

IMPLEMENTASI MODEL TRANSFER LEARNING ARSITEKTUR CONVNEXT UNTUK KLASIFIKASI SUARA BURUNG DI TAMAN NASIONAL WAY KAMBAS

Rizki Adrian Bennovry*, Alber Analafean, Nabilah Andika Fitriati, Helma Lia Putri, Catherine Firdhasari Maulida Sinaga, Christyan Tamaro Nadeak, Ardika Satria, Ade Lailani
Program Studi Sains Data, Institut Teknologi Sumatera, Lampung Selatan, Indonesia

*Penulis korespondensi: rizki.121450073@student.itera.ac.id

ABSTRAK

Deforestasi di Sumatera telah mengancam keanekaragaman hayati dan habitat satwa liar, terutama burung. Penelitian ini bertujuan mengimplementasikan model transfer learning arsitektur ConvNeXt untuk mengklasifikasikan suara burung di Taman Nasional Way Kambas sebagai upaya pemantauan dan konservasi keanekaragaman hayati. Metode penelitian menggunakan pendekatan biofoni dengan ekstraksi fitur menggunakan Mels Spectrogram untuk merepresentasikan karakteristik frekuensi suara burung secara visual. Pemodelan transfer learning ConvNeXt dilakukan dengan dua pendekatan: augmentasi dan non-augmentasi data, di mana teknik augmentasi diterapkan untuk meningkatkan variabilitas model dalam mengenali berbagai variasi suara burung. Hasil penelitian menunjukkan model ConvNeXt dengan augmentasi data memberikan performa yang signifikan lebih baik dalam mengidentifikasi spesies burung dengan akurasi 71% berdasarkan karakteristik suaranya. Penelitian ini memberikan kontribusi penting dalam pengembangan teknologi pemantauan biodiversitas menggunakan kecerdasan buatan yang berpotensi menjadi alat efektif untuk memantau perubahan ekosistem dan mendukung upaya konservasi di Taman Nasional Way Kambas.

Kata kunci: ConvNeXt, Klasifikasi Suara Burung, Transfer Learning, Konservasi, Way Kambas.

1 PENDAHULUAN

Taman Nasional Way Kambas merupakan salah satu kawasan konservasi paling penting di Indonesia, terletak di Provinsi Lampung, yang memiliki keanekaragaman hayati luar biasa, terutama dalam hal kekayaan populasi burung. Sebagai habitat yang unik dan kompleks, kawasan ini menyimpan berbagai spesies burung yang sebagian di antaranya merupakan satwa endemik dan dilindungi. Namun, upaya identifikasi dan monitoring populasi burung secara tradisional menghadapi sejumlah tantangan signifikan, di antaranya keterbatasan sumber daya manusia, biaya penelitian yang tinggi, serta kompleksitas proses identifikasi yang memerlukan keahlian khusus. (Andyono et al., 2018). Beberapa tahun terakhir, teknologi pengolahan sinyal audio berbasis kecerdasan buatan telah memberikan alternatif baru dalam pengklasifikasian suara burung. Suara burung memberikan informasi unik yang dapat digunakan untuk mengidentifikasi spesies, sehingga memungkinkan pendekatan non-inovatif dalam pemantauan biodiversitas. Akan tetapi, tantangan utama dalam klasifikasi suara burung adalah kompleksitas data audio, seperti variasi frekuensi, amplitudo serta keberadaan noise lingkungan.

Perkembangan teknologi kecerdasan buatan, khususnya dalam ranah deep learning dan machine learning, telah membuka ruang transformasi yang sangat potensial dalam bidang konservasi dan penelitian keanekaragaman hayati. Transfer Learning memungkinkan pemanfaatan model yang

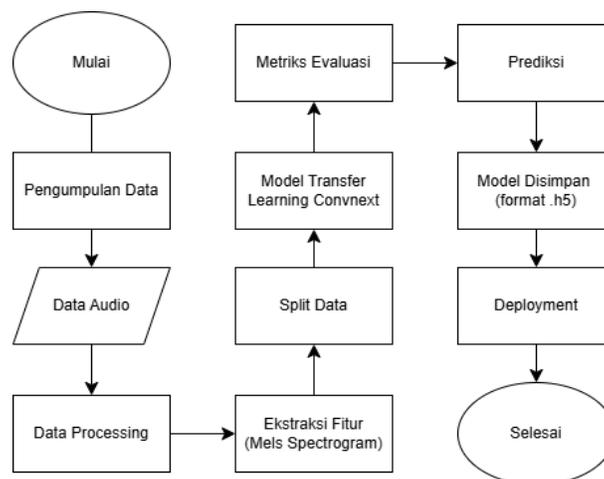
telah dilatih pada dataset besar untuk diaplikasikan pada domain yang lebih spesifik dengan kebutuhan data pelatihan yang lebih sedikit. Salah satu terobosan teknologi yang menjanjikan adalah penggunaan arsitektur jaringan syaraf tiruan modern seperti ConvNeXt, yang telah menunjukkan kemampuan luar biasa dalam mengekstraksi fitur-fitur kompleks dari berbagai jenis data, termasuk data audio. ConvNeXt memiliki keunggulan dalam arsitektur yang mampu menangkap representasi fitur secara mendalam, menjadikannya ideal untuk klasifikasi suara burung yang memerlukan pengenalan pola temporal dan spektral. (Firmansah et al., 2023).

