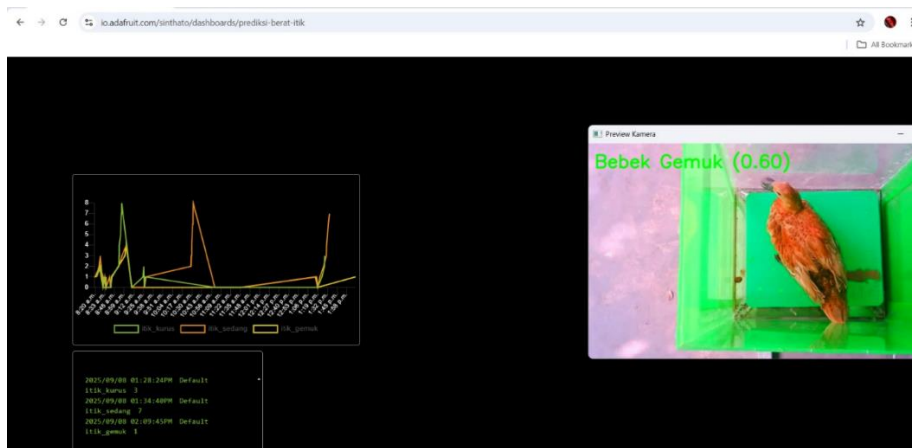
1. Pengujian Deteksi Objek: Model RF-DETR Nano diuji untuk mendeteksi itik pada citra yang diambil. Model ini memeriksa apakah citra tersebut mengandung itik atau tidak. Jika itik terdeteksi dengan nilai confidence lebih dari 0,6, citra diteruskan ke tahap klasifikasi.
2. Pengujian Klasifikasi Bobot: Setelah itik terdeteksi, citra tersebut diproses dengan dua model, **ResNet50** dan **ViT**, untuk mengklasifikasikan bobot itik ke dalam kategori kurus, sedang, atau gemuk. Pengujian dilakukan untuk mengevaluasi akurasi klasifikasi berdasarkan dataset citra yang telah dilabeli.
3. Pengujian Responsivitas Sistem: Evaluasi dilakukan untuk mengukur waktu respons sistem dalam mengklasifikasikan bobot itik dan mengirimkan hasil ke platform Adafruit IO.
4. Pengujian Pengiriman Data IoT: Sistem diuji untuk memastikan data klasifikasi dapat dikirimkan dengan lancar dan ditampilkan secara *real-time* di platform **Adafruit IO**, sehingga peternak dapat memantau kondisi bobot itik dengan efisien.



Gambar 14. Skema Pengujian Sistem Keseluruhan untuk Klasifikasi Berat Itik



Gambar 15. Pemberian Feed untuk Class Objek Itik dari Dashboard Adafruit IoT



Gambar 16. Implementasi Sistem Klasifikasi Load Model dan IoT

Pada Gambar 16 memperlihatkan implementasi sistem klasifikasi citra yang diintegrasikan dengan dashboard pemantauan berbasis *Internet of Things* (IoT) melalui platform Adafruit IO. Tampilan pada sisi kanan menunjukkan keluaran prediksi dari model klasifikasi, di mana objek uji berupa itik berhasil teridentifikasi dalam kategori “Gemuk” dengan tingkat kepercayaan (*confidence score*) sebesar 0,60. Hasil ini menegaskan bahwa sistem mampu memberikan informasi kondisi tubuh itik secara *real-time* berdasarkan data visual yang diperoleh dari kamera.

## 2.7. Rumus Arsitektur CNN

Arsitektur umum *Convolutional Neural Network* (CNN) yang terdiri atas beberapa lapisan utama, yaitu *input layer*, *convolutional layer*, *pooling layer*, *fully connected layer*, dan *output layer*.

### 1. Convolutional layer

Lapisan konvolusi bertugas mengekstraksi fitur dari citra dengan melakukan operasi konvolusi antara filter (*kernel*) dengan citra input. Persamaan operasi konvolusi 2D:

$$(f * g)(x, y) = \sum_m \sum_n f(m, n) \cdot g(x - m, y - n) \dots\dots\dots(1)$$

Dengan *f* adalah citra *input* dan *g* adalah *filter/kernel*.

