

Klasifikasi Daun Teh Klon Seri GMB Menggunakan Convolutional Neural Network dengan Arsitektur VGG16 dan Xception

Alphi Rinaldi Nalendra Mukti¹, Putri Taqwa Prasetyaningrum²

^{1,2}Program Studi Sistem Informasi, Universitas Mercu Buana Yogyakarta, Yogyakarta, Indonesia
Email: ¹201210090@student.mercubuana-yogya.ac.id, ²putri@mercubuana-yogya.ac.id

Abstrak

Indonesia memiliki tingkat konsumsi teh tertinggi di dunia, di mana kualitas daun teh sangat bergantung pada lokasi tumbuhnya. Untuk mengidentifikasi jenis teh, sistem otomatisasi dengan pengolahan citra digital digunakan. Penelitian ini membandingkan dua arsitektur model yaitu dengan augmentasi data dan tanpa augmentasi dalam mengklasifikasikan daun teh klon seri GMB 1-5. Hasil penelitian menunjukkan bahwa model CNN tanpa augmentasi memberikan akurasi yang lebih tinggi dibandingkan dengan yang menerapkan augmentasi. Secara spesifik, model Xception tanpa augmentasi mencapai akurasi 98%, sedangkan VGG16 tanpa augmentasi mencapai 95%. Sebaliknya, model dengan augmentasi memperoleh akurasi 92% untuk Xception dan 94% untuk VGG16. Temuan ini menunjukkan bahwa, dalam konteks dataset terbatas, model tanpa augmentasi cenderung lebih akurat karena menghindari overfitting yang sering terjadi pada dataset kecil.

Kata Kunci: Augmentasi, Klasifikasi, CNN, Teh, VGG16, Xception

Abstract

Indonesia has the highest tea consumption rate in the world, where the quality of tea leaves is heavily dependent on their growing location. To identify tea types, an automation system using digital image processing is employed. This study compares two model architectures: one with data augmentation and one without, in classifying GMB 1-5 series tea leaves. The results indicate that the CNN model without augmentation achieved higher accuracy compared to the one with augmentation. Specifically, the Xception model without augmentation reached an accuracy of 98%, while VGG16 without augmentation achieved 95%. In contrast, the model with augmentation achieved 92% accuracy for Xception and 94% for VGG16. These findings suggest that, in the context of a limited dataset, models without augmentation tend to be more accurate as they avoid overfitting commonly encountered with small datasets.

Keywords: Augmentation, classification, CNN, Tea, VGG16, Xception

1. PENDAHULUAN

Indonesia dikenal sebagai negara dengan konsumsi teh tertinggi di dunia, membuat teh menjadi bagian penting dan menjadi budaya masyarakatnya. Kualitas daun teh menjadi sangat penting karena berpengaruh langsung pada jenis teh yang dihasilkan, yang dipengaruhi oleh lokasi tempat tumbuhnya. Pesatnya kemajuan di era saat ini terjadi seiring dengan berkembangnya teknologi [1]. Teknologi telah merambah berbagai sektor, termasuk sektor perkebunan.

Mereka yang terlibat dalam industri perkebunan perlu mampu menyesuaikan diri dan mengikuti perkembangan teknologi ini. Dalam upaya mengidentifikasi jenis teh yang berkembang, digunakanlah sistem otomatisasi dengan teknologi pengolahan citra digital. Namun, tantangan muncul karena keterbatasan data foto teh yang tersedia, sehingga perlu dilakukan augmentasi data untuk memperkaya variasi dataset.

Augmentasi pada Convolutional Neural Network adalah metode yang mampu menambah jumlah. Biasanya, data di-augmentasi melalui transformasi data, yaitu menciptakan salinan data yang ada tanpa mengubah label pada setiap bagian data tersebut. Cropping (memotong) dan flipping (membalik) adalah dua transformasi yang biasa dilakukan dalam proses augmentasi [2].

Melakukan perbandingan akurasi metode Convolutional Neural Network adalah tujuan penelitian ini yaitu antara arsitektur yang melewati proses augmentasi data dan yang tidak pada data daun teh klon seri GMB 1-5. Daun teh dari varietas GMB memiliki kelebihan, seperti kemampuan perbanyak vegetatif, hasil yang konsisten dan tinggi, adaptasi yang luas terhadap berbagai kondisi lingkungan pertanian teh di Indonesia, kandungan antioksidan (katekin) yang sangat tinggi, ketahanan terhadap penyakit seperti opt dan cacar, serta potensi kualitas dan rasa yang lebih enak dari teh biasa [3].

