

Image-Based Classification of Healthy and Unhealthy Goats Using ResNet-18 Deep Learning Model

Nurrochim Amin Putra ^{1*}, Ajie Kusuma Wardhana ^{2*}

* Informatika, Universitas Amikom Yogyakarta

nurrochimap@students.amikom.ac.id ¹, ajiekusuma@amikom.ac.id ²

Article Info

Article history:

Received 2025-07-16

Revised 2025-09-19

Accepted 2025-09-28

Keyword:

*Deep Learning,
Healthy and Unhealthy Goats,
Image Classification,
CNN ResNet-18,
Model Evaluation.*

ABSTRACT

Early detection of livestock health conditions is a critical factor in maintaining animal productivity and welfare. This study aims to develop an image-based classification system for identifying healthy and unhealthy goats using deep learning techniques. The dataset of goat images was obtained from Roboflow and processed through a series of augmentation, normalization, and feature extraction stages using the ResNet-18 convolutional neural network architecture pretrained on ImageNet. The dataset was divided into training and testing sets with a 70:30 stratified split to ensure balanced class distribution. To address class imbalance, a random undersampling technique was applied. The model was trained using optimally tuned hyperparameters, including the Adam optimizer, cross-entropy loss function, a batch size of 32, and 20 epochs. Evaluation results showed that the model achieved an accuracy of 95.97%, with a precision of 96.22%, recall of 95.97%, and F1-score of 95.92%. The confusion matrix and evaluation curves demonstrated that the model is both stable and reliable. These findings indicate that the proposed system has strong potential to be implemented in automated and real-time livestock health monitoring applications, providing a fast, accurate, and non-invasive solution for precision livestock farming.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Perkembangan *deep learning*, khususnya Convolutional Neural Networks (CNN), telah memberikan kemajuan signifikan dalam klasifikasi citra, termasuk pada pemantauan dan diagnosis kesehatan hewan ternak. Model populer seperti ResNet dan EfficientNet banyak digunakan pada bidang *computer vision* untuk mendeteksi perilaku, posisi, dan kondisi fisik hewan secara otomatis [1], [2]. Sistem berbasis citra dinilai lebih efisien dibandingkan pemeriksaan fisik konvensional yang bersifat invasif dan memakan waktu, seperti pengukuran suhu tubuh atau observasi manual. Analisis citra memungkinkan pemantauan serentak terhadap banyak individu, bersifat hemat biaya, serta dapat diintegrasikan dengan sistem kamera sederhana di lingkungan peternakan [3]. Pendekatan ini juga mendukung pemantauan waktu nyata (*real-time monitoring*) serta mengurangi bias subjektif yang sering muncul pada metode tradisional [4].

Meskipun penerapan CNN pada kasus klasifikasi penyakit sapi dan babi telah banyak diteliti [5], [6], penelitian serupa pada kambing masih terbatas [7]. Sebagian besar studi berfokus pada perilaku atau pendeteksian jumlah individu melalui metode seperti YOLO atau *head counting* [8]. Hingga kini, belum banyak kajian yang secara spesifik memanfaatkan CNN untuk klasifikasi kondisi kesehatan kambing. Tantangan utama yang dihadapi adalah keterbatasan dataset publik dengan label kesehatan yang jelas serta tingginya variabilitas citra kambing, baik dari segi warna bulu, postur tubuh, maupun pencahayaan [9].

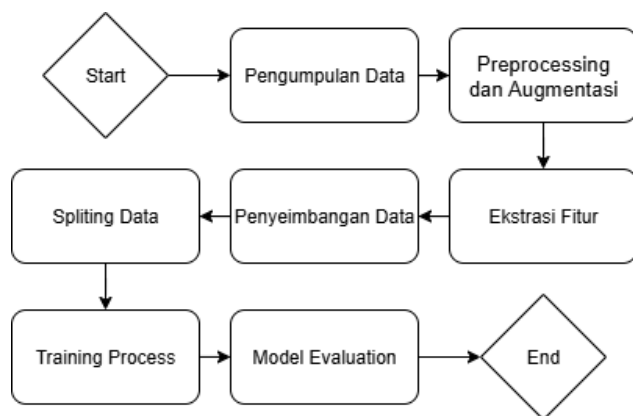
Penelitian ini mengembangkan model CNN berbasis arsitektur ResNet-18 yang dimodifikasi untuk klasifikasi biner, yaitu membedakan kambing sehat dan tidak sehat. Hasil eksperimen menunjukkan performa yang tinggi, dengan akurasi validasi sebesar 95,97%, precision sekitar 96%, recall 96,64%, serta F1-score 96,61%. Capaian ini lebih baik dibandingkan penelitian sebelumnya yang menggunakan VGG16 maupun metode lama dengan akurasi masing-masing

