

KLASIFIKASI PENYAKIT AYAM BERDASARKAN CITRA KOTORAN MENGGUNAKAN CNN DENGAN XCEPTION

Shela Atya Mitasya¹, Ary Prabowo², Vitri Tundjungsari³

^{1,2,3} Teknik Informatika, Ilmu Komputer, Universitas Esa Unggul, Indonesia

¹shelaam03@gmail.com, ²ary.prabowo@esaunggul.ac.id, ³vitri.tundjungsari@esaunggul.ac.id

Abstrak

Peternakan ayam di Indonesia menghadirkan potensi ekonomi yang substansial karena tingginya permintaan daging dan telur. Namun, peternakan ini juga menghadapi risiko signifikan dari penyakit yang dapat menginfeksi ayam secara tiba-tiba dan seringkali sulit dideteksi sejak dini. Penelitian ini bertujuan untuk membantu peternak mengidentifikasi penyakit ayam lebih cepat dan akurat dengan memanfaatkan teknologi pemrosesan citra digital. Sistem klasifikasi dibangun menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur Xception, yang dikenal karena efisiensinya dalam mengekstraksi fitur visual. Model tersebut mengklasifikasikan citra menjadi empat kategori: Coccidiosis, Newcastle Disease, Salmonella, and healthy conditions. Proses pelatihan menggunakan dataset dari Kaggle dan sejumlah citra lapangan yang terbatas, dengan pembagian data 80:10:10 untuk pelatihan, validasi, dan pengujian. Model tersebut mencapai akurasi 94%, menunjukkan kinerja terbaik dalam mendeteksi Koksidiosis, sementara Penyakit Newcastle menimbulkan lebih banyak tantangan karena keterbatasan data. Pengujian lebih lanjut dengan 36 foto feses lapangan mengonfirmasi keandalan sistem, terutama dalam mengidentifikasi sampel yang sehat. Sistem ini terintegrasi ke dalam aplikasi seluler atau web yang dapat membantu peternak dalam mendeteksi penyakit ayam secara otomatis dari gambar tinja, yang pada akhirnya mengurangi kerugian dan mendukung praktik peternakan unggas yang lebih sehat.

Kata kunci: peternakan ayam, CNN, klasifikasi citra, penyakit unggas, xception

1. Pendahuluan

Peternakan ayam merupakan sektor penting dalam industri peternakan Indonesia karena tingginya permintaan daging dan telur ayam. Provinsi Jawa Barat, sebagai produsen daging ayam terbesar di Indonesia, mencerminkan potensi besar sektor ini (Direktorat SP2K, 2024) (Abdi, M.N., et al. (2023). Namun, ancaman penyakit unggas seperti Newcastle Disease, Salmonella, dan Coccidiosis masih menjadi kendala utama, terutama bagi peternak tradisional di daerah terpencil yang tidak memiliki akses memadai ke fasilitas kesehatan hewan (Mahfudz, L. D., et al. (2021). Penyakit-penyakit ini sulit dikenali pada tahap awal, dan penyebarannya yang cepat dapat mengakibatkan kerugian ekonomi yang besar. Untuk menjawab tantangan ini, diperlukan sistem deteksi yang cepat, tepat, dan hemat biaya.

Dalam beberapa tahun terakhir, penggunaan kecerdasan buatan, khususnya Convolutional Neural Networks (CNN), telah berkembang sebagai pendekatan yang efektif untuk mengenali pola visual yang tidak terlihat oleh manusia. CNN dapat mendeteksi perubahan warna, tekstur, dan bentuk pada kotoran ayam sebagai indikator penyakit (Ahadin, A. I., et al. (2024).

Salah satu arsitektur CNN yang dianggap efisien dan akurat untuk tugas klasifikasi citra kompleks adalah Xception, yang merupakan perluasan dari arsitektur Inception dengan menggunakan konvolusi

yang dapat dipisahkan secara mendalam untuk meningkatkan efisiensi komputasi (Chollet, F. (2017). Model-model yang dibandingkan seperti AlexNet, VGG, dan Inception. Selain itu, Xception terbukti unggul dalam menangkap detail-detail halus pada citra, termasuk dalam klasifikasi citra kotoran ayam (Krichen, M. (2023). Beberapa penelitian menunjukkan bahwa arsitektur ini mampu menghasilkan hasil klasifikasi yang lebih akurat dan hemat waktu dan sumber daya (Al Haq, J. (2021). Namun, potensi Xception belum banyak dieksplorasi dalam konteks deteksi penyakit ayam berbasis citra feses, terutama di lingkungan peternakan tradisional yang memiliki keterbatasan teknologi (Tundjungsari, V & Mitasya, S.A. (2024).