CNN adalah jenis arsitektur deep learning yang berfungsi dengan menerima input dalam bentuk gambar [4]. Dalam CNN terdapat beberapa lapisan, diantaranya Fully connected layer, Convolutional layer, dan Pooling layer. Dalam tahap convolution layer, filter digeser (convolve) ke setiap posisi yang mungkin pada gambar. Hasilnya adalah activation map, di mana nilai di setiap titik gambar didapat dari dot product antara filter yang digunakan dengan bagian gambar tersebut [5]. Input tersebut akan dilatih menggunakan arsitektur CNN sehingga menghasilkan output yang mampu mengenali objek yang diberikan. Melalui pengujian yang dilakukan, nantinya diperoleh informasi tentang tingkat akurasi masing-masing model, yang mana yang lebih unggul di antara keduanya.

Berbagai penelitian yang memanfaatkan teknologi pengolahan citra digital telah dilakukan. Salah satunya adalah penelitian oleh Pradnya yang menggunakan Convolutional Neural Network dengan membahas analisis dampak augmentasi data pada klasifikasi bumbu dapur. Dalam penelitian ini, digunakan metode Convolutional Neural Network dengan arsitektur yang telah dilatih sebelumnya (pretrained) dan metode confusion matrix untuk mengevaluasi hasilnya. Hasil dari studi ini mencakup pengembangan model untuk mengklasifikasikan bumbu dapur. Saat diuji, CNN tanpa augmentasi hanya mencapai tingkat akurasi sebesar 54%, sementara CNN dengan augmentasi mencapai tingkat akurasi sebesar 80%. [6].


Ibrahim meneliti klasifikasi gambar daun teh klon seri GMB dengan memanfaatkan Convolutional Neural Network (CNN) yang menggunakan arsitektur ResNet, VGGNet, dan AlexNet. Dalam penelitian ini, dilakukan pre-processing dengan merubah ukuran dan augmentasi data, dimana jumlah dataset yang awalnya 1100 menjadi 2860 setelah proses pra-pemrosesan. Pengujian yang optimal dilakukan dengan menggunakan dataset yang telah mengalami augmentasi, terdiri dari 220 data testing dan 2640 data training. Hasil terbaik ada pada akurasi ResNet sebesar 97.80%, VGGNet sebesar 95.45%, dan AlexNet sebesar 98.18% [7].

Rikendry meneliti perbandingan antara arsitektur VGG16 dan RESNET50 untuk mengenali tulisan tangan aksara Lampung. Penelitian ini menggunakan 20 sampel gambar tulisan tangan aksara lampung. Pra-pemrosesan yang digunakan melibatkan teknik Cropping dan augmentasi citra. Hasil dari studi menunjukkan bahwa model model ResNet50 mencapai akurasi 65%. Sebaliknya, VGG16 menghasilkan akurasi sebesar 91% dengan waktu pelatihan yang lebih cepat [8].

Selanjutnya ada Jaelani yang melakukan penelitian yang berkaitan dengan Desain Aplikasi untuk Klasifikasi Daun Teh Klon GAMBUNG (GMB) dengan menggunakan Algoritma Convolutional Neural Network. Studi ini menggunakan dua jenis dataset, dengan dataset pertama mengandung 1136 foto dan dataset kedua mengandung 830 foto. parameter yang digunakan diantaranya algoritma optimisasi bernama adam, learning rate sebesar 0,0001, epoch berjumlah 100, dan 204 neuron. Hasil uji coba menunjukkan tingkat akurasi sekitar 60%, sementara pengujian aplikasi memperlihatkan akurasi sebesar 25% [9]. Kelas tidak seimbang adalah situasi dimana jumlah instance kelas minoritas jauh lebih sedikit dibandingkan kelas mayoritas, sehingga dapat menurunkan kinerja algoritma klasifikasi yang umumnya bekerja lebih baik pada distribusi kelas yang seimbang [10]. Sehingga, dibutuhkan penelitian untuk menyelesaikan permasalahan ini dengan menggunakan teknik data mining [11].