### 2. Activation Function (ReLU)

Fungsi aktivasi ReLU (*Rectified Linear Unit*) memperkenalkan non-linearitas ke dalam jaringan.

$$f(x) = \max(0, x) \dots\dots\dots(2)$$

### 3. Pooling Layer

Digunakan untuk mereduksi dimensi data dan jumlah parameter. Contoh umum adalah *max pooling*:

$$y = \max_{i,j} (0, x_{i,j}) \dots\dots\dots(3)$$

### 4. Connected Layer

Lapisan ini menghubungkan seluruh neuron untuk menghasilkan output akhir berupa prediksi kelas.

### 5. Softmax Function

Untuk klasifikasi multi-kelas, CNN menggunakan fungsi softmax pada lapisan output:

$$\sigma(Z_i) = \frac{e^{Z_i}}{\sum_{j=1}^K e^{Z_j}} \dots\dots\dots(4)$$

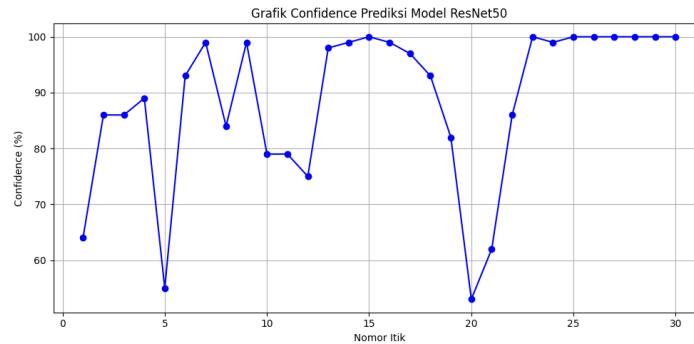
Dengan demikian, *machine learning* dapat digunakan untuk mengklasifikasikan bobot itik ke dalam kelas kurus, sedang, dan gemuk. Algoritma klasik seperti *Support Vector Machine* (SVM) atau *K-Nearest Neighbor* (KNN) sebelumnya banyak digunakan, tetapi CNN lebih unggul karena mampu mengekstraksi fitur citra secara otomatis.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Hasil Pengujian Model Klasifikasi

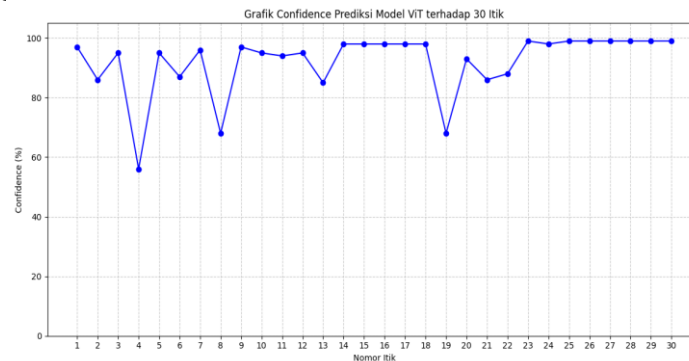
Pada tahap pengujian, sistem klasifikasi bobot itik pedaging berbasis *Convolutional Neural Network* (CNN) dan *Vision Transformer* (ViT) diuji untuk mengklasifikasikan bobot itik ke dalam tiga kategori: kurus, sedang, dan gemuk. Hasil pengujian model dihitung berdasarkan akurasi, presisi, dan recall.

- a. **Model CNN:** Berdasarkan Tabel 5, model CNN *Resnet50* menghasilkan akurasi sebesar 85,1%, dengan presisi 84,3% dan recall 83,8%. Ini menunjukkan bahwa model CNN mampu mengklasifikasikan bobot itik dengan akurasi yang cukup tinggi. Namun, model ini menunjukkan sedikit penurunan pada recall, yang menunjukkan adanya kesalahan pada beberapa kategori bobot itik yang lebih tipis.