sebesar 91,5% dan 90,1% [10], [11]. Namun demikian, sebagian besar penelitian, masih terbatas pada ukuran dataset yang kecil dan belum menguji ketahanan model terhadap variasi latar belakang, pencahayaan, maupun orientasi tubuh. Penelitian yang mengimplementasikan validasi atau pengujian dengan *external dataset* sehingga potensi *overfitting* pada model masih terus menjadi perhatian. Hal ini menjadi tantangan meskipun nilai evaluasi numerik tinggi, tetapi menjaga hasil generalisasi model atau menjaga model tetap mengenali pola diluar data latih [12].

Dengan mempertimbangkan hal tersebut, penelitian ini menggunakan dataset terbuka (*open source*) yang diolah melalui teknik augmentasi untuk meningkatkan kemampuan generalisasi model. Proses pelatihan dilakukan dengan validasi silang (*cross-validation*) dan evaluasi menggunakan metrik akurasi, precision, recall, serta F1-score. Tujuan penelitian ini Adalah untuk mengembangkan model CNN ResNet-18 untuk klasifikasi penyakit yang lebih akurat dan memiliki generalisasi model yang baik.

II. METODE

Penelitian ini menggunakan citra kambing sebagai data utama untuk klasifikasi kondisi kesehatan, yaitu membedakan antara kambing sehat dan tidak sehat. Dataset diperoleh dari platform RoboFlow dengan resolusi gambar yang kemudian diubah menjadi 224×224 piksel. Untuk meningkatkan variasi data serta kemampuan generalisasi model, dilakukan proses augmentasi berupa horizontal flip, rotasi acak, dan random crop. Teknik augmentasi ini juga digunakan untuk menyeimbangkan distribusi kelas ketika terdapat ketimpangan jumlah data.



Gambar 1 Research Flow

Model yang digunakan adalah ResNet-18 berbasis *transfer learning*, di mana bobot awal berasal dari model yang telah dilatih pada dataset ImageNet. Bagian akhir (*output layer*) dimodifikasi agar sesuai dengan tugas klasifikasi biner. Proses pelatihan dilakukan dengan konfigurasi optimizer Adam, loss function CrossEntropy, batch size 32, dan 20 epoch. Untuk meminimalkan risiko *overfitting*, proses pelatihan dilengkapi dengan validasi silang (*cross-*

validation), serta model terbaik disimpan berdasarkan capaian akurasi validasi tertinggi.

Data dibagi menjadi dua subset, yaitu 70% untuk pelatihan dan 30% untuk validasi. Evaluasi kinerja model dilakukan dengan beberapa metrik, yaitu akurasi, precision, recall, F1-score, serta analisis confusion matrix. Metrik-metrik tersebut digunakan untuk memberikan gambaran menyeluruh mengenai kemampuan model dalam membedakan kondisi kambing sehat dan tidak sehat. Alur lengkap penelitian ditunjukkan pada Gambar 1.

A. Pengumpulan Dataset

Proses pengumpulan dataset diawali dengan menggabungkan data citra kambing dari dua sumber, yaitu RoboFlow dan Mendeley. Seluruh data yang terkumpul kemudian diproses dan dijalankan melalui platform RoboFlow untuk standarisasi format, anotasi, serta penyesuaian resolusi citra. Dari hasil pengolahan tersebut, dipilih dataset akhir yang telah disusun oleh RoboFlow dengan nama Goat Dataset [13].

Dataset ini berisi kumpulan gambar kambing dalam berbagai kondisi visual, seperti postur tubuh abnormal, luka pada kulit, maupun kebersihan bulu, sehingga merepresentasikan variasi kesehatan kambing di lapangan. Dataset disusun dalam struktur folder yang sesuai dengan format ImageFolder pada PyTorch, sehingga anotasi label dapat dilakukan secara otomatis berdasarkan nama folder masing-masing kelas. Informasi detail mengenai jumlah data pada setiap kelas ditampilkan pada Tabel 1.