2. METODE PENELITIAN


Penelitian ini melibatkan beberapa langkah metodologis. Tahap-tahap yang digunakan untuk melakukan klasifikasi daun teh klon seri GMB dengan menggunakan CNN tanpa mengaplikasikan augmentasi dapat dilihat dalam ilustrasi Gambar 1.



Gambar 1. Jalan Penelitian Tanpa Augmentasi Data

Gambar 1 menunjukkan proses dimulai dengan pengumpulan data, di mana data mentah dari daun teh klon seri GMB dikumpulkan. Data mentah ini kemudian menjalani tahap preprocessing, yang melibatkan berbagai teknik untuk membersihkan dan menyiapkan data agar sesuai untuk pemrosesan lebih lanjut. Setelah preprocessing, data hasil preprocessing dibentuk menjadi dataset yang

siap digunakan dalam pelatihan model. Selanjutnya, perancangan model arsitektur CNN dilakukan untuk menentukan struktur dan parameter yang tepat untuk tugas klasifikasi ini. Jika diperlukan, model pretrained bisa digunakan sebagai dasar untuk meningkatkan kinerja. Model yang telah dirancang dan dilatih kemudian diuji untuk menilai kinerjanya. Jika hasil pengujian menunjukkan bahwa model berfungsi dengan baik, model tersebut diimplementasikan ke dalam sebuah website untuk digunakan secara praktis. Tahap-tahap yang digunakan untuk melakukan klasifikasi daun teh klon seri GMB dengan menggunakan CNN tanpa mengaplikasikan augmentasi dapat dilihat dalam ilustrasi Gambar 2.



Gambar 2. Jalan Penelitian Menggunakan Augmentasi Data

Proses ini mirip dengan metode tanpa augmentasi, namun setelah tahap preprocessing, dilakukan augmentasi data. Berbagai teknik seperti rotasi, flipping, dan penyesuaian warna diterapkan untuk meningkatkan variasi dalam dataset. Hasil dari augmentasi ini menghasilkan dataset akhir yang siap digunakan untuk melatih model.

2.1. Pengumpulan Data

Dataset yang dipergunakan diperoleh dari platform Kaggle.

2.2. Preprocessing

Preprocessing gambar dilakukan dengan normalisasi menggunakan pustaka Keras dan teknik rescale, yang mengubah skala gambar $[0, 255]$ menjadi $[0, 1]$. Langkah ini membantu memperkecil data loss dan menambah akurasi ketika dataset dilatih. Sedangkan dalam augmentasi, digunakan pustaka Image Data Generator yang ada pada Keras, yang meningkatkan jumlah data dengan mengubah gambar sehingga model dapat mengidentifikasi variasi dalam data sebagai data yang berbeda. Augmentasi ini dapat dilakukan saat jumlah dataset terbatas, karena membantu meningkatkan kinerja model dan juga mengurangi risiko underfitting dan overfitting. [12].


Dalam penelitian ini, data dikumpulkan dan dikelompokkan menjadi enam kelas, yaitu GMB1, GMB2, GMB3, GMB4, GMB5, dan BukanGMB. Selanjutnya, data dibagi menjadi data testing, validation, dan training. Setiap data akan diberi label setelah data selesai dibagi menjadi beberapa jenis. Data dikelompokkan sesuai dengan kelasnya. Data awal yang berhasil dikumpulkan berasal dari kaggle berjumlah 2.434 data. Kemudian dibagi menjadi data training berjumlah 2.190 data, data validation berjumlah 122 data dan data testing berjumlah 122 data. Preprocessing dalam sistem ini mencakup empat model arsitektur yang berbeda, yaitu VGG16 dan Xception yang melibatkan augmentasi dalam prosesnya dan yang tidak, seperti yang terlihat di Gambar 1 dan Gambar 2. Augmentasi yang digunakan yaitu rotasi 15 derajat, rescale 1./255, dan digeser acak secara horizontal dan vertikal 10%, transformasi shear 20%, zoom acak 20%, diflipping secara horizontal.