Penelitian ini bertujuan untuk mengembangkan model CNN berbasis Xception untuk mendeteksi dan mengklasifikasikan penyakit ayam dari citra feses ayam secara lebih efisien dan akurat. Selain itu, model ini diharapkan dapat menjadi solusi yang terjangkau dan aplikatif bagi peternak skala kecil untuk mendeteksi penyakit secara dini, mengurangi mortalitas ayam, dan meningkatkan efisiensi produksi ternak (Nugroho, M. & Astuti, F.Y. (2021).

Penelitian ini juga bertujuan untuk mengukur efektivitas model dari segi akurasi, efisiensi, dan kelayakan implementasi di lapangan. Model dibangun menggunakan gabungan dataset dari platform Kaggle dan peternakan lokal di Garut dan mencakup empat kelas kategori: Newcastle Disease,

Salmonella, Coccidiosis, dan Healthy (Riyanti, R., et al. (2024)). Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi nyata bagi penerapan teknologi kecerdasan buatan di sektor peternakan, khususnya dalam meningkatkan kesejahteraan peternak dan ketahanan pangan nasional.

2. Metode

2.1 Rencana Penelitian

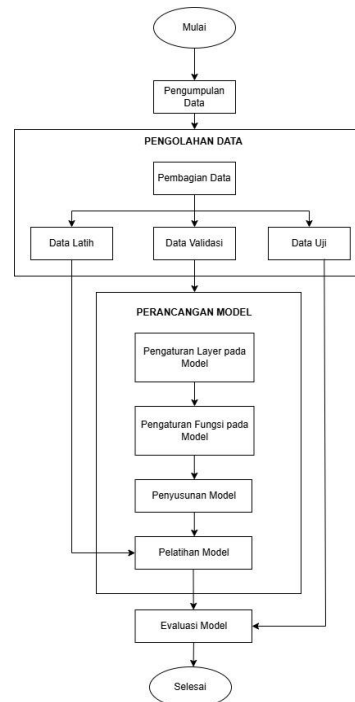
Penelitian ini dilakukan di Garut, Jawa Barat. Dengan waktu penelitian pada bulan Oktober 2024 – Februari 2025. Objek penelitian adalah kotoran ayam yang terdapat di peternakan. Kotoran ayam ini diambil sebagai sampel yang mewakili kondisi kesehatan ayam dan menjadi indikator keberadaan penyakit tertentu (Vandana, et al, (2023)). Penelitian ini juga menggunakan beberapa perangkat keras dan perangkat lunak untuk mendukung seluruh proses pengembangan dan pengolahan data.

Perangkat keras yang digunakan meliputi laptop HP 14-em0xxx dengan RAM 8GB yang menjalankan sistem operasi Windows 11. Laptop ini merupakan perangkat utama dalam proses pengembangan, seperti menjalankan aplikasi, menulis kode, dan mengolah data. Selain itu, kamera smartphone dengan resolusi 50 MP juga digunakan untuk pengumpulan data lapangan berupa sampel kotoran ayam. Kamera ini berfungsi untuk memperoleh citra yang dibutuhkan dalam analisis citra kotoran ayam.

Dari segi perangkat lunak, Google Colab digunakan sebagai platform untuk membuat dan membandingkan model pembelajaran mesin. Google Colab dilengkapi dengan GPU seperti NVIDIA K80s, T4s, P4s, dan P100s, yang mempercepat proses pelatihan model pembelajaran mesin. Selain itu, Microsoft Word 2021 digunakan untuk menulis dan mengedit dokumen penelitian, dengan spesifikasi prosesor 2-core 1,6GHz yang membantu dalam penyusunan tesis dalam format yang sesuai.


2.2 Tahap Penelitian

Pada tahap pengumpulan data ini, penelitian ini membutuhkan dataset yang memadai untuk melatih model klasifikasi. Dataset tersebut diperoleh dari platform Kaggle yang menawarkan data dalam jumlah besar dan memiliki variasi yang cukup luas, sehingga ideal untuk melatih model CNN (Galahartlambang, Y., et al. (2021)). Dataset yang digunakan dapat diakses melalui tautan berikut: <https://www.kaggle.com/datasets/efoetienneblavo/c-hicken-disease-dataset/data>. Dengan dataset dari Kaggle, model dapat belajar dari berbagai pola dan tekstur yang ada pada citra kotoran ayam. Selain itu, penelitian ini juga akan memvalidasi model dengan menggunakan dataset nyata yang diambil dari penelitian lapangan.