TABEL I
KELAS DATASET

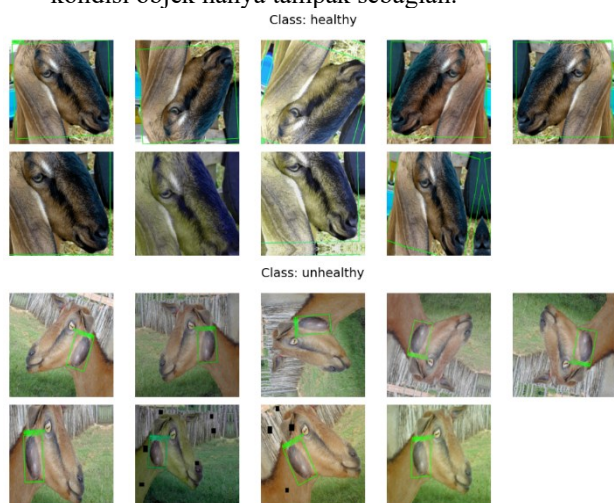
No	Class	Size
1	Healthy Goat	214
2	Unhealthy Goat	132

B. Preprocessing dan Augmentasi Gambar

Citra yang diperoleh memiliki dimensi dan kualitas berbeda. Seluruh gambar diubah ukurannya menjadi 224×224 piksel, disesuaikan dengan input standar dari model ResNet-18. Proses proses dilakukan untuk memperkaya variasi data dan mencegah *overfitting* menggunakan transformasi sebagai berikut :

- Horizontal & Vertical Flip: membalik citra secara horizontal maupun vertikal untuk meniru posisi objek yang bervariasi di lapangan.
- Random Rotate 90° & Rotate: memutar citra hingga 20° atau kelipatan 90° untuk menyesuaikan dengan variasi orientasi objek.
- Brightness & Contrast Adjustment: menyesuaikan tingkat kecerahan dan kontras sehingga model tahan terhadap perubahan pencahayaan.
- Hue, Saturation, Value Adjustment: menambahkan variasi warna agar model tidak hanya menghafal distribusi warna spesifik.

- Blur dan Gaussian Noise: menambahkan gangguan sederhana untuk meningkatkan ketahanan model terhadap citra buram atau noise.
- Random Resized Crop: melakukan pemotongan acak dengan skala 85–100% untuk memperkuat model dalam mendeteksi objek dengan ukuran berbeda.
- Shift, Scale, Rotate, Elastic Transform, Grid Distortion: menghasilkan variasi geometrik ekstrem yang meniru distorsi kamera atau perbedaan sudut pandang.
- Brightness, Contrast, Hue-Saturation, CLAHE, RGB Shift: memperluas distribusi warna dan pencahayaan agar model mampu belajar dari kondisi pengambilan gambar yang ekstrem, termasuk bayangan atau overexposure.
- Motion Blur, Median Blur, Gaussian Noise, ISO Noise: menambahkan gangguan kualitas gambar seperti blur akibat gerakan atau noise sensor kamera.
- Coarse Dropout (Occlusion): menutupi sebagian area citra untuk melatih model mengenali objek meskipun sebagian fitur penting tidak terlihat.
- Random Resized Crop dengan skala rendah (70–100%): membuat variasi ukuran objek lebih ekstrem, termasuk kondisi objek hanya tampak sebagian.



Gambar 2 Hasil Preprocessing dan Augmentasi

Gambar 2 menampilkan contoh hasil augmentasi data pada dua kelas, yaitu *unhealthy* dan *healthy*. Pada kelas *unhealthy*, terlihat kambing dengan kondisi tidak sehat seperti adanya pembengkakan pada wajah atau kelainan pada kulit. Sedangkan pada kelas *healthy*, ditampilkan kambing dengan kondisi normal tanpa tanda-tanda penyakit. Setiap gambar ditandai dengan *bounding box* berwarna hijau yang berfungsi untuk menyoroti area penting pada wajah kambing. Proses augmentasi yang diterapkan mencakup rotasi, flipping, penyesuaian pencahayaan, perubahan warna, penambahan *noise*, hingga *cropping*. Variasi ini bertujuan untuk memperkaya dataset, mengurangi risiko *overfitting*, serta meningkatkan kemampuan model dalam mengenali kondisi

kambing pada situasi nyata dengan pencahayaan, sudut pandang, maupun kualitas gambar yang bervariasi.

C. Ekstraksi Fitur

Ekstraksi fitur pada penelitian ini dilakukan menggunakan model ResNet-18 yang telah dilatih sebelumnya (*pre-trained*) pada dataset ImageNet. Model ini dimanfaatkan sebagai feature extractor, di mana lapisan awal digunakan untuk menangkap pola visual dasar, sedangkan lapisan lebih dalam mempelajari representasi kompleks dari citra kambing.