2.3. Training

CNN ditraining untuk mencapai nilai akurasi yang baik dalam klasifikasi [13]. Training dilakukan pada gambar-gambar sehingga menghasilkan sebuah model yang akan disimpan untuk kemudian digunakan dalam tahap pengujian. Proses pembuatan model ini melatih data citra latih untuk mengenali objek dan mengelompokkannya berdasarkan kelasnya. Penelitian ini memanfaatkan CNN sebagai metode utama dalam pengklasifikasian serta menggunakan arsitektur VGG16 dan Xception untuk mengoptimalkan proses klasifikasi.

Secara keseluruhan, proses pelatihan pada VGG16 dapat disesuaikan atau disesuaikan dengan kebutuhan spesifik. VGG16 adalah jenis model CNN yang

menggunakan lapisan konvolusi dengan filter berukuran kecil, yaitu 3×3 . Dengan begitu model CNN akan lebih presisi jika dibandingkan dengan model CNN sebelumnya. Struktur dari model VGG16 terdiri dari total 19 layer, di mana terdapat 16 layer konvolusi dan 3 layer yang sepenuhnya terhubung (fully connected) [8]. Sebagai contoh, input citra pada model CNN dapat menggunakan ukuran $128 \times 128 \times 3$, seperti yang ditunjukkan dalam penelitian ini. Citra masukan akan diproses melalui lapisan-lapisan konvolusi dan pooling VGG16. Model VGG16 yang digunakan memiliki 16 lapisan konvolusi dengan jumlah filter yang berbeda seperti pada Gambar 3. Hasil dari lapisan pooling kemudian diubah menjadi vektor melalui proses flatten, yang selanjutnya diproses oleh beberapa lapisan fully connected untuk menghasilkan output klasifikasi sesuai dengan jumlah kelas.




Gambar 3. Tahapan training system VGG16

Xception adalah sebuah arsitektur CNN yang berdasar kepada pembagian lapisan konvolusi. Ini menghasilkan pemisahan yang jelas antara korelasi lintas saluran dan korelasi spasial pada peta fitur CNN. Xception merupakan penyempurnaan dari arsitektur Inception. Terdapat 36 lapisan convolutional dalam arsitektur Xception yang membentuk dasar ekstraksi fitur dari jaringan [14]. Pada penelitian ini, Model arsitektur Xception menggunakan gambar berukuran 128×128 piksel dengan 3 saluran warna (RGB) dimasukkan ke dalam model. Citra masukan

kemudian diproses melalui beberapa blok konvolusi. Pada Konvolusi Blok 1, gambar diproses menggunakan 32 filter ukuran 3x3, diikuti oleh aktivasi ReLU, normalisasi batch, dan pooling maksimal untuk menghasilkan output berukuran (63, 63, 32). Blok konvolusi berikutnya (Blok 2) menggunakan 64 filter ukuran 3x3 dengan proses yang sama, menghasilkan output (31, 31, 64). Proses ini berlanjut ke Blok 3 dengan 128 filter untuk menghasilkan output (15, 15, 128), Blok 4 dengan 256 filter untuk output (7, 7, 256), dan Blok 5 dengan 728 filter untuk output (3, 3, 728).

Setelah itu, gambar diproses melalui beberapa blok separable convolution. Blok 6 hingga Blok 9 menggunakan 728 filter ukuran 3x3, ReLU, dan normalisasi batch untuk menghasilkan output (3, 3, 728). Pada Blok 10, operasi separable convolution yang sama diikuti oleh pooling maksimal menghasilkan output (1, 1, 728). Hasil dari lapisan pooling ini kemudian diubah menjadi vektor satu dimensi melalui operasi Global Average Pooling. Vektor tersebut kemudian diproses oleh lapisan Dense dengan 1000 neuron dan aktivasi softmax untuk menghasilkan output prediksi kelas gambar.