Gambar 1. Tahap Penelitian

Dataset ini terdiri dari citra kotoran ayam yang dikumpulkan langsung dari lapangan, yang akan digunakan untuk mengevaluasi kinerja model pada data dunia nyata, bukan pada lingkungan eksperimen yang lebih terstruktur.



Gambar 2. Dataset Kotoran Ayam

Gambar 2 adalah visualisasi dataset Kaggle yang menunjukkan karakteristik kotoran ayam berdasarkan jenis penyakit. Kotoran ayam yang terinfeksi penyakit koksidiosis umumnya berwarna kuning dan bertekstur encer. Sebaliknya, ayam yang terinfeksi penyakit Newcastle Disease menghasilkan feses berwarna hijau. Infeksi Salmonella menyebabkan feses berwarna putih keabu-abuan, sedangkan feses ayam yang sehat biasanya berwarna coklat tua dengan tekstur yang normal dan konsisten.

Pengolahan data dalam penelitian ini melibatkan pembagian data menjadi tiga subset utama: data latih, data validasi, dan data uji. Data latih digunakan untuk melatih model selama proses pembelajaran, sedangkan data validasi berfungsi untuk memantau kinerja model secara berkala dan menentukan parameter yang optimal. Setelah pelatihan selesai, data uji digunakan untuk mengevaluasi kinerja akhir model. Pendekatan ini bertujuan untuk memperoleh hasil yang objektif dan menghindari bias dalam pengujian model (Sudriyanto, et al. (2023)).

Desain model klasifikasi dilakukan menggunakan *arsitektur Xception* dengan bobot awal dari ImageNet. Model ini tidak menggunakan top (*include_top=False*), yang memungkinkan kustomisasi pada lapisan akhir. Ukuran gambar input ditetapkan pada 224x224 piksel dengan tiga saluran warna (RGB). Ekstraksi fitur dilakukan melalui lapisan *GlobalAveragePooling2D*, diikuti oleh lapisan Dense yang berisi 256 unit dan fungsi aktivasi ReLU, yang kemudian diteruskan ke lapisan Dropout pada 0,5 untuk mencegah overfitting. Lapisan output menggunakan fungsi aktivasi softmax dan terdiri dari empat unit yang mewakili kelas: *Coccidiosis*, *Healthy*, *Newcastle Disease*, dan *Salmonella*. Model dikompilasi dengan fungsi loss *categorical_crossentropy*, pengoptimal Adam dengan laju pembelajaran 0,001, dan metrik evaluasi akurasi.

Untuk meningkatkan kinerja dan stabilitas model, *ReduceLRonPlateau* digunakan serta augmentasi data melalui *ImageDataGenerator*, yang mencakup transformasi seperti pembalikan horizontal, penyesuaian pencahayaan, geseran, dan pergeseran saluran warna (Nazhirin, A. F. Z., et al. (2023)). Fungsi aktivasi yang digunakan dalam model ini berperan penting dalam meningkatkan kapasitas pembelajaran jaringan. Fungsi ReLU digunakan pada lapisan konvolusional dan lapisan terhubung penuh karena cepat dan efektif dalam mengatasi masalah *gradien menghilang*. Sedangkan pada lapisan keluaran, digunakan fungsi SoftMax yang mengubah keluaran menjadi probabilitas antar kelas sehingga model dapat menentukan kategori penyakit yang paling tepat dari citra masukan (Stiawan, A. (2024)).

Pemodelan dilakukan dengan menyusun komponen-komponen utama seperti pengoptimal Adam, fungsi kerugian entropi silang kategoris, dan metrik akurasi. Model juga dilengkapi dengan skema penyesuaian *laju pembelajaran* menggunakan *ReduceLRonPlateau* yang secara otomatis menurunkan laju pembelajaran ketika *val_loss* tidak menunjukkan perbaikan. Model dilatih menggunakan 6.508 citra untuk pelatihan dan 778 citra untuk validasi selama 50 epoch. Proses pelatihan diawasi melalui panggilan balik *lr_schedule* untuk menjaga stabilitas pembelajaran (Harahapp, M., et al. (2024)).