Lapisan akhir (*fully connected layer*) dimodifikasi agar menghasilkan keluaran dua kelas, yaitu sehat dan tidak sehat. Selama proses ekstraksi, fitur-fitur penting dari citra, seperti tekstur bulu, bentuk tubuh, serta karakteristik visual lainnya, dikonversi menjadi vektor numerik berdimensi tetap. Vektor inilah yang menjadi representasi numerik dari setiap gambar dan digunakan pada tahap klasifikasi [14].

D. Penyeimbangan Data

Dalam permasalahan klasifikasi citra, ketidakseimbangan jumlah data antar kelas (*class imbalance*) dapat menyebabkan model lebih akurat dalam mengenali kelas mayoritas dan mengabaikan kelas minoritas. Kondisi ini berdampak pada rendahnya nilai metrik seperti recall dan F1-score pada kelas minoritas [1].

Dataset yang digunakan dalam penelitian ini terdiri atas dua kelas, yaitu kambing sehat dan kambing tidak sehat, dengan distribusi jumlah gambar yang tidak seimbang. Untuk mengatasi hal ini, digunakan pendekatan data augmentation pada kelas minoritas.

Teknik augmentasi dilakukan dengan operasi seperti horizontal flip, rotasi acak, perubahan brightness/contrast, serta random crop. Dengan cara ini, jumlah citra pada kelas minoritas dapat ditingkatkan sehingga distribusi kedua kelas menjadi lebih seimbang.

$$IR = \frac{N_{mayoritas}}{N_{minoritas}}$$

Keterangan :

$N_{mayoritas}$ = jumlah sampel pada kelas mayoritas.

$N_{minoritas}$ = jumlah sampel pada kelas minoritas.

E. Normalisasi Data

Fitur hasil ekstraksi dinormalisasi menggunakan teknik *standard scaling*. Pada metode ini, setiap fitur x diubah berdasarkan rata-rata μ dan standar deviasi σ sebagai berikut:

$$x' = \frac{x - \mu}{\sigma}$$

Transformasi ini menghasilkan distribusi fitur dengan rata-rata nol dan standar deviasi satu. Proses normalisasi membantu dalam menjaga kestabilan distribusi data,

mempercepat konvergensi model saat pelatihan, serta meningkatkan performa algoritma optimisasi.

F. Split Data: Training dan Testing

Setelah semua data citra kambing selesai diproses, langkah selanjutnya adalah membagi dataset menjadi dua bagian utama, yaitu data pelatihan dan data pengujian. Sebanyak 70% dari total data digunakan untuk melatih model, sementara 30% sisanya digunakan untuk menguji performa model setelah pelatihan selesai [15]. Proses pembagian ini dilakukan secara acak, namun tetap menjaga proporsi jumlah data dari masing-masing kelas agar tetap seimbang. Hal ini bertujuan agar model tidak hanya belajar dari satu kelas saja, serta mampu melakukan prediksi dengan baik pada data baru yang belum pernah dilihat sebelumnya. Dengan demikian, proses ini membantu dalam mengukur kemampuan generalisasi dari model yang dikembangkan.

G. Pelatihan Model CNN

Model yang digunakan dalam penelitian ini adalah ResNet-18, salah satu arsitektur *Convolutional Neural Network* (CNN) yang telah banyak digunakan karena kestabilan dan efisiensinya dalam klasifikasi citra. Pelatihan dilakukan untuk menyesuaikan bobot model dengan data kambing yang tersedia, agar model dapat membedakan antara kambing sehat dan tidak sehat secara akurat. Untuk mengukur kesalahan atau jarak antara prediksi model dan label sebenarnya, digunakan fungsi loss Cross Entropy Loss, yang dirumuskan sebagai berikut:

$$L(x, y) = - \sum_{i=1}^C y_i \log(\hat{y}_i)$$

Keterangan :

C = Jumlah kelas (dalam kasus ini, 2).

y_i = Label sebenarnya (1 untuk kelas benar, 0 untuk lainnya).

\hat{y}_i = Probabilitas prediksi model terhadap kelas ke-i (hasil dari softmax).

Untuk memperbarui bobot jaringan selama proses pelatihan, digunakan optimizer Adam (*Adaptive Moment Estimation*), yang merupakan kombinasi antara RMSProp dan momentum. Rumus pembaruan bobot pada Adam secara umum diberikan oleh:

$$\theta_{i+1} = \theta_t - \alpha \cdot \frac{\hat{m}_t}{\sqrt{\hat{u}_t + \epsilon}}$$

Keterangan :

$C\theta$ = Bobot model.