Gambar 4 Tahapan training system Xception

2.4. Perencanaan Tes

Pada tahap perencanaan tes, terdapat empat kondisi yang akan dijalankan saat pengujian sistem, diantaranya:

- 1) Kondisi pertama, menggunakan model arsitektur VGG16 dengan augmentasi data
- 2) Kondisi kedua, menggunakan model arsitektur Xception dengan augmentasi data
- 3) Kondisi ketiga, menggunakan model arsitektur VGG16 tanpa augmentasi data
- 4) Kondisi keempat, menggunakan model arsitektur Xception tanpa augmentasi data

2.5. Kinerja Sistem

Hasil kinerja sistem yang telah dirancang akan dinilai berdasarkan sejauh mana kinerjanya sesuai dengan standar performa yang ditetapkan. Selain itu, keunggulan dan kelemahan sistem yang telah dirancang akan dievaluasi berdasarkan parameter-parameter seperti *accuracy*, dan *precision*. *Accuracy* adalah ukuran kebenaran data dalam sebuah studi yang mencerminkan tingkat keakuratan hasil. *Precision* adalah metrik yang mengukur keberhasilan data dengan membandingkan jumlah prediksi yang tepat dengan total prediksi yang dibuat. *Loss* merupakan indikator yang menunjukkan seberapa tidak akuratnya sistem dalam mengenali objek.

3. HASIL DAN PEMBAHASAN

Uji coba yang sudah dibuat dengan CNN serta menggunakan arsitektur VGG16 dan Xception dalam melakukan klasifikasi daun teh klon seri GMB terdiri dari enam kelas, yaitu GMB1, GMB2, GMB3, GMB4, GMB5, dan BukanGMB. Sistem pengujian dibuat dengan empat perbandingan, yaitu menggunakan model VGG16 dengan dan tanpa augmentasi data, serta model Xception dengan dan tanpa augmentasi data, dengan epoch sebanyak 50 dan tingkat pembelajaran (learning rate) sebesar 0,001 untuk setiap skenario tersebut.

3.1. Uji Coba Menggunakan VGG16 dan Augmentasi Data



Gambar 5. Grafik Accuracy dan Loss pada VGG16 menggunakan augmentasi data

Berdasarkan grafik diatas, menunjukkan bahwa nilai akurasi data uji tertinggi tercapai pada epoch ke-33. Epoch merupakan satu siklus lengkap di mana semua data input telah diteruskan melalui semua lapisan jaringan neural baik forward propagation (penerusan input melalui lapisan-lapisan jaringan) maupun backward propagation (penyesuaian bobot berdasarkan kesalahan prediksi) [15]. Epoch berfungsi sebagai satuan pengukuran yang membantu mengatur berapa kali seluruh dataset akan digunakan selama pelatihan. Untuk loss data testing pada Gambar 5 turun dan stabil mendekati nol, mencapai nilai akhir sebesar 0.1370.

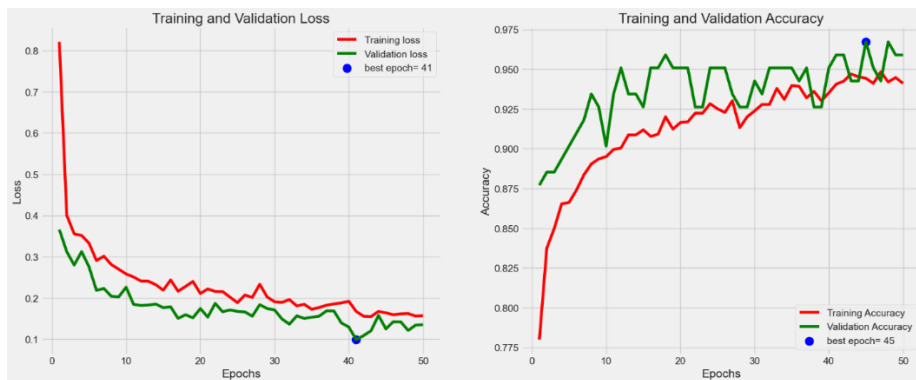
Table 1 Hasil klasifikasi menggunakan model arsitektur VGG16 dan augmentasi data

Class	Precision	Recall	F1-Score	Support
Bukan_GMB	1.00	1.00	1.00	81
GMB_01	0.88	0.70	0.78	10
GMB_02	0.67	0.80	0.73	5
GMB_03	1.00	0.67	0.80	9
GMB_04	0.86	1.00	0.92	6
GMB_05	0.79	1.00	0.88	11
Accuracy			0.94	122
Macro AVG	0.86	0.86	0.85	122
Weighted AVG	0.95	0.94	0.94	122

Tabel 1 menunjukkan bahwa sistem klasifikasi yang telah diuji memiliki tingkat ketepatan (precision), sensitivitas (recall), dan skor f1 (f1-score) yang bervariasi untuk masing-masing kelas yang diujikan. Kelas Bukan_GMB menunjukkan performa yang sangat baik dengan nilai ketepatan, sensitivitas, dan skor f1 yang sempurna (1.00), sementara kelas lainnya memiliki nilai yang beragam.