Selama proses pelatihan, model menunjukkan peningkatan akurasi yang signifikan. Dalam 10 epoch pertama, akurasi pelatihan meningkat dari 75,78% menjadi 92,73%, sedangkan akurasi validasi meningkat dari 90,49% menjadi 92,80%. Kehilangan data pelatihan dan validasi juga menurun secara konsisten. Pada epoch ke-25, akurasi pelatihan mencapai 95,96% dan stabil pada 94,47% dalam validasi. Hingga akhir pelatihan pada epoch ke-50, model mencatat akurasi sebesar 97,95% dan validasi mendekati 95%, menunjukkan proses pembelajaran yang stabil tanpa overfitting yang signifikan (Zein, A. (2019)).

Evaluasi akhir dilakukan dengan menggunakan data uji sebanyak 781 gambar. Prediksi model diubah menjadi label kelas menggunakan *argmax*, dan kinerja dievaluasi menggunakan matriks kebingungan dan laporan klasifikasi. Hasil menunjukkan akurasi keseluruhan sebesar 94%, dengan kinerja terbaik pada *kelas Koksidiosis* (skor F1 0,96). Meskipun demikian, model ini secara keseluruhan memiliki kinerja yang sangat baik, yaitu kelas *Penyakit Newcastle*. *kelas* mencatat ingatan yang lebih rendah (0,79), mungkin karena jumlah data yang lebih sedikit. Visualisasi matriks kebingungan dalam bentuk peta panas membantu analisis lebih lanjut dari distribusi prediksi (Suyuti, M. (2023)).

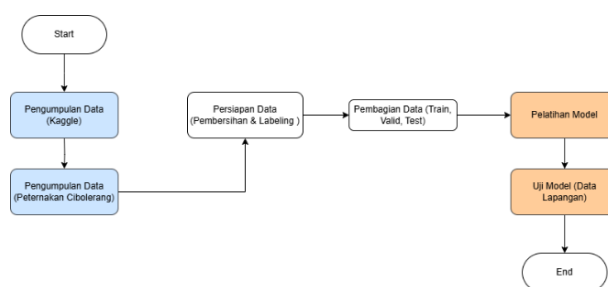
3. Hasil dan Pembahasan

3.1 Data Hasil Penelitian

Hasil penelitian yang telah dilakukan adalah menghasilkan model pembelajaran mesin yang dapat mendeteksi penyakit ayam berdasarkan objek feces ayam menggunakan metode CNN dan arsitektur Xception. Hasil ini akan dijelaskan secara detail, yang terbagi menjadi hasil proses dataset, pembuatan model, hasil pelatihan model, hingga hasil pengujian model.

3.1.1 Pemrosesan Dataset

Proses pengumpulan data merupakan tahap awal yang sangat penting dalam pembuatan model klasifikasi, terutama dalam klasifikasi penyakit ayam berbasis citra feces. Hasil dari proses pengumpulan data dapat dilihat pada Gambar 3.




Gambar 3. Diagram Proses Dataset

Pada tahap pengumpulan data, penelitian ini memanfaatkan dua sumber utama untuk membangun dataset. Sumber pertama berasal dari dataset publik di Kaggle yang berisi citra feces ayam yang telah diberi label berdasarkan jenis penyakit. Dataset ini dipilih karena telah melalui proses kurasi, sehingga memudahkan untuk melatih model dengan data yang representatif dan siap pakai. Sumber kedua adalah data lapangan yang dikumpulkan langsung dari peternakan ayam di Cibolerang, Garut, menggunakan kamera telepon genggam dengan pencahayaan alami di lingkungan kandang. Meskipun jumlahnya terbatas pada 36 citra, data ini digunakan sebagai set uji untuk mengukur kemampuan model dalam

mengenali pola penyakit dalam kondisi nyata. Kombinasi data Kaggle dan data lapangan diharapkan dapat meningkatkan generalisasi model ke berbagai citra feses ayam.

3.1.2 Pembuatan Model



Gambar 4. Diagram Model

Hasil pemodelan dapat dilihat pada arsitektur Gambar 4. Hasil arsitektur model yang telah dibuat untuk mendeteksi kondisi kesehatan feses ayam menggunakan pendekatan deep learning berbasis model Xception dapat dilihat pada Gambar 5.