Gambar 17. Grafik Confidence Prediksi Model ResNet50

- b. **Model ViT:** Berdasarkan Tabel 6, model *Vision Transformer* (ViT) memberikan hasil akurasi yang lebih baik yaitu **85,8%**, dengan presisi 86,2% dan recall 85,5%. Hasil ini menunjukkan bahwa ViT lebih unggul dalam mengklasifikasikan bobot itik pedaging, terutama dalam hal pengelompokan itik ke dalam kategori bobot yang lebih tepat.



Gambar 18. Grafik Confidence Prediksi Model ViT

#### 3.2. Pembahasan

Penelitian ini menunjukkan kemajuan signifikan dalam klasifikasi berat itik pedaging dibandingkan dengan beberapa penelitian sebelumnya yang terkait dengan pengolahan citra dan *deep learning*. Penelitian Lieng & Sangpradit (2020) mengembangkan metode estimasi berat itik menggunakan pengolahan citra, namun masih mengandalkan proses manual, sedangkan penelitian ini memanfaatkan *Convolutional Neural Network* (CNN) dan *Vision Transformer* (ViT) untuk klasifikasi otomatis, yang merupakan langkah maju dalam mengurangi ketergantungan pada metode manual dan meningkatkan efisiensi. Selain itu, penelitian ini mengintegrasikan teknologi IoT untuk pemantauan hasil klasifikasi secara *real-time*, yang tidak ditemukan pada penelitian sebelumnya.

Penelitian Mahendra & Riadi (2022) mengembangkan aplikasi pengolahan citra untuk estimasi bobot sapi, yang menggunakan metode titik berat berbasis Android. Meskipun aplikasi ini berhasil dalam estimasi bobot, penelitian ini terbatas pada pemrosesan manual dan aplikasi pada sapi, sedangkan penelitian ini mengembangkan sistem yang lebih canggih dengan penggunaan CNN dan ViT, serta menambahkan IoT untuk

---

memonitor bobot itik secara langsung tanpa perlu pemeriksaan fisik, yang memudahkan pengambilan keputusan oleh peternak.

Sebagai perbandingan, penelitian Winardi & Setyati (2021) mengidentifikasi jenis daging menggunakan CNN, yang serupa dengan aplikasi CNN dalam penelitian ini untuk klasifikasi bobot itik. Namun, penelitian ini lebih berfokus pada jenis daging, sedangkan penelitian ini memanfaatkan klasifikasi berat itik yang lebih kompleks, dengan integrasi IoT untuk pemantauan hasil secara *real-time*.

Penelitian Justam et al. (2024) mengintegrasikan IoT dengan pengolahan citra untuk sistem pakan otomatis pada udang bioflok, yang mirip dengan penerapan IoT dalam penelitian ini. Namun, penelitian ini lebih terbatas pada pemantauan pakan, sedangkan penelitian ini lebih fokus pada klasifikasi bobot itik yang lebih mendalam.

Di sisi lain, penelitian Jaini et al. (2023) tentang estimasi bobot sapi menggunakan *deep learning* dan Ruchay et al. (2022) yang menggunakan *deep regression* untuk prediksi bobot sapi, menunjukkan bahwa meskipun teknologi *deep learning* telah digunakan dalam konteks sapi, penelitian ini memperkenalkan penggunaan ViT untuk klasifikasi berat itik pedaging yang lebih efisien dan diintegrasikan dengan IoT untuk pemantauan hasil secara *real-time*.

Dalam teori *deep learning*, CNN terbukti unggul dalam ekstraksi fitur spasial lokal, sedangkan ViT lebih efektif dalam menangkap hubungan global antar bagian citra. Oleh karena itu, ViT lebih unggul untuk klasifikasi citra kompleks seperti pada kasus ini, di mana bobot itik perlu dikategorikan dengan ketepatan tinggi. Secara praktis, teknologi ini memungkinkan peternak untuk memantau kondisi tubuh itik tanpa memerlukan pemeriksaan fisik langsung, yang mengurangi waktu dan biaya.