Penelitian R Arif Firmansah et al. tentang Implementasi Transfer Learning pada Pengenalan Citra Rumah Adat Indonesia menggunakan metode CRISP-DM untuk mengklasifikasikan lima kelas rumah adat. Penelitian menguji empat arsitektur model transfer learning: MobileNetV2, VGG16, Xception, dan ResNet50, dengan hasil akurasi bervariasi. Model MobileNetV2 mencapai akurasi tertinggi 0,96%, diikuti ResNet50 (0,94%), Xception (0,92%), dan VGG16 (0,74%). Temuan kunci menunjukkan bahwa performa model machine learning sangat bergantung pada karakteristik dataset spesifik, menegaskan pentingnya eksperimentasi dengan berbagai arsitektur model. Peneliti merekomendasikan pengembangan penelitian selanjutnya dengan memperbesar dataset, menambah variasi kelas, dan mengembangkan proses deployment machine learning yang lebih komprehensif. Penelitian ini signifikan karena mendemonstrasikan efektivitas transfer learning dalam klasifikasi citra warisan budaya Indonesia, membuka peluang aplikasi teknologi machine learning untuk pelestarian budaya. (Outwile et al., 2024). Penelitian ini menerapkan teknik transfer learning menggunakan arsitektur ConvNext yang dikombinasikan dengan teknik augmentasi data untuk meningkatkan akurasi klasifikasi suara burung di Taman Nasional Way Kambas. Melalui serangkaian eksperimen dengan berbagai konfigurasi parameter, penelitian ini bertujuan untuk mengidentifikasi parameter optimal yang menghasilkan performa model terbaik dalam mengklasifikasikan suara burung di kawasan konservasi tersebut.

2 METODE

2.1 Diagram Alir

Penelitian ini dilakukan dengan beberapa tahapan proses yang sistematis untuk mendapatkan data yang relevan dan melakukan analisis secara kuantitatif. Berikut adalah tahapan dan pendekatan yang digunakan:



Gambar 1. Diagram Alir

2.2 Pengumpulan Data

Data suara burung diperoleh dari database audio burung di seluruh wilayah (<https://xeno-canto.org/>) dengan melakukan *data crawling* menggunakan API Xeno-Canto dan informasi database nama burung diseluruh wilayah Avibase. Data yang dikumpulkan mencakup berbagai kelas suara burung yang ada di Taman Nasional Way Kambas. Penelitian ini difokuskan pada wilayah Taman Nasional Way Kambas untuk mendapatkan daftar burung berdasarkan nama ilmiah, genus, dan spesies. Daftar tersebut digunakan sebagai acuan utama dalam proses klasifikasi. Berdasarkan pada informasi yang terverifikasi dari Avibase, penelitian ini memastikan bahwa data spesies burung yang dianalisis relevan dan valid dalam konteks geografis Way Kambas.

Data dikumpulkan secara Data Crawling dengan memanfaatkan API dari Xeno-Canto, dengan persebaran type audio database xeno-canto. Dataset yang diperoleh yaitu rata-rata 191 audio di seluruh kelas, dengan total keseluruhan data audio sebanyak 1912 audio. Data audio burung pada Tabel 1 dilakukan pemodelan hanya beberapa audio pada masing-masing kelas, dengan menggunakan model transfer learning arsitektur ConvNeXt. Dataset yang digunakan sebagai berikut.

Tabel 1 Dataset Burung Xeno-Canto

Nama Spesies	Nama Ilmiah	Jumlah Data Audio
Kedasi Hitam	<i>Surniculus Lugubris</i>	156
Tekukur Biasa	<i>Spilopelia Chinensis</i>	223
Prenjak Rawa	<i>Prinia Flaviventris</i>	267
Sikatan Kepala Abu	<i>Culicicapa Ceylonensis</i>	273
Perkutut Jawa	<i>Geopelia Striata</i>	133
Punggok Cokelat	<i>Ninox Scutulata</i>	176
Paok Hijau	<i>Pitta Sordida</i>	159
Wiwik Kelabu	<i>Cacomantis Merulinus</i>	201
Cinenen Kelabu	<i>Orthotomus Ruficeps</i>	125
Cekakak Belukar	<i>Halcyon Smyrnensis</i>	199

2.3 Preprocessing

Tahap preprocessing dimulai dengan memilih 100 sampel audio secara acak untuk setiap kelas burung. Tujuannya adalah menciptakan dataset yang seimbang dan representatif. Selanjutnya, dilakukan resampling frekuensi untuk menstandarisasi format audio ke frekuensi sampling 16000 Hz. Proses segmentasi audio akan membatasi durasi setiap rekaman menjadi 5 detik menggunakan librosa, yang kemudian dikelompokkan berdasarkan kelas yang selanjutnya disimpan dengan format baru dan setiap segmen diberi nama sesuai kelas suara burung, yang bertujuan menciptakan input model yang konsisten dan terukur, serta mengurangi variabilitas yang tidak perlu dalam data latih. (Simonyan et al., 2014)

2.4 Ekstraksi Fitur

Fitur data diekstraksi dalam bentuk *Mel Spectrogram* menggunakan transformasi *Fourier* untuk menangkap karakteristik spektral dan temporal dari suara burung. *Mel Spectrogram* adalah metode yang digunakan untuk mengubah sinyal audio mentah menjadi representasi visual berbasis spektrum frekuensi dalam domain waktu. Teknik ini menggunakan skala Mel, yang dirancang

menyerupai cara manusia memahami perbedaan frekuensi, dengan memberikan resolusi lebih tinggi pada frekuensi rendah. Dalam proses ini, sinyal audio diproses untuk menghasilkan visualisasi dua dimensi, di mana sumbu waktu, frekuensi, dan intensitas suara ditampilkan dalam bentuk gradasi warna. Representasi ini sangat efektif untuk menangkap karakteristik unik dari pola suara burung, sehingga mempermudah model machine learning dalam mengenali dan mengklasifikasikan suara berdasarkan spesiesnya. Hasil ekstraksi fitur akan menjadi masukan utama untuk model. (Rafliansyah et al., 2024)

Berikut tahapan Pembuatan Mel Spectrogram:

1. Transformasi Fourier Cepat (Fast Fourier Transform - FFT) :

Mengubah sinyal audio dari domain waktu menjadi domain frekuensi. Rumus dasar FFT :

$$X(k) = \sum_{n=0}^{N-1} x(n).e^{-j2\pi kn/N}, k = 0, 1, \dots, N-1$$

Dimana $X(k)$ adalah komponen frekuensi, $x(n)$ adalah sinyal input, N adalah panjang sinyal, dan j adalah unit imajiner

2. Penerapan Filter Bank Mel :

Frekuensi linear dari hasil FFT diubah menjadi skala Mel menggunakan filter triangular. Konversi dari frekuensi f (Hz) ke frekuensi Mel dilakukan dengan :

$$m = 2595 \cdot \log_{10}\left(1 + \frac{f}{700}\right)$$

filter ini memberikan resolusi lebih tinggi pada frekuensi rendah

3. Logaritma Spektral :

Menghitung logaritma dari magnitudo spektrum untuk meniru persepsi manusia terhadap intensitas suara.