Model: "sequential"

Layer (type)	Output Shape	Param #
xception (Functional)	(None, 7, 7, 2048)	20,861,480
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dense (Dense)	(None, 256)	524,544
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 4)	1,028

Total params: 21,387,052 (81.59 MB)
 Trainable params: 525,572 (2.00 MB)
 Non-trainable params: 20,861,480 (79.58 MB)


Gambar 5. Hasil Arsitektur Xception

Model klasifikasi dirancang menggunakan arsitektur Xception dengan citra masukan berukuran 224 x 224 piksel dan 3 kanal warna (RGB). Model ini memanfaatkan bobot dari pelatihan sebelumnya di ImageNet dan berfungsi sebagai ekstraktor fitur tanpa lapisan atas. Fitur yang dihasilkan kemudian diringkas melalui lapisan GlobalAveragePooling2D untuk mengurangi kompleksitas (Suyuti, M. (2023)). Hasilnya kemudian diproses ke lapisan Dense dengan 256 unit dan aktivasi ReLU untuk mengenali pola-pola penting. Untuk mencegah overfitting, nilai dropout sebesar 0,5 diterapkan. Terakhir, model mengklasifikasikan citra ke dalam empat kategori penyakit ayam —*koksidiosis*, *penyakit tetelo*, *salmonella*, dan *sehat*—melalui lapisan keluaran Dense dengan 4 unit dan fungsi aktivasi Softmax.

3.2 Hasil Model Pelatihan


Hasil Model Pelatihan dilakukan setelah proses pelatihan dijalankan, model CNN berbasis arsitektur Xception menunjukkan kinerja yang sangat baik dalam mengenali pola dari data gambar. Evaluasi dilakukan dengan memantau metrik akurasi dan loss pada data pelatihan dan validasi. Pada awal pelatihan, tepatnya pada epoch ke-1 hingga ke-10, akurasi pelatihan meningkat secara signifikan dari 75,78% menjadi 92,73%. Akurasi validasi juga menunjukkan

hasil yang tinggi dan stabil, yaitu pada rentang 90,49% hingga 92,80%, ditunjukkan pada Gambar 6.



Gambar 6. Training and Validation Accuracy

Penurunan nilai loss yang drastis pada kedua data yaitu dari 0,6357 menjadi 0,2032 pada data pelatihan dan dari 0,2888 menjadi 0,2066 pada data validasi menunjukkan bahwa model mampu melakukan pembelajaran dengan baik sekaligus menghindari overfitting, ditunjukkan pada Gambar 7.



Gambar 7. Training and Validation Loss

Proses pelatihan kemudian dilanjutkan hingga epoch ke-25 dengan penyesuaian learning rate secara bertahap dari nilai awal 0,0010. Pada fase ini, akurasi pelatihan terus meningkat hingga mencapai 95,96%, sedangkan akurasi validasi tetap tinggi pada rentang 91,65% hingga 94,47%. Nilai training loss terus menurun hingga 0,1171, dan validation loss tetap rendah pada rentang 0,1784 hingga 0,1981.

Hal ini menunjukkan bahwa model tidak hanya memahami pola data pelatihan, tetapi juga mampu mempertahankan performanya pada data yang belum pernah terlihat sebelumnya. Pada tahap selanjutnya, yaitu epoch ke-26 hingga ke-50, learning rate diturunkan lagi secara bertahap hingga mencapai 3,1250e-05. Akurasi pelatihan mencapai nilai tertinggi yaitu 97,95%, sedangkan akurasi validasi tetap stabil pada rentang 94,60% hingga 94,86%. Meskipun kerugian pelatihan menurun drastis menjadi sekitar 0,0579, kerugian pada data validasi tetap stabil dan rendah, sekitar 0,190 hingga 0,1936. Performa yang stabil ini menunjukkan tidak adanya overfitting yang signifikan dan model mampu mempertahankan generalisasinya.