Meskipun hasil penelitian ini menunjukkan kemajuan signifikan, ada beberapa keterbatasan yang perlu diperhatikan:

- Dataset terbatas: Penelitian ini menggunakan dataset citra yang terbatas, terutama untuk kelas itik yang lebih kurus. Penelitian selanjutnya dapat memperluas dataset untuk meningkatkan generalisasi model.
- Akurasi *real-time*: Pengujian lebih lanjut diperlukan untuk mengoptimalkan database data yang lebih besar untuk dapat memantau jumlah peternakan yang lebih luas.
- Eksplorasi model lain: Selain CNN dan ViT, model lain dapat dieksplorasi untuk mencari hasil yang lebih baik.

Secara keseluruhan, penelitian ini memberikan kontribusi baru dalam mengintegrasikan CNN dan ViT dengan teknologi IoT untuk klasifikasi berat itik pedaging. Dengan pendekatan ini, sistem yang dikembangkan tidak hanya lebih akurat tetapi juga lebih efisien dalam aplikasinya, memberikan solusi otomatis yang dapat mempermudah peternak dalam pensortiran berat itik dan membuat keputusan yang lebih cepat serta tepat.

#### 4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi bobot itik pedaging berbasis Convolutional Neural Network (CNN) yang terintegrasi dengan teknologi *Internet of Things* (IoT), untuk memudahkan peternak dalam mengklasifikasikan bobot itik secara otomatis dan memantau hasilnya secara *real-time*.

Berdasarkan hasil pengujian, model Vision Transformer (ViT) menunjukkan kinerja yang lebih baik dibandingkan dengan CNN dalam hal akurasi dan presisi klasifikasi bobot itik. Model ViT menghasilkan akurasi sebesar 85,8%, sedikit lebih tinggi dibandingkan dengan 85,1% yang dicapai oleh model CNN. Selain itu, model ViT juga menunjukkan presisi dan *recall* yang lebih baik, yaitu 86,2% dan 85,5%, masing-masing, dibandingkan dengan model CNN yang hanya mencapai 84,3% dan 83,8%. Namun, model CNN menunjukkan waktu eksekusi yang lebih cepat, dengan rata-rata waktu 0,45 detik per citra, yang lebih efisien dibandingkan dengan model ViT, yang memerlukan 0,56 detik per citra. Kecepatan ini dapat menjadi keuntungan dalam aplikasi *real-time* di lapangan.

Integrasi sistem dengan IoT menggunakan ESP32 dan MQTT menunjukkan bahwa hasil klasifikasi dapat dipantau secara *real-time* oleh peternak melalui Adafruit IO, yang mempermudah pengambilan keputusan terkait manajemen bobot itik tanpa memerlukan pemeriksaan fisik secara langsung.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa penerapan teknologi *deep learning* (CNN dan ViT) bersama dengan IoT dapat meningkatkan efisiensi dan akurasi dalam manajemen peternakan itik, serta memberikan solusi yang lebih efisien dan otomatis bagi peternak dalam mengklasifikasikan berat itik pedaging.

## 5. UCAPAN TERIMA KASIH

Penghargaan khusus saya sampaikan kepada Fakultas Teknologi Industri, Program Studi MTE Universitas Ahmad Dahlan Yogyakarta yang telah menyediakan fasilitas laboratorium, peralatan, dan dukungan administratif sehingga penelitian ini dapat terlaksana dengan baik. Penelitian ini di danai oleh Direktorat Penelitian dan Pengabdian kepada Masyarakat (DPPM), dengan nomor kontrak: 020/PTM/LPPM.UAD/V/2025.