4. Transformasi Cepat Terbalik (Inverse Discrete Cosine Transform - IDCT)

Menyediakan visualisasi dua dimensi (waktu vs frekuensi) dalam bentuk Mel Spectrogram.

Proses ekstraksi fitur dengan Mels Spectrogram dilakukan pada masing-masing kelas.

Parameter utama pengaturan Mels-Spectrogram yang digunakan yaitu:

1. Sample rate (sr) dengan frekuensi : 16.000 Hz
2. FFT window size (n_fft) : 1024 sampel
3. Hop length : 512 sampel (overlap antar jendela analisis)
4. Jumlah filter Mel (n_mels) : 128

Dengan nilai power hasil Mel-Spectrogram dikonversi ke skala desibel menggunakan *librosa.power_to_db* untuk memudahkan interpretasi. Setelah itu, Mel-Spectrogram divisualisasikan dalam bentuk gambar menggunakan skema warna 'magma'. Setiap file audio disimpan dalam format gambar .png. Tahap ekstraksi fitur mengonversi file audio masing-masing kelas menjadi representatif Mel-Spectrogram.

2.5 Subsampling

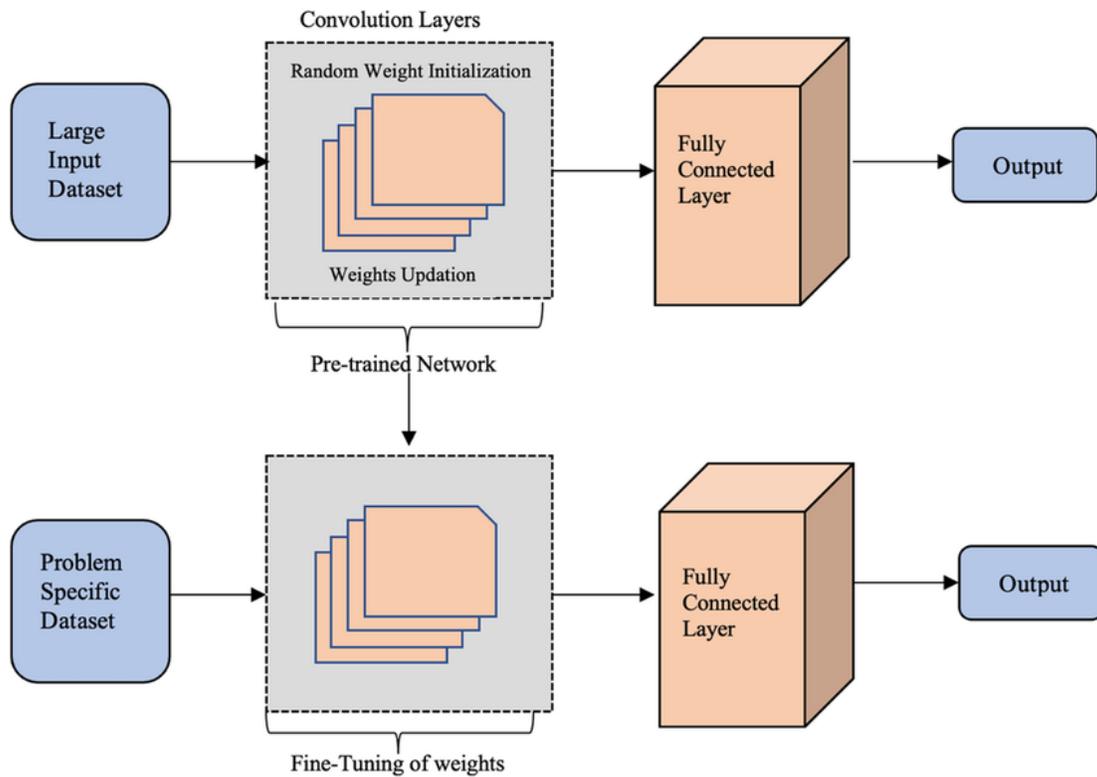
Tahap subsampling akan membatasi jumlah data menjadi 150 sampel dari hasil mel spectrogram menggunakan teknik stratified sampling. Tujuan utama dari proses ini adalah mengoptimasi beban komputasi dan mencegah overfitting, dengan memastikan bahwa setiap kelas tetap terwakili secara proporsional. Metode ini membantu mengendalikan kompleksitas model tanpa mengorbankan keanekaragaman informasi dalam dataset.