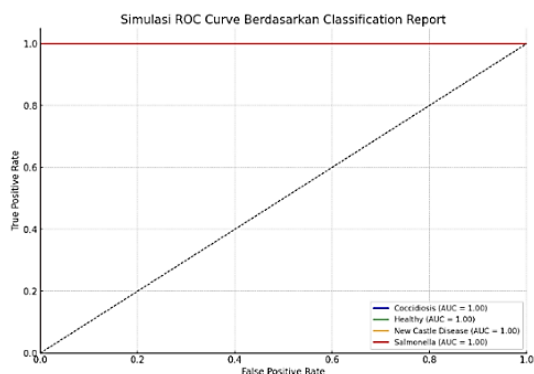
3.3 Hasil Pengujian Model

Setelah model dilatih, langkah selanjutnya adalah melakukan pengujian untuk mengevaluasi performa model terhadap data uji yang belum pernah dilihat sebelumnya. Proses ini bertujuan untuk menilai sejauh mana model mampu menggeneralisasi pengetahuannya dalam mengklasifikasikan citra feses ayam ke dalam kategori penyakit yang sesuai. Pengujian dilakukan menggunakan data uji yang sebelumnya telah dipisahkan dari data pelatihan dan validasi. Berikut adalah tabel yang menghitung hasil akurasi, presisi, recall, dan nilai f1 dari keseluruhan kelas. Tabel evaluasi menunjukkan bahwa model klasifikasi citra feses ayam secara keseluruhan berkinerja sangat baik dalam membedakan empat kelas penyakit menggunakan metrik presisi, recall, skor F1, dan jumlah sampel (support).

Tabel I. Hasil Klasifikasi

No.	Kelas	Precision	Recall	F1-Score	Support
1	Coccidiosis	0,96	0,96	0,96	248
2	Healthy	0,93	0,92	0,93	241
3	New Castle Disease	0,92	0,79	0,85	29
4	Salmonella	0,92	0,95	0,93	263
	Accuracy			0,94	781
	Macro Average	0,93	0,90	0,92	781
	Weighted Average	0,94	0,94	0,94	781

Model menunjukkan akurasi tinggi pada kelas *Coccidiosis* dengan ketiga metrik evaluasi mencapai 0,96, yang menunjukkan kemampuan prediksi dan deteksi yang sangat baik. Kelas *Healthy* juga diklasifikasikan cukup merata, dengan presisi 0,93 dan recall 0,92. Untuk kelas *Salmonella*, model berkinerja baik dengan presisi 0,92 dan recall 0,95, yang menunjukkan efektivitas dalam mendeteksi hampir semua sampel. Namun, kinerja pada kelas *New Castle Disease* masih perlu ditingkatkan karena meskipun presisinya tinggi (0,92), recall hanya 0,79, yang mungkin disebabkan oleh sedikitnya jumlah data uji. Selain metrik ini, analisis kurva ROC satu-vs-yang lain juga digunakan untuk menilai kemampuan model dalam membedakan setiap kelas secara individual, meskipun menggunakan pendekatan multikelas.



Gambar 8. Grafik ROC-AUC

Berdasarkan hasil simulasi kurva ROC yang dikompilasi dari laporan klasifikasi, nilai AUC relatif tinggi untuk setiap kelas penyakit ayam. Hal ini menunjukkan bahwa model memiliki kemampuan yang sangat baik untuk membedakan setiap jenis penyakit. Meskipun data yang digunakan merupakan data estimasi, visualisasi kurva ROC tetap memberikan gambaran representatif tentang kemampuan generalisasi model terhadap data uji (Vandana, et al. (2023)).

Meskipun model mencapai akurasi keseluruhan sebesar 94%, evaluasi kinerja tidak dapat hanya bergantung pada nilai akurasi, terutama pada kondisi distribusi data yang tidak seimbang. Analisis terhadap confusion matrix menunjukkan bahwa kesalahan klasifikasi paling banyak terjadi pada kelas *Newcastle Disease* yang memiliki jumlah sampel lebih sedikit dibandingkan kelas lainnya. Nilai recall sebesar 0,79 mengindikasikan bahwa sebagian sampel pada kelas tersebut masih salah diprediksi ke kelas lain, kemungkinan akibat kemiripan karakteristik visual seperti warna dan tekstur feses dengan kelas tertentu. Sebaliknya, kelas *Coccidiosis* menunjukkan performa sangat baik dengan precision dan recall tinggi, yang menandakan pola visualnya lebih konsisten dan mudah dikenali oleh model.





Perbandingan antara macro average dan weighted average juga menunjukkan adanya pengaruh ketidakseimbangan data terhadap performa model, di mana nilai macro average sedikit lebih rendah karena mempertimbangkan setiap kelas secara setara tanpa melihat proporsi sampel. Secara keseluruhan, model mencapai akurasi 94% pada 781 sampel data uji. Rata-rata makro, yang menunjukkan rata-rata metrik presisi, recall, dan skor F1 tanpa mempertimbangkan proporsi kelas, menunjukkan nilai sekitar 0,90 hingga 0,93, sementara rata-rata tertimbang, yang memperhitungkan proporsi sampel per kelas, memberikan nilai sedikit lebih tinggi, yaitu sekitar 0,94. Hal ini menunjukkan bahwa model memiliki kinerja yang stabil dan konsisten dalam mengklasifikasikan berbagai kelas penyakit. Dengan hasil ini, model dapat dianggap berhasil dalam mengenali dan membedakan kondisi kesehatan feses ayam secara efektif, meskipun masih terdapat ruang untuk perbaikan, terutama pada kelas dengan jumlah data terbatas seperti *New Castle Disease*.