## DAFTAR PUSTAKA

- [1] P. Lieng and K. Sangpradit, "Study on duck weight estimation by using image processing," *E3S Web Conf.*, vol. 187, p. 02001, 2020, doi: 10.1051/e3sconf/202018702001.
- [2] V. Y. Mahendra, A. A. Riadi, and E. Evanita, "Aplikasi Pengolahan Citra Digital Menentukan Bobot Sapi Dengan Metode Titik Berat Berbasis Android," *Jurasik J. Ris. Sist. Inf. Dan Tek. Inform.*, vol. 7, no. 1, p. 88, Feb. 2022, doi: 10.30645/jurasik.v7i1.419.
- [3] M. Campbell *et al.*, "Automated precision weighing: Leveraging 2D video feature analysis and machine learning for live body weight estimation of broiler chickens," *Smart Agric. Technol.*, vol. 10, p. 100793, Mar. 2025, doi: 10.1016/j.atech.2025.100793.
- [4] P. Winardi and E. Setyati, "Identifikasi Jenis Daging dengan Menggunakan Algoritma Convolution Neural Network," *J. Inf. Syst. Hosp. Technol.*, vol. 3, no. 02, pp. 82–88, Dec. 2021, doi: 10.37823/insight.v3i02.178.
- [5] J. Justam, M. Hasanuddin, H. Mubarak, R. Rahmah, and T. Nurjanah, "IoT dan Pengolahan Citra untuk Sistem Pakan Otomatis Udang dalam Kolam Bioflok," *J. Ilm. Sist. Inf. Dan Tek. Inform. JISTI*, vol. 7, no. 2, pp. 351–362, Oct. 2024, doi: 10.57093/jisti.v7i2.272.
- [6] Abdul Aziz, Abdul Fadlil, and Tole Sutikno, "Optimization of Convolutional Neural Network (CNN) Using Transfer Learning for Disease Identification in Rice Leaf Images," *J. E-Komtek Elektro-Komput.-Tek.*, vol. 8, no. 2, pp. 504–515, Dec. 2024, doi: 10.37339/e-komtek.v8i2.2132.
- [7] S. B. Sulistyio *et al.*, "Analisis Regresi Untuk Evaluasi Mutu Jeruk Selama Penyimpanan Berdasarkan Fitur Citra Digital," *Rona Tek. Pertan.*, vol. 13, no. 1, pp. 56–66, Apr. 2020, doi: 10.17969/rtp.v13i1.15172.
- [8] A. Azis, A. Fadlil, and T. Sutikno, "Real-time Rice Leaf Disease Diagnosis: A Mobile CNN Application with Firebase Integration," *J. Tek. Inform. Jutif*, vol. 6, no. 3, pp. 1469–1484, June 2025, doi: 10.52436/1.jutif.2025.6.3.4452.
- [9] R. Mahdaliza and B. Sugandi, "Prediksi Berat dan Harga Buah Menggunakan Sensor Visual," *J. INTEGRASI*, vol. 13, no. 1, pp. 10–14, Apr. 2021, doi: 10.30871/ji.v13i1.2916.
- [10] H. Fitriyah, "Pengukuran Panjang-Berat Ikan dan Sayuran secara Otomatis pada Budikdamber (Budi Daya Ikan dalam Ember) Menggunakan Visi Komputer dan Regresi Linier," 2020.
- [11] A. Ruchay, V. Kober, K. Dorofeev, V. Kolpakov, A. Gladkov, and H. Guo, "Live Weight Prediction of Cattle Based on Deep Regression of RGB-D Images," *Agriculture*, vol. 12, no. 11, p. 1794, Oct. 2022, doi: 10.3390/agriculture12111794.
- [12] D. A. Supriyatna, M. Si, and I. Taufik, "IDENTIFIKASI JENIS TUMBUHAN DI LINGKUNGAN UIN SUNAN GUNUNG DJATI BANDUNG BERDASARKAN CITRA DAUN MENGGUNAKAN CNN".
- [13] N. T. Duc *et al.*, "Image-based phenotyping of seed architectural traits and prediction of seed weight using machine learning models in soybean," *Front. Plant Sci.*, vol. 14, p. 1206357, Sept. 2023, doi: 10.3389/fpls.2023.1206357.
- [14] E. N. Cahyo, E. Susanti, and R. Y. Ariyana, "Model Machine Learning Untuk Klasifikasi Kesegaran Daging Menggunakan Arsitektur Transfer Learning Xception," *J. Sist. Dan Teknol. Inf. JustIN*, vol. 11, no. 2, p. 371, July 2023, doi: 10.26418/justin.v11i2.57517.
- [15] I. Supiyani, J. Haerul, and T. N. Padilah, "PENGOLAHAN CITRA DIGITAL PREDIKSI BOBOT SAPI MENGGUNAKAN EKSTRAKSI FITUR CANNY DAN KLASIFIKASI K-NEAREST NEIGHBOR," 2021.