2.6 Augmentasi Data

Teknik yang digunakan meliputi shear, zoom, flip horizontal, dan rotasi pada gambar mel spectrogram (Simonyan et al., 2014). Augmentasi data dilakukan untuk meningkatkan variabilitas data pelatihan dan ketahanan model terhadap perubahan kecil. Teknik augmentasi mencegah model overfitting dengan variasi tambahan pada data pelatihan (train). Augmentasi data menggunakan *ImageDataGenerator* yang memberikan variasi data melalui transformasi. Augmentasi hanya diterapkan pada data training, sedangkan data validasi hanya dinormalisasi (*rescale*). Melalui manipulasi ini, model diharapkan dapat lebih robust terhadap variasi pola visual yang merepresentasikan suara burung, mampu mengenali pola akustik burung dalam kondisi yang berbeda, dan mengurangi potensi bias dalam proses klasifikasi. (Toyib et al., 2024, 7)

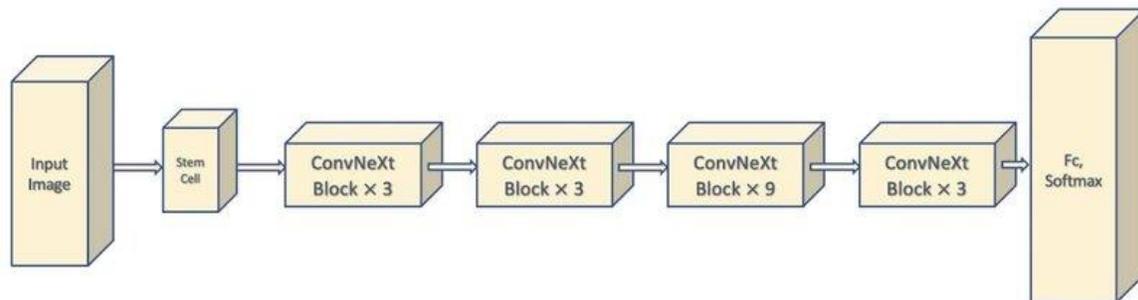
2.7 Model Transfer Learning

Transfer Learning merupakan pembelajaran mesin dimana sebuah model yang telah dilatih sebelumnya. Transfer learning adalah model yang memanfaatkan pengetahuan yang telah diperoleh dari pelatihan sebelumnya untuk mempercepat proses pembelajaran dan meningkatkan performa model. Transfer learning memiliki keunggulan diantaranya dapat menghemat waktu dan sumber daya dengan melatih model dari awal yang memerlukan banyak waktu pada proses komputasi. Transfer learning juga banyak digunakan dalam machine learning seperti pengenalan objek, pengenalan suara, pemrosesan bahasa alami, dan mendeteksi emosi dalam gambar. Transfer learning ini, teknik yang sangat efektif dalam pengembangan sebuah model machine learning. Terutama, dalam menghadapi keterbatasan data dan sumber daya. Dengan memanfaatkan pengetahuan dari model, dapat mempercepat proses pelatihan dan meningkatkan akurasi pada berbagai aplikasi. (Wijaya et al., 2021)



Gambar 2. Arsitektur Model Transfer Learning

ConvNeXt adalah arsitektur jaringan syaraf konvolusional (CNN) yang dirancang untuk meningkatkan kinerja model dalam menjalankan tugas-tugas pemrosesan gambar, seperti klasifikasi suara burung dan deteksi objek burung. Model ini terinspirasi oleh desain *Vision Transformers* dengan tetap mempertahankan sifat efisien CNN dan memiliki tujuan untuk menggabungkan keunggulan dari kedua pendekatan tersebut. ConvNeXt memiliki kedalaman yang signifikan yang terdiri dari lapisan konvolusi, lapisan aktivasi, dan lapisan yang terhubung sepenuhnya. ConvNeXt menunjukkan performa yang sangat baik menggunakan *ImageNet*. ConvNeXt juga banyak digunakan dalam berbagai aplikasi pengolahan citra, seperti klasifikasi suara burung, mendeteksi objek burung, maupun segmentasi. (Austin et al., 2024)



Gambar 2.3 Arsitektur ConvNeXt

Arsitektur ConvNeXt Type Base dipilih sebagai model transfer learning, dengan menggunakan framework *TensorFlow* dan *Keras*. Model akan diinisiasi dengan bobot pra-latih dari ImageNet, dan seluruh lapisan akan di-*fine-tuning terkecuali 5 lapisan terakhir* dilakukan *freeze* (membekukan lapisan) yang bertujuan untuk *fine tuning* agar diperoleh performa model yang sangat baik. Pendekatan transfer learning memungkinkan pemanfaatan pengetahuan dari model yang sudah dilatih sebelumnya, mengadaptasikannya ke konteks klasifikasi suara burung (Pedregosa & Fabian, 2011, 6). Untuk memastikan performa model yang optimal, optimizer yang digunakan model adalah Adam, yang dapat menyesuaikan learning rate selama proses pelatihan. (Zhang & Zijun, 2018)

2.8 Performa Model

Model Performa model akan di visualisasikan melalui grafik akurasi dan loss menggunakan Matplotlib dan Seaborn. Grafik akan menampilkan kurva training dan validasi, memberikan wawasan visual tentang proses pembelajaran model, menunjukkan konvergensi, potensi overfitting, atau underfitting, serta membantu peneliti dalam menginterpretasi kinerja arsitektur ConvNeXt.

2.9 Evaluasi Metrik

Evaluasi metrik dilakukan secara komprehensif menggunakan Scikit-learn, mencakup confusion matrix, akurasi, presisi, recall, dan F1-score. Analisis diperluas hingga perhitungan akurasi per kelas untuk memberikan pemahaman yang lebih mendalam terkait performa model dalam mengklasifikasikan setiap spesies burung. Metode ini memungkinkan penilaian kuantitatif yang lebih akurat terhadap kemampuan model. Tambahan rumus-rumus evaluasi metrik seperti presisi

(Precision), recall (Sensitivity), dan F1-score digunakan untuk melengkapi analisis performa model (Abadi et al., 2016)

Berikut adalah semua rumus evaluasi metrik yang digunakan dalam Evaluasi Klasifikasi:

1. Akurasi

$$Accuracy = \frac{TP + TN}{Total\ Sampel}$$

2. Presisi

$$Precision = \frac{TP}{Tp + FP}$$

3. Recall

$$Recall = \frac{TP}{TP + FN}$$

4. F-1 Score

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Keterangan :

TP : True Positive

FP : False Positive

FN : False Negative

TN : True Negative

2.10 Prediksi

Penelitian ini menggunakan stratifikasi dengan proporsi 80% untuk data latih (training), 10% untuk validasi, dan 10% untuk pengujian (testing). Teknik pembagian ini memastikan distribusi kelas yang seimbang pada setiap subset data. Pada tahap training, model ConvNeXt akan dilatih menggunakan 80% dataset, yang memungkinkan model untuk mempelajari pola-pola kompleks dalam klasifikasi suara burung. Validasi 10% digunakan untuk melakukan evaluasi berkala selama proses pelatihan, membantu mencegah overfitting dan memastikan generalisasi model. Subset testing 10% akan digunakan untuk mengevaluasi performa akhir model, memberikan penilaian independen dan objektif terhadap kemampuan klasifikasi model pada data yang sama sekali tidak pernah dilihat sebelumnya.