3.3.1 Hasil Penelitian Lapangan

Pengujian model pada penelitian ini dilakukan menggunakan data citra feses ayam yang diperoleh langsung dari lapangan, yaitu dari peternakan ayam. Data lapangan ini mencerminkan kondisi nyata dengan variasi serta potensi gangguan yang lebih tinggi dibandingkan data standar atau data sintetis. Citra dipilih sebagai sampel pengujian yang mewakili berbagai kelas penyakit ayam. Pemilihan data lapangan ini bertujuan untuk mengevaluasi kemampuan model dalam mengklasifikasikan penyakit berdasarkan kondisi nyata, sehingga hasil

pengujian dapat mencerminkan kesiapan model untuk aplikasi praktis di lingkungan peternakan.

Tabel 2. Hasil Penelitian Lapangan

Citra	Hasil	Presentase
	Healthy	0.9862389
	Salmonella	0.8463298
	Coccidiosis	0.9808017
	New castle disease	0.8579160

Secara keseluruhan, hasil ini mengindikasikan bahwa arsitektur Xception yang dipadukan dengan teknik regularisasi Dropout dan optimizer Adam mampu menghasilkan model yang cukup efektif untuk klasifikasi penyakit ayam berbasis citra. Performanya konsisten pada data validasi dan pengujian, menunjukkan potensi penerapan model ini dalam lingkungan praktis di peternakan. Namun, masih diperlukan peningkatan, terutama untuk kelas-kelas yang memiliki jumlah data terbatas, melalui penambahan data atau penerapan teknik augmentasi yang lebih optimal guna meningkatkan akurasi klasifikasi di masa mendatang.

4. Kesimpulan

Kesimpulan Berdasarkan hasil penelitian, dapat disimpulkan bahwa model klasifikasi penyakit ayam berbasis citra feses dengan arsitektur CNN Xception mampu mengidentifikasi kondisi ayam secara efektif ke dalam empat kategori utama, yaitu Coccidiosis, Newcastle Disease, Salmonella, dan Healthy. Model ini menunjukkan kinerja yang sangat baik dengan akurasi validasi sebesar 94% dan F1-score yang tinggi, terutama pada kelas Coccidiosis.

Hasil ini menunjukkan bahwa pendekatan visual berbasis CNN dapat menjadi solusi yang efektif untuk deteksi penyakit ayam secara non-invasif, terutama bagi peternak tradisional yang memiliki akses terbatas ke fasilitas medis. Meskipun arsitektur Xception sudah sering digunakan dalam berbagai tugas klasifikasi gambar, penelitian ini belum

melakukan perbandingan langsung dengan arsitektur CNN lainnya dalam kondisi eksperimen yang sama. Oleh karena itu, untuk menunjukkan secara jelas bagaimana baiknya model yang dikembangkan, dilakukan perbandingan dengan arsitektur jaringan saraf tiruan yang sudah umum digunakan dalam penelitian serupa, seperti InceptionV3, ResNet50, dan EfficientNet. Berdasarkan laporan penelitian sebelumnya, arsitektur InceptionV3 biasanya mencapai tingkat akurasi sekitar 90% hingga 93% dalam klasifikasi gambar penyakit unggas dengan jumlah kelas antara 3 sampai 4. ResNet50 diklaim mampu mencapai tingkat akurasi hingga 94% hingga 95% ketika digunakan pada dataset yang besar, meskipun jumlah parameter yang dimilikinya lebih besar dibandingkan beberapa model lainnya. EfficientNet memiliki efisiensi parameter yang baik dan akurasi cukup tinggi, yaitu di atas 93%, tetapi membutuhkan pengaturan pelatihan yang lebih rumit.