α = *Learning rate* (dalam penelitian ini 1×10^{-4}).

\hat{m}_t dan \hat{u}_t = Estimasi momentum dan skala gradien.

ϵ = Konstanta kecil untuk mencegah pembagian oleh nol.

Proses pelatihan dilakukan selama 20 epoch, dengan ukuran batch sebanyak 149 gambar per iterasi. Pada setiap epoch, model melakukan forward pass, menghitung loss, melakukan backpropagation, lalu memperbarui bobot. Model terbaik disimpan secara otomatis saat mencapai akurasi validasi tertinggi, yang menunjukkan performa optimal pada data yang belum pernah dilihat. Selama pelatihan, nilai loss dan accuracy dicatat setiap epoch sebagai indikator evaluasi dan pemantauan overfitting.

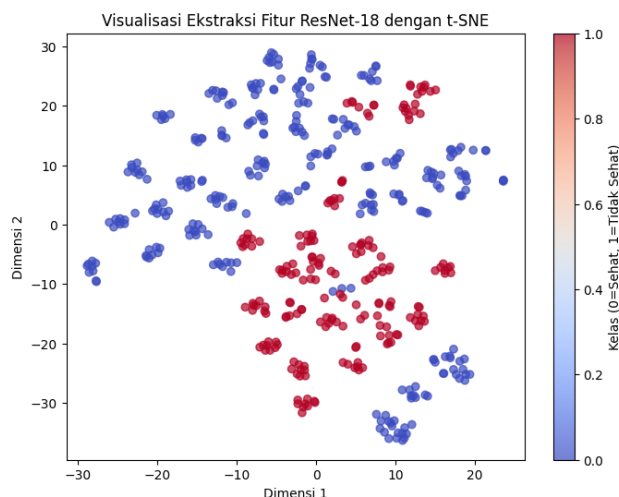
H. Normalisasi Vektor Fitur

Setelah model selesai dilatih, dilakukan evaluasi untuk mengetahui seberapa baik kinerjanya dalam mengklasifikasikan gambar kambing sehat dan tidak sehat. Evaluasi ini menggunakan beberapa metrik utama, yaitu accuracy yang mengukur proporsi prediksi yang benar dari seluruh data, serta precision dan recall yang menggambarkan ketepatan dan kelengkapan model dalam mengenali kelas tertentu. Untuk menggabungkan kedua metrik tersebut secara seimbang, digunakan juga F1-score yang merupakan rata-rata harmonik dari precision dan recall. Selain metrik angka, digunakan juga confusion matrix sebagai alat visualisasi untuk menunjukkan hasil prediksi benar dan salah pada masing-masing kelas. Hasil evaluasi ini memberikan gambaran menyeluruh mengenai kelebihan dan kekurangan model serta menjadi dasar dalam menilai apakah performa klasifikasi ini layak digunakan pada aplikasi nyata.

III. HASIL DAN PEMBAHASAN

A. Ekstraksi Fitur


Tahap pertama dari proses klasifikasi adalah melakukan ekstraksi fitur terhadap seluruh gambar kambing yang telah diproses dan dinormalisasi. Proses ini menggunakan arsitektur ResNet-18 yang telah dilatih sebelumnya (pre-trained) pada dataset ImageNet. Setiap gambar diubah menjadi vektor fitur berdimensi tetap yang mencerminkan karakteristik visual penting seperti tekstur bulu, bentuk tubuh, dan tanda-tanda gejala penyakit yang dapat diamati. Vektor numerik ini digunakan untuk pelatihan dan evaluasi model klasifikasi selanjutnya. Hasil visualisasi proyeksi 2D dari fitur yang diekstrak ditunjukkan pada Gambar 3.



Gambar 3 Visualisasi Ekstraksi Fitur dari Citra Kambing

B. Penyeimbangan Data

Analisis awal terhadap distribusi jumlah data citra menunjukkan adanya ketidakseimbangan antar kelas, sebagaimana ditampilkan pada Gambar 4. Kelas *unhealthy_goat* memiliki jumlah gambar lebih tinggi dibandingkan *healthy_goat*, yaitu sekitar 214 berbanding 132. Kondisi ini berisiko menimbulkan bias klasifikasi, dimana model cenderung mengenali pola dari kelas yang lebih dominan, sehingga menurunkan sensitivitas terhadap kelas minoritas. Untuk menjaga kualitas generalisasi model, dilakukan pembagian data latih dan data uji menggunakan teknik *stratified splitting* dengan rasio 70:30. Metode ini memastikan bahwa proporsi masing-masing kelas tetap terjaga dalam subset pelatihan dan pengujian. Dengan demikian, distribusi data pada set pelatihan dan set pengujian tetap proporsional terhadap distribusi awal, sehingga proses evaluasi menjadi lebih objektif dan adil.