2.11 Deployment

Tahapan deployment dilakukan dalam implementasi interface model yang dibangun dengan menggunakan framework streamlit. Streamlit merupakan library dari python yang berguna dalam membuat tampilan user interface dari python (Iwandini et al., 2023). Dimana tahapan deployment memanfaatkan basis pemrograman python, css serta html. Penggunaan streamlit agar bisa model dibangun ditampilkan dalam bentuk user interface yang bisa dimanfaatkan oleh pengguna luas.

3 HASIL DAN PEMBAHASAN

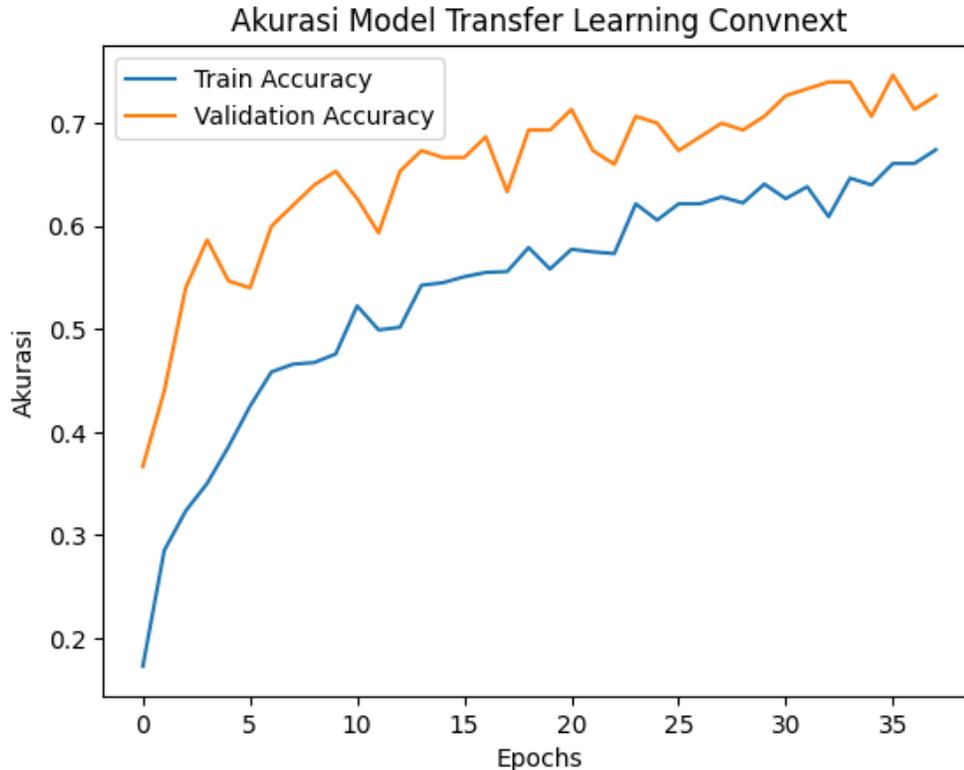
Penelitian ini menggunakan 2 dugaan yaitu model yang menggunakan augmentasi dan model yang menggunakan non augmentasi. Kombinasi parameter yang dilakukan dengan masing masing dugaan tersebut memiliki 2 parameter yang berbeda. Parameter tersebut dilakukan pemodelan dan didapatkan bahwa hasil dengan dugaan tanpa augmentasi pada epoch 25 didapatkan akurasi

sebesar 0.70 dan pada epoch 50 didapatkan akurasi sebesar 0.69. Pada dugaan menggunakan augmentasi pada epoch 25 didapatkan akurasi sebesar 0.65 dan pada epoch 50 didapatkan akurasi sebesar 0.71. Berdasarkan parameter yang dijalankan pada model transfer learning arsitektur ConvNeXt didapatkan bahwa model dengan augmentasi pada epoch 50 memiliki akurasi yang cukup tinggi diantara parameter yang lain sehingga didapatkan model augmentasi pada epoch 50 menunjukkan model yang terbaik dibandingkan parameter yang lain. Parameter yang sudah dijalankan dapat dilihat pada Tabel 2.