Dibandingkan dengan kelas lainnya, kelas GMB_01, GMB_02, dan GMB_03 memiliki kinerja yang kurang baik. Secara keseluruhan, sistem mencapai tingkat akurasi (accuracy) sebesar 0.94, yang menunjukkan kinerja yang baik dalam mengklasifikasikan data.

3.2. Uji Coba Menggunakan Xception dan Augmentasi Data



Gambar 6. Grafik Accuracy dan Loss pada Xception menggunakan augmentasi data

Berdasarkan Gambar 6, menunjukkan bahwa nilai akurasi data uji tertinggi tercapai pada epoch ke-45, Sementara kerugian (loss) pada pengujian data menurun dan tetap stabil hingga mendekati nol, mencapai nilai akhir sebesar 0.1901.

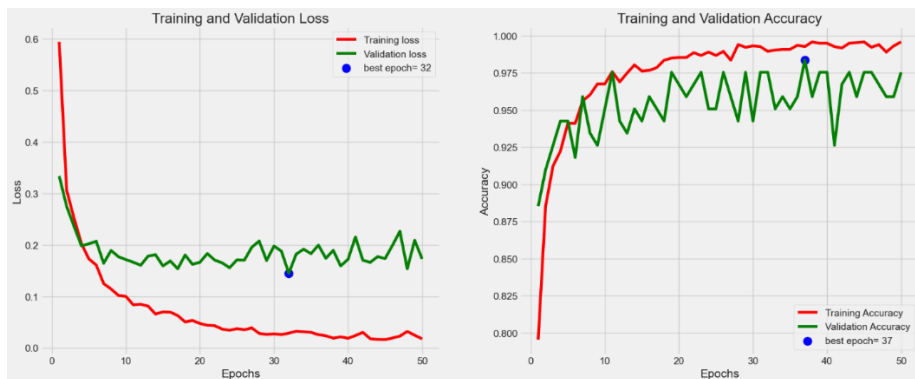
Table 2. Hasil klasifikasi menggunakan model arsitektur Xception dan augmentasi data

Class	Precision	Recall	F1-Score	Support
Bukan_GMB	1.00	1.00	1.00	81
GMB_01	0.86	0.60	0.71	10
GMB_02	0.50	1.00	0.67	5
GMB_03	1.00	0.67	0.80	9
GMB_04	0.60	1.00	0.75	6
GMB_05	1.00	0.73	0.84	11
Accuracy			0.92	122
Macro AVG	0.83	0.83	0.79	122
Weighted AVG	0.95	0.92	0.92	122

Berdasarkan Tabel 2, dapat diambil kesimpulan bahwa sistem klasifikasi menunjukkan kinerja yang memuaskan dimana tingkat presisi (precision), sensitivitas (recall), dan skor f1 (f1-score) mendapat skor cukup tinggi secara

keseluruhan. Kelas Bukan_GMB menampilkan *accuracy*, *precision*, dan *skor f1* yang sempurna (1.00), menunjukkan kemampuan sistem untuk mengenali kelas tersebut dengan akurat. Sementara itu, kelas lainnya juga menunjukkan performa yang relatif baik, meskipun ada beberapa kelas seperti GMB_01 dan GMB_04 yang memiliki tingkat ketepatan dan sensitivitas yang lebih rendah. Akurasi keseluruhan sistem mencapai 0.92.

3.3. Uji Coba Menggunakan VGG16 tanpa Augmentasi Data



Gambar 7. Grafik Accuracy dan Loss pada VGG16 tanpa augmentasi data

Gambar 7 menampilkan nilai akurasi data uji tertinggi tercapai pada epoch ke-37, Sementara kerugian (loss) pada pengujian data menurun dan konstan menuju nilai nol, mencapai nilai sebesar 0.1255.