Gambar 4 Sebelum dan Sesudah Penyeimbangan Data


C. Proses Pelatihan Model

Dalam tahap pelatihan model, digunakan arsitektur ResNet-18 yang dioptimalkan melalui konfigurasi hyperparameter seperti *learning rate* sebesar 0.0001, *optimizer* Adam, dan *loss function* *CrossEntropyLoss*. Pemilihan hyperparameter seperti learning rate 0.0001 dan optimizer Adam merujuk pada praktik yang telah terbukti efektif pada model pretrained seperti yang dijelaskan pada [16]. Selain itu, penggunaan struktur model yang stabil juga sejalan dengan pendekatan modern berbasis transformer pada penelitian [17].

Penggunaan *CrossEntropyLoss* sangat umum untuk tugas klasifikasi multi-kelas karena secara matematis mampu mengukur jarak antara distribusi prediksi dan label sebenarnya secara sensitif. Sementara itu, Adam optimizer dipilih karena kemampuannya yang adaptif dalam mengatur pembaruan bobot berdasarkan rata-rata momentum dan variansi gradien, yang mempercepat konvergensi dan mencegah jebakan local minima, terutama pada arsitektur deep CNN seperti ResNet.

Nilai learning rate sebesar 0.0001 digunakan untuk memberikan proses pembelajaran yang stabil cukup kecil untuk menghindari lonjakan besar dalam fungsi loss, namun cukup besar agar proses training tidak terlalu lambat. Dalam literatur, nilai ini sering direkomendasikan untuk model yang menggunakan bobot pralatih (*pre-trained*), di mana pelatihan lebih difokuskan pada fine-tuning. Pemilihan batch size 32 merupakan kompromi ideal antara efisiensi komputasi dan kestabilan gradien selama backpropagation. Ukuran batch ini juga cukup besar untuk memanfaatkan efisiensi GPU, namun tetap kecil agar tidak membebani memori.

Jumlah epoch sebanyak 20 dipilih berdasarkan hasil pelatihan yang menunjukkan bahwa model mencapai akurasi tinggi dan loss yang rendah pada data latih dalam rentang epoch tersebut. Grafik pelatihan menunjukkan penurunan loss dan peningkatan akurasi pada data latih. Meskipun terdapat fluktuasi pada data validasi, kinerja model pada pengenalan pola pada data latih yang diproses melalui undersampling menunjukkan performa yang baik.



Gambar 5 Grafik Akurasi dan Loss Selama Pelatihan

D. Evaluasi dan Analisis Kinerja Model

Evaluasi model dalam penelitian ini dilakukan untuk menilai seberapa baik performa klasifikasi dapat membedakan kambing sehat dan tidak sehat berdasarkan

citra. Proses evaluasi dilakukan menggunakan data uji sebesar 30% dari total dataset, yang sebelumnya tidak dilibatkan dalam proses pelatihan. Hal ini bertujuan untuk mengukur kemampuan generalisasi model terhadap data baru.


Model dievaluasi menggunakan lima metrik utama yaitu accuracy, precision, recall, F1-score, dan confusion matrix. Pada Gambar 5 performa model tidak memiliki indikasi terhadap keadaan overfitting atau underfitting. Hal ini dibuktikan dengan jarak performa latih dan testing tidak terlalu jauh. Kemudian, hasil evaluasi dirangkum pada Tabel 3 berikut:

TABEL 3
EVALUASI MODEL

Metrik	Diskripsi Singkat	Nilai (%)
Accuracy	Proporsi keseluruhan prediksi yang benar dari semua data uji	95.97
Precision	Proporsi prediksi kambing sakit yang benar dari seluruh prediksi sakit	96.22
Recall	Proporsi kambing sakit yang berhasil dikenali dengan benar oleh model	95.97
F1-Score	Rata-rata harmonik antara precision dan recall	95.92

Nilai-nilai metrik tersebut menunjukkan bahwa model memiliki performa yang sangat baik dan seimbang dalam mengenali kedua kelas, yaitu kambing sehat dan sakit. Akurasi tinggi menandakan ketepatan model secara keseluruhan, sementara recall dan precision yang tinggi menunjukkan sensitivitas dan ketelitian model dalam mengenali kambing yang benar-benar sakit aspek yang sangat krusial dalam konteks peternakan dan kesehatan hewan.