Tabel 2. Parameter Model Dengan Data Non-Augmentasi & Augmentasi

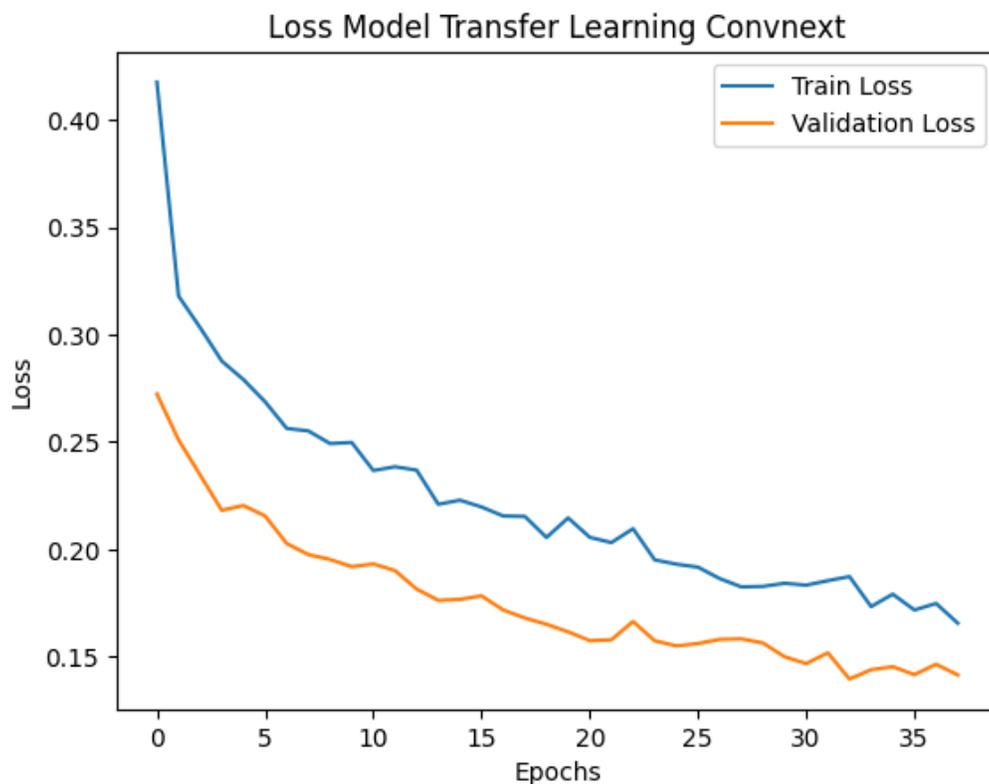
Batch Size	Learning Rate	Augmentasi Data	Epochs	Akurasi
32	1e-4(0.0001)	Tanpa Augmentasi	25	0.70
		Data	50	0.69
	1e-4(0.0001)	Augmentasi Data	25	0.65
			50	0.71

Evaluasi performa model dengan akurasi mencapai 0.71 (71%) yang menunjukkan bahwa model mampu mengklasifikasikan sebagian besar data dengan baik atau performa model yang cukup baik. Augmentasi membantu model untuk *generalize* lebih baik pada data yang belum pernah dilihat sebelumnya, sehingga mengurangi risiko *overfitting*. Performa sebesar 71% sudah cukup baik, dengan model yang dilatih dengan data augmentasi yang memiliki variasi tinggi. Model mampu menangkap pola-pola penting dalam gambar burung. Dan berikut grafik hasil akurasi pelatihan model transfer learning convnext pada data augmentasi 50 epoch.



Gambar 3. Akurasi Model Data Augmentasi Epochs 50

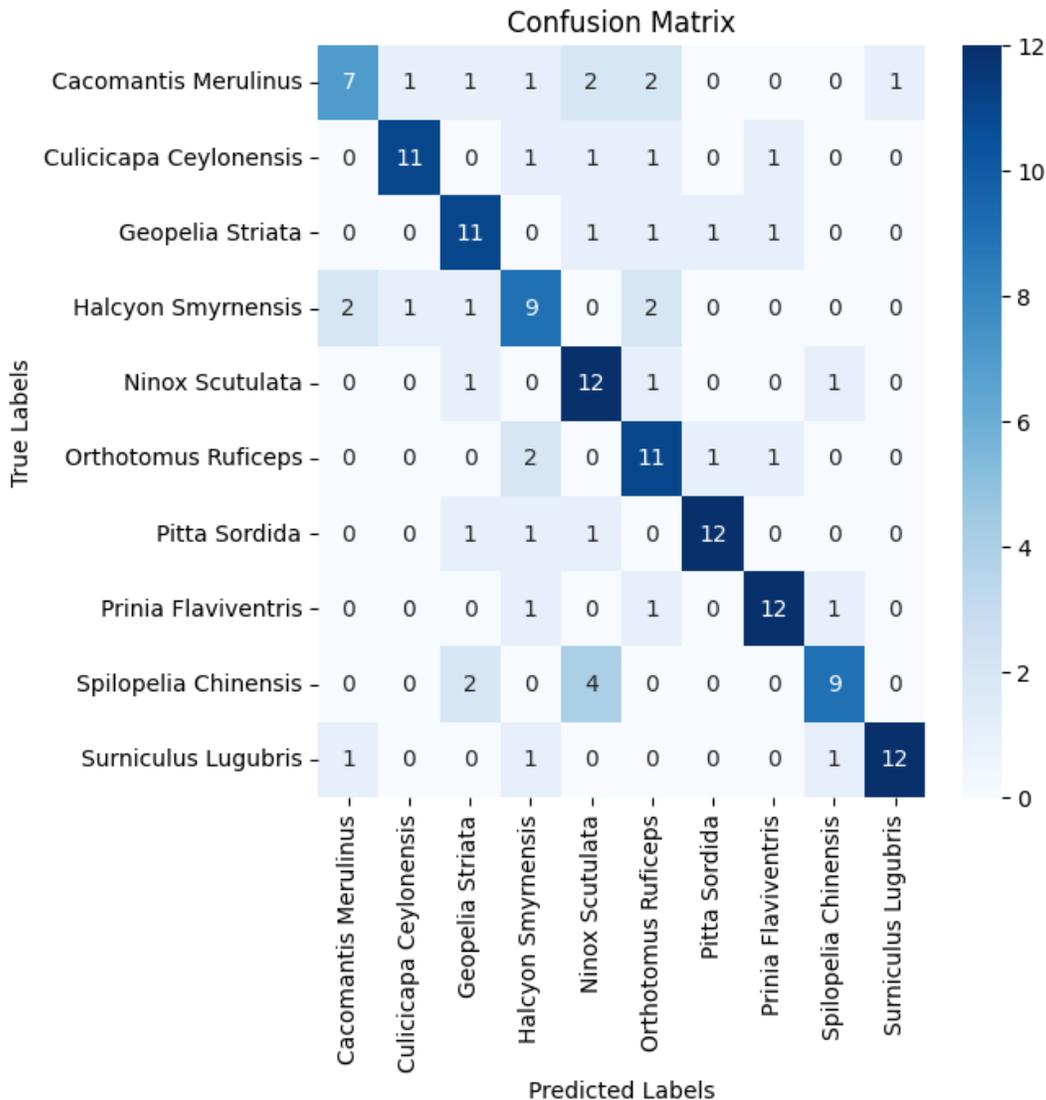
Pada gambar 3, grafik menunjukkan performa model transfer learning ConvNeXt yang dilatih dengan data augmentasi. Pada hasil grafik diatas yang menjadi parameter adalah epoch 50 dengan batch size 32 dan learning rate yang digunakan yaitu 0.0001. Akurasi model pada data pelatihan (train accuracy) semakin meningkat seiring bertambahnya epoch, menandakan model semakin mahir dalam mengklasifikasikan data latih. Akurasi validasi (validation accuracy) juga meningkat secara konsisten, meskipun dengan sedikit fluktuasi. Hal ini mengindikasikan model dapat menggeneralisasi dengan baik. Grafik juga menunjukkan kecenderungan konvergensi antara akurasi train dan validasi, serta stabilitas performa setelah epoch 20. Secara keseluruhan, model ConvNeXt yang dilatih dengan data augmentasi menunjukkan performa yang baik dalam mengklasifikasikan suara burung. Temuan ini memberikan pemahaman tentang kemampuan model dalam konteks klasifikasi suara burung menggunakan transfer learning.