Model yang dibuat dalam penelitian ini menggunakan arsitektur Xception dan mampu mencapai akurasi sebesar 94% dengan skor F1 rata-rata tertimbang sebesar 0,94. Secara angka, performa tersebut berada dalam tingkat yang seimbang dengan arsitektur lain yang lebih rumit. Selain itu, Xception memiliki jumlah parameter yang lebih efisien dibandingkan ResNet50 dalam beberapa konfigurasi tertentu, sehingga lebih cocok digunakan dalam implementasi di sistem berbasis web atau perangkat dengan sumber daya terbatas. Namun, keterbatasan data, terutama pada kelas minoritas seperti Newcastle Disease, tetap menjadi tantangan yang perlu diatasi untuk lebih meningkatkan kinerja model secara keseluruhan.

Daftar Pustaka:

Abdi, M. N., dkk. (2023). Manajemen tata kelola keuangan dan manaj. *Pengabdian Dharma Laksana Mengabdikan Untuk Negeri*, 5(2), 340–347.

Mahfudz, L. D., Sunarti, D., Kismiyati, S., Sarjana, T. A., & MHN. (2021). *Pencegahan penyakit ternak unggas*.

Ahadin, A. I., Hana, F. M., Prihandono, A., & Pujiono, I. P. (2024). Pengembangan model klasifikasi produk furnitur sebagai visual search menggunakan algoritma convolutional neural network. *Sistem Komputer dan Kecerdasan Buatan*, 8, 1–9.

Chollet, F. (2017). *Xception: Deep learning with depthwise separable convolutions*. arXiv. <http://arxiv.org/abs/1610.02357>

Krichen, M. (2023). Jaringan saraf tiruan konvensional: Sebuah survei. *Computers*, 12(8). <https://doi.org/10.3390/computers12080151>

Al Haq, J. (2021). Klasifikasi cepat model XceptionNet dan ResNet-50 pada video deepfake menggunakan Local Binary Pattern.

Tundjungsari, V., & Mitasya, S. A. (2024). Pengembangan aplikasi deteksi penyakit ayam menggunakan metode Xception transfer learning.

- 2024 7th International Conference on Information and Communications Technology (ICOIACT), 67–72. <https://doi.org/10.1109/ICOIACT64819.2024.10913426>
- Nugroho, M., & Astuti, F. Y. (2021). Analisis kelayakan usaha peternakan ayam pedaging (broiler).
- Riyanti, R., Nova, K., Septinova, D., Hasiib, A., & Artikel, P. (2024). Penerapan inovasi ramah lingkungan *Moringa oleifera* dalam upaya meningkatkan produktivitas peternakan ayam petelur CV. Marga Raya Farm. *Jurnal Pengabdian Fakultas Pertanian Universitas Lampung*, 3(2), 1–10.
- Vandana, Kumar Yogi, & Yadav, S. P. (2023). Surveillance for detection and classification of poultry diseases from fecal images using CNN. *Proceedings of the International Conference on Contemporary Computing and Informatics (IC3I)* (pp. 939–943). <https://doi.org/10.1109/IC3I59117.2023.10397876>
- Galahartlambang, Y., Khotiah, T., & Jumain. (2021). Visualisasi data dari dataset COVID-19 menggunakan pemrograman Python. *Jurnal Teknologi Informasi UMUS*.
- Sudriyanto, Syahro, F., & Fitriani, N. (2023). Perbandingan performa model machine learning Support Vector Machine, Neural Network, dan K-Nearest Neighbors dalam prediksi harga saham. *Jurnal Advance Research Informatika*, 2(1), 13.
- Nazhirin, A. F. Z., Muttaqin, M. R., & Hermanto, T. I. (2023). Klasifikasi kondisi ban kendaraan menggunakan arsitektur VGG16. *INTI Nusa Mandiri*, 18(1), 1–12. <https://doi.org/10.33480/inti.v18i1.4270>
- Stiawan, A. (2024). Implementasi model pre-trained pada CNN berdasarkan multi input parameter untuk identifikasi jenis kopi berbasis GUI.
- Harahapp, M., Husein, A. M., & Thedora, F. (2024). Penerapan EfficientNet dalam mengklasifikasi kanker kulit. *Unpri Press*.
- Zein, A. (2019). Pendeteksian penyakit malaria menggunakan analisis gambar medis dengan deep learning Python. *Sainstech*, 29(1), 1410–7104.
- Suyuti, M. (2023). Pengembangan model klasifikasi mata tertutup dan terbuka dalam identifikasi kelelahan menggunakan arsitektur Mobile CNN.

Halaman ini sengaja dikosongkan