Confusion matrix pada Gambar 7 memberikan informasi granular mengenai jumlah klasifikasi benar dan salah antar kelas dari 149 data uji.



Gambar 6 Confusion Matrix Hasil Klasifikasi Kambing Sehat dan Sakit

Berdasarkan hasil evaluasi menggunakan confusion matrix Gambar 6, model menunjukkan performa klasifikasi yang sangat baik terhadap kedua kelas. Sebagian besar data uji berhasil diklasifikasikan dengan benar, meskipun masih terdapat sedikit kesalahan prediksi. Hal ini menunjukkan bahwa model ResNet-18 mampu mengenali pola visual penting pada citra kambing sehat maupun tidak sehat.

Nilai *loss* validasi akhir tercatat sebesar 0.1443, dengan akurasi mencapai 94.95%. Tingginya akurasi ini menegaskan bahwa model tidak mengalami bias dominan terhadap salah satu kelas, melainkan dapat membedakan dengan baik kondisi kambing sehat dan sakit. Hasil evaluasi ini sekaligus memperlihatkan bahwa penggunaan *stratified splitting* dalam pembagian dataset berhasil menjaga distribusi kelas, sehingga model dapat melakukan generalisasi dengan lebih adil pada data uji.

E. Perbandingan dengan Studi Sebelumnya

Untuk memastikan efektivitas pendekatan yang digunakan, model ini dibandingkan dengan penelitian lain yang relevan. Tabel berikut menyajikan perbandingan dalam hal dataset, metode, balancing data, dan akurasi.

TABEL 4
HASIL PERBANDINGAN PENELITIAN

Peneliti	Dataset	Ekstraksi Fitur	Balancing	Akurasi (%)
Studi ini		ResNet-18(CNN Pretrained)	Random Undersampling	95.97
[11]	Citra Kambing Lokal	Ekstraksi Manual	Tidak Dilakukan	90.1
[10]	Kambing Jawa & PE	VGG16	SMOTE	91.5

Hasil yang sudah dilakukan menampilkan bahwa metode CNN menggunakan ekstraksi fitur ResNet-18 dan preprocessing yang digunakan pada penelitian ini lebih unggul dibandingkan dengan metode yang digunakan pada penelitian lain dengan model deep learning yang serupa. Dengan metode balancing menggunakan Undersampling hasil membuktikan akurasi menjadi lebih bagus dibandingkan tidak dilakukannya balancing.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi kesehatan kambing berbasis citra menggunakan algoritma deep learning, khususnya arsitektur ResNet-18 pretrained pada ImageNet. Model dibangun melalui tahapan sistematis, mulai dari preprocessing, augmentasi data, ekstraksi fitur, hingga penyeimbangan data dengan teknik undersampling untuk mengatasi ketidakseimbangan kelas. Evaluasi model dilakukan secara menyeluruh menggunakan metrik performa dan visualisasi hasil prediksi.

Hasil pengujian menunjukkan bahwa model mampu membedakan kambing sehat dan tidak sehat secara otomatis dengan tingkat akurasi 95.97%, precision 96.22%, recall 95.97%, dan F1-score 95.92%. Evaluasi menggunakan confusion matrix memperlihatkan distribusi prediksi yang proporsional, dengan jumlah kesalahan klasifikasi yang sangat minimal. Selain itu, pola akurasi dan loss selama proses pelatihan menunjukkan konvergensi yang stabil tanpa indikasi overfitting, menandakan bahwa konfigurasi hyperparameter yang digunakan telah optimal.

Dibandingkan dengan pendekatan terdahulu, strategi ini terbukti lebih efisien dan akurat karena menggabungkan arsitektur CNN modern, augmentasi data, serta teknik penyeimbangan data berbasis undersampling. Hal ini berkontribusi besar terhadap peningkatan kemampuan generalisasi model sekaligus menjaga efisiensi komputasi.

Secara keseluruhan, model yang dikembangkan memiliki potensi tinggi untuk diimplementasikan dalam peternakan presisi, khususnya sistem monitoring kesehatan kambing secara otomatis melalui kamera atau aplikasi mobile. Pendekatan visual ini memungkinkan pemantauan kesehatan ternak dengan cepat, akurat, efisien, dan tanpa kontak langsung, sehingga relevan dalam mendukung transformasi digital sektor peternakan. Penelitian ini juga membuka peluang pengembangan lebih lanjut untuk sistem diagnosis penyakit hewan secara real-time dan berkelanjutan berbasis kecerdasan buatan (AI).