Gambar 4. Loss Model Data Augmentasi dengan Epochs 50

Gambar 4 menunjukkan performa model transfer learning ConvNeXt berdasarkan matrik loss selama pelatihan menggunakan data augmentasi. Nilai loss pada data pelatihan (train loss) menurun secara signifikan seiring bertambahnya epoch, menandakan model semakin baik dalam mempelajari pola data latih. Demikian pula, loss validasi (validation loss) menurun secara konsisten dengan laju penurunan yang hampir seimbang dengan train loss, mencerminkan kemampuan generalisasi model yang baik tanpa indikasi overfitting. Grafik ini juga menunjukkan stabilitas performa model setelah epoch ke-20. Secara keseluruhan, model ConvNeXt yang dilatih dengan data augmentasi menunjukkan performa yang memadai untuk mengklasifikasikan suara burung, dengan hasil yang stabil dan konvergen di akhir pelatihan. Temuan ini memberikan

gambaran yang mendalam tentang efisiensi metode transfer learning dalam klasifikasi suara burung di Taman Nasional Way Kambas. Selanjutnya, dilakukan evaluasi matrik dengan hasil ditunjukkan pada gambar dibawah.



Gambar 5. Evaluasi Model

Gambar 5 menampilkan evaluasi model menggunakan *confusion matrix* yang mengevaluasi kinerja model ConvNeXt dalam mengklasifikasikan suara burung di Taman Nasional Way Kambas. Model menunjukkan akurasi tinggi pada kelas seperti *Ninox Scutulata* dan *Orthotomus Ruficeps*, namun terdapat beberapa kesalahan prediksi, seperti *Halcyon Smyrnensis* yang terkadang diklasifikasikan sebagai kelas lain. Kesalahan ini disebabkan oleh kemiripan pola suara antar spesies atau distribusi data yang tidak merata. Matriks ini membantu mengidentifikasi area perbaikan untuk meningkatkan akurasi model.

Dari *confusion matrix* tersebut, diperoleh *classification report* yang terlihat pada Tabel 3 dibawah yang menunjukkan model transfer learning pada data augmentasi dengan epochs 50 memiliki akurasi cukup tinggi sebesar 0.71 serta nilai *precision*, *recall*, dan *f1-score* mendekati 1 yang menunjukkan bahwa model bekerja dengan cukup baik.

Tabel 3. Classification Report

Class	Precision	Recall	f1-score	support
0	0.70	0.47	0.56	15
1	0.85	0.73	0.79	15
2	0.65	0.73	0.69	15
3	0.56	0.60	0.58	15
4	0.57	0.80	0.67	15
5	0.58	0.73	0.65	15
6	0.86	0.80	0.83	15
7	0.80	0.80	0.80	15
8	0.75	0.60	0.67	15
9	0.92	0.80	0.86	15
accuracy			0.71	150
macro avg	0.72	0.71	0.71	150
weighted avg	0.72	0.71	0.71	150

Pada Tabel 3 menunjukkan hasil akurasi model pada masing-masing kelas yang menunjukkan performa yang bervariasi antar kelas. Kelas dengan akurasi tertinggi (*Ninox Scutulata*, *Pitta Sordida*, *Prinia Flaviventris*, dan *Surniculus Lugubris*) memiliki akurasi sebesar 80% yang menunjukkan kemampuan model dalam mengenali fitur-fitur penting dari spesies burung. Akan tetapi, terdapat kelas dengan akurasi rendah seperti *Cacomantis Merulinus* sebesar 46.67% yang menunjukkan bahwa fitur pada kelas ini lebih sulit dipelajari oleh model. Secara keseluruhan, hasil akurasi masing-masing kelas menunjukkan bahwa model memiliki performa yang cukup baik.

Tabel 3.3 Hasil Akurasi Per Class

Name Class	Total Akurasi
<i>Cacomantis Merulinus</i>	46.67%
<i>Culicicapa Ceylonensis</i>	73.33%
<i>Geopelia Striata</i>	73.33%
<i>Halcyon Smyrnensis</i>	60%
<i>Ninox Scutulata</i>	80%
<i>Orthotomus Ruficeps</i>	73.33%
<i>Pitta Sordida</i>	80%
<i>Prinia Flaviventris</i>	80%
<i>Spilopelia Chinensis</i>	60%
<i>Surniculus Lugubris</i>	80%

Setelah, dilakukan evaluasi matriks, selanjutnya dilakukan tahapan menguji model (testing) menggunakan data yang baru. Diperoleh hasil prediksi dari model yang dibangun dengan menggunakan data baru, yang bisa terlihat pada Tabel 3 bahwa tebakan kelasnya sudah benar walaupun akurasi model yang dibangun pada Tabel 4 telah menunjukkan hasil yang cukup baik.