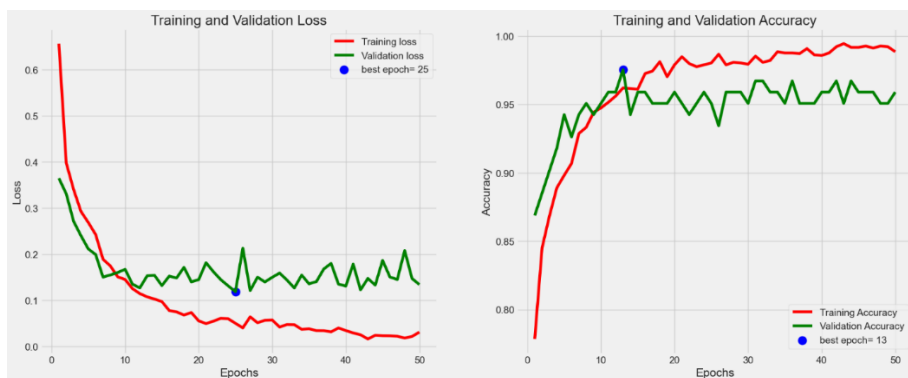
Table 3. Hasil klasifikasi menggunakan model arsitektur VGG16 tanpa augmentasi data

Class	Precision	Recall	F1-Score	Support
Bukan_GMB	1.00	1.00	1.00	81
GMB_01	0.83	0.50	0.62	10
GMB_02	0.62	1.00	0.77	5
GMB_03	0.89	0.89	0.89	9
GMB_04	0.86	1.00	0.92	6
GMB_05	1.00	1.00	1.00	11
Accuracy			0.95	122
Macro AVG	0.87	0.90	0.87	122
Weighted AVG	0.96	0.95	0.95	122

Pada kondisi ketiga yang menggunakan model arsitektur VGG16 tanpa menggunakan augmentasi data menunjukkan performa model dengan tingkat

akurasi sebesar 95%. Berdasarkan nilai presisi, sensitivitas (recall), dan skor f1 untuk setiap kelas, terlihat bahwa kelas "Bukan_GMB" menunjukkan hasil yang sangat positif dengan nilai presisi, sensitivitas, dan skor f1 yang mencapai 1.00. Artinya, model mampu mengidentifikasi kelas tersebut dengan sangat baik. Namun, terdapat beberapa kelas lain seperti "GMB_01" dan "GMB_02" yang memiliki nilai recall yang lebih rendah, mengindikasikan bahwa model memiliki kesulitan dalam mengenali kelas-kelas tersebut. Secara keseluruhan, nilai rata-rata f1-score, precision, dan recall pada setiap kelas menunjukkan performa model yang bagus, dengan nilai f1-score tertinggi pada kelas "GMB_05" sebesar 1.00.

3.4. Uji Coba Menggunakan Xception tanpa Augmentasi Data



Gambar 8. Grafik Accuracy dan Loss pada Xception tanpa augmentasi data

Pada grafik di atas menunjukkan bahwa nilai akurasi data uji tertinggi tercapai pada epoch ke-13 Sementara kerugian (loss) pada pengujian data menurun dan tetap stabil hingga mendekati nol, mencapai nilai akhir sebesar 0.0766.

Table 4. Hasil klasifikasi menggunakan model arsitektur Xception tanpa augmentasi data

Class	Precision	Recall	F1-Score	Support
Bukan_GMB	1.00	1.00	1.00	81
GMB_01	0.89	0.80	0.84	10
GMB_02	1.00	1.00	1.00	5
GMB_03	1.00	0.89	0.94	9
GMB_04	0.86	1.00	0.92	6
GMB_05	0.92	1.00	0.96	11
Accuracy			0.98	122
Macro AVG	0.94	0.95	0.94	122
Weighted AVG	0.98	0.98	0.98	122