DAFTAR PUSTAKA

- [1] A. Rohan, M. S. Rafiq, M. J. Hasan, F. Asghar, A. K. Bashir, and T. Dottorini, "Application of deep learning for livestock behaviour recognition: A systematic literature review," *Comput Electron Agric*, vol. 224, pp. 1–24, 2024, doi: 10.1016/j.compag.2024.109115.
- [2] S. D. Scott et al., "Systematic Literature Review of Vision-Based Approaches to Outdoor Livestock Monitoring with Lessons from Wildlife Wildlife Studies," 2024, [Online]. Available: <http://www.mendeley.com>
- [3] and A. S. R. Mehta, S. Agrawal, "Deep Learning-Based Animal Health Monitoring: A Survey of Techniques and Applications," *IEEE Access*, vol. 10, pp. 132456–132471, 2022, doi: <https://doi.org/10.1109/ACCESS.2022.3220534>.
- [4] and X. C. Z. Chen, Y. Lin, "Lightweight CNN Models for Livestock Disease Detection in Real-time Applications," *Comput Electron Agric*, vol. 208, p. 107748, Apr. 2023, [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0168169923001369>
- [5] B. L. S. and V. A. M. R. Lamani, K. Padmaja, "Enhanced Lumpy Cattle Skin Disease Prognosis via Deep Learning Methods," 2024 Second International Conference on Networks, Multimedia and Information Technology (NMITCON), Bengaluru, India, pp. 1–6, 2024, doi: <https://doi.org/10.1109/NMITCON62075.2024.10699233>.
- [6] N. Reza, S. Kabir, A. Haque, and H. Jin, "Instance segmentation and automated pig posture recognition for smart health management," vol. 67, no. 3, pp. 677–700, 2025.
- [7] et al. X. Wang, W. Peng, Z. Chen, "GSCW-YOLO: A Real-Time Lightweight Behavior Recognition Model for Multiple Dairy Goats," *Animals*, vol. 14, no. 24, p. 3667, 2024, [Online]. Available: <https://www.mdpi.com/2076-2615/14/24/3667>
- [8] et al. Y. Zhang, Y. Fu, B. Song, "An Integrated Goat Head Detection and Automatic Counting Method Based on Deep Learning," *Animals*, vol. 12, no. 14, p. 1810, 2022, [Online]. Available: <https://www.mdpi.com/2076-2615/12/14/1810>
- [9] and B. J. R. S. Thakur, M. R. Rahman, "Convolutional Neural Network for Disease Detection in Small Ruminants: A Comparative Study," *Procedia Comput Sci*, vol. 219, pp. 447–454, 2023.
- [10] and G. A. A.-R. F. B. Mahama, A. Alhassan, "Goat Disease Classification Using VGG16 Deep Learning Model," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 32, no. 1, pp. 100–108, 2024.
- [11] R. Y. Kusuma and L. M. Hidayat, "Klasifikasi Penyakit Kambing Berdasarkan Citra Kulit Menggunakan Ekstraksi Warna dan K-Nearest Neighbor," *Jurnal Teknologi Informasi*, vol. 10, no. 2, pp. 115–122, 2023.
- [12] and D. J. A. Gebremariam, F. Zewdu, "Classification of Goat Skin Diseases Using CNN Models: A Case Study in East Africa," *Heliyon*, vol. 9, no. 4, 2023.
- [13] "Goat", [Online]. Available: <https://app.roboflow.com/goat-dataset-zahyx/goat-q1lcu/models>
- [14] and J. W. F. Li, Y. Wang, "Lightweight Residual CNNs for Efficient Animal Disease Detection in Low-Resource Environments," *Neurocomputing*, vol. 460, pp. 336–348, Oct. 2021, doi: 10.1016/j.neucom.2021.06.011.
- [15] A. A.-A. et Al., "Data-driven livestock classification using deep CNNs with augmented goat face images," *Biosyst Eng*, vol. 217, pp. 171–183, Jun. 2022, doi: 10.1016/j.biosystemseng.2022.03.010.
- [16] S. Howard, J., & Gugger, "Fastai: A layered API for deep learning," *IEEE Access*, vol. 9, pp. 102153–102163, 2021, doi: <https://doi.org/10.1109/ACCESS.2021.3059362>.
- [17] et al. Dosovitskiy, A., Beyer, L., Kolesnikov, A., "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," *ICLR*, 2021, doi: <https://doi.org/10.48550/arXiv.2010.11929>.