Tabel 4. Hasil Prediksi

Actual	Prediksi	Validasi Klasifikasi
<i>Surniculus Lugubris</i>	<i>Surniculus Lugubris</i>	Benar
<i>Spilopelia Chinensis</i>	<i>Spilopelia Chinensis</i>	Benar
<i>Prinia flaviventris</i>	<i>Prinia flaviventris</i>	Benar
<i>Culicicapa Ceylonensis</i>	<i>Culicicapa Ceylonensis</i>	Benar
<i>Geopelia striata</i>	<i>Geopelia striata</i>	Benar

Setelah diperoleh model terbaik dari beberapa parameter, dilakukan tahapan deployment menggunakan streamlit, agar model bisa melakukan prediksi secara tampilan berbasis website. Tahapan deployment dibangun dengan basis pemrograman python, html serta css. Dan diperoleh tampilan hasil deployment pada gambar.



Gambar 6. Deployment

4 KESIMPULAN

Implementasi dan pengujian model transfer learning arsitektur ConvNeXt menggunakan audio suara burung di Taman Nasional Way Kambas di Provinsi Lampung diperoleh hasil signifikan dapat mengenali dan klasifikasi objek burung. Implementasi proses dengan data augmentasi 50 epochs memiliki peran yang penting dalam model memperoleh performa model dan akurasi yang cukup baik. Dari model dibangun dengan menggunakan beberapa pengaturan parameter, diperoleh bahwa model memiliki akurasi yang cukup baik. Ketika pada pengaturan parameter model yaitu dengan batch size sebesar 32, learning rate 0.0001 dan epochs sebesar 50, diperoleh akurasi model sebesar 0.71 yang menunjukkan model telah cukup baik. Evaluasi model yang cukup tinggi, bahwa model bisa diimplementasikan secara aplikatif seperti dengan mengembangkan aplikasi sistem deteksi klasifikasi suara burung pada kawasan area konservasi seperti cagar alam, suaka margasatwa, taman nasional bahkan geopark.

UCAPAN TERIMAKASIH

Ucapan terimakasih disampaikan kepada dosen pembimbing tugas besar dan seluruh dosen pengampu mata kuliah Deep Learning Program Studi Sains Data Institut Teknologi Sumatera baik

dukungan mental, ilmu dan materi, sehingga model dan penulisan paper penelitian ini dapat diselesaikan dengan tepat waktu dan mendapatkan hasil yang dapat dipertanggungjawabkan.

DAFTAR PUSTAKA

- Abadi, Paul and Chen, Jianmin and Chen, Zhifeng and Davis, Andy and Dean, Jeffrey and Devin, Matthieu and Ghemawat, Sanjay and Irving, Geoffrey and Isard, & Michael and others. (2016). *TensorFlow: A System for Large-Scale Machine Learning*.
- Andyono, Gebyar, Marsono, Djoko, Sadono, Ronggo, Imron, & M Ali. (2018). andyono2018analysis. *The analysis on the stakeholders of conflict mitigation in the Way Kambas National Park, Lampung*, 22, 15-28.
- Austin, Y. S., Irfano, H., Christopher, J. Y., Sukma, L. C., Putra, O. P., Ardhanto, R. I., & Novanto Yudistira. (2024, Desember). Klasifikasi Penyakit Alzheimer Dari Scan Mri Otak Menggunakan Convnext. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 11, 6-7. 10.25126/jtiik.2024118117
- Firmansah, R Arif, Santoso, Handri, Anwar, & Agus. (2023). firmansah2023transfer. *Transfer Learning Implementation on Image Recognition of Indonesian Traditional Houses*, 4, 1469--1478.
- Iwandini, I. (2023). Analisa Sentimen Pengguna Transportasi Jakarta Terhadap Transjakarta Menggunakan Metode Naives Bayes dan K-Nearest Neighbor. *Journal of Information System Research (JOSH)*. 10.47065/josh.v4i2.2937
- Michael and others, Geoffrey and Isard, Sanjay and Irving, Matthieu and Ghemawat, Jeffrey and Devin, Andy and Dean, Zhifeng and Davis, Jianmin and Chen, Paul and Chen, & {Abadi. (2016). *TensorFlow: a system for large-scale machine learning*.
- Outlwile, Whata, Albert, Olusanya, Micheal, Mhlongo, & Siyabonga. (2024). mmileng2024application. *Application of ConvNeXt with Transfer Learning and Data Augmentation for Malaria Parasite Detection in Resource-Limited Settings Using Microscopic Images*, 2024-10.
- Pedregosa, & Fabian. (2011). pedregosa2011scikit. *Scikit-learn: Machine learning in python Fabian*, 12, 2825.
- Rafliansyah, Royan Hisyam and Rahmat, Basuki and Putra, & Chrystia Aji. (2024). rafliansyah2024klasifikasi. *Klasifikasi Suara Instrumen Musik Tiup Menggunakan Metode Convolutional Neural Network*, 2, 01-09.
- Simonyan, Karen, Zisserman, & Andrew. (2014). simonyan2014very. *Very deep convolutional networks for large-scale image recognition*.
- Toyib, Mochammad and Pratama, Tegar Decky Kurniawan and Aqil, & Ibnu. (2024). toyib2024penerapan. *Penerapan Algoritma CNN Untuk Mendeteksi Tulisan Tangan Angka Romawi dengan Augmentasi Data*, 2, 108--120.
- Wijaya, A. E., Windra Swastika, & Kelana, O. H. (2021, September). Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan Pneumonia Pada Citra X-Ray. *SAINSBERTEK Jurnal Ilmiah Sains & Teknologi*, 2 No. 1-T.INFORMATIKA, 2.
<https://sainsbertek.machung.ac.id/index.php/sbtek/article/download/125/74>
- Zhang, & Zijun. (2018). zhang2018improved. *Improved adam optimizer for deep neural networks*, 1-2.