Hasil laporan pada Tabel 4 menunjukkan performa model dengan tingkat akurasi sebesar 98%. Dari nilai f1-score, precision, dan recall disetiap kelas, terlihat bahwa kelas "Bukan_GMB" memiliki hasil sempurna dengan nilai f1-score, precision, dan recall masing-masing sebesar 1.00. Kelas "GMB_01" memperoleh nilai f1-score sebesar 0.84 dengan precision 0.89 dan recall 0.80, menunjukkan sedikit penurunan dalam pengenalan dibandingkan kelas lainnya. Kelas "GMB_02" dan "GMB_03" masing-masing memiliki nilai f1-score 1.00 dan 0.94, dengan recall dan precision yang sangat baik. Kelas "GMB_04" dan "GMB_05" juga menunjukkan performa yang sangat baik dengan nilai f1-score 0.92 dan 0.96. Secara keseluruhan, nilai rata-rata f1-score, precision, dan recall untuk semua kelas menunjukkan performa model yang sangat baik, dengan nilai rata-rata tertimbang masing-masing sebesar 0.98 untuk f1-score, precision, dan recall. Kinerjanya yang unggul dalam semua metrik ini menunjukkan bahwa model dapat mengklasifikasikan data dengan tingkat akurasi yang sangat tinggi.

3.5. Pembahasan

Dalam uji coba yang dilakukan, model CNN dengan arsitektur VGG16 dan Xception digunakan untuk mengklasifikasikan daun teh klon seri GMB ke dalam enam kelas: GMB1, GMB2, GMB3, GMB4, GMB5, dan BukanGMB. Sistem pengujian mencakup empat perbandingan: VGG16 dengan dan tanpa augmentasi data, serta Xception dengan dan tanpa augmentasi data, masing-masing dengan 50 epoch dan tingkat pembelajaran 0,001.

Untuk model VGG16 dengan augmentasi data, akurasi tertinggi pada data uji tercapai pada epoch ke-33. Nilai kerugian (loss) stabil dan mendekati nol, dengan nilai akhir sebesar 0,1370. Hasil klasifikasi menunjukkan bahwa kelas BukanGMB mencapai nilai presisi, recall, dan F1-score sempurna yaitu 1,00. Kelas lainnya menunjukkan performa yang bervariasi, dengan GMB_01, GMB_02, dan GMB_03 memiliki nilai yang lebih rendah. Secara keseluruhan, model ini mencapai akurasi sebesar 0,94, yang mencerminkan kinerja yang baik dalam mengklasifikasikan data.

Pada model Xception dengan augmentasi data, akurasi tertinggi pada data uji tercapai pada epoch ke-45, dengan nilai kerugian menurun hingga 0,1901 dan stabil mendekati nol. Hasil klasifikasi menunjukkan kinerja yang memuaskan secara keseluruhan, dengan kelas BukanGMB memperoleh nilai 1,00 di semua metrik. Kelas-kelas lain, seperti GMB_01 dan GMB_04, menunjukkan presisi dan recall yang lebih rendah. Sistem ini mencapai akurasi keseluruhan 0,92, menunjukkan performa yang memadai dengan augmentasi data.

Untuk model VGG16 tanpa augmentasi data, akurasi tertinggi dicapai pada epoch ke-37, dengan nilai kerugian sebesar 0,1255. Model ini menunjukkan performa yang sangat baik untuk kelas BukanGMB, dengan nilai sempurna di semua metrik. Namun, kelas-kelas seperti GMB_01 dan GMB_02 menunjukkan nilai recall yang lebih rendah, menandakan tantangan dalam mengklasifikasikan kelas-kelas tersebut dengan akurat. Akurasi keseluruhan mencapai 0,95, dengan kinerja tinggi di sebagian besar metrik, terutama pada kelas GMB_05.

Model Xception tanpa augmentasi data mencapai akurasi tertinggi pada epoch ke-13, dengan nilai kerugian akhir sebesar 0,0766. Hasil klasifikasi menunjukkan performa yang sangat baik, dengan nilai sempurna untuk kelas BukanGMB dan nilai F1-score yang tinggi untuk kelas-kelas lain seperti GMB_02 dan GMB_03. Model ini mencapai akurasi keseluruhan 0,98, menunjukkan kinerja yang unggul di semua metrik dan menunjukkan tingkat akurasi klasifikasi yang sangat tinggi.

Secara keseluruhan, uji coba ini menunjukkan bahwa model VGG16 dan Xception tanpa augmentasi data memberikan performa yang lebih baik dibandingkan dengan model yang menggunakan augmentasi data, terutama dalam skenario dengan dataset terbatas.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa dalam klasifikasi daun teh klon seri GMB menggunakan arsitektur CNN VGG16 dan Xception, model tanpa augmentasi data secara umum memberikan performa yang lebih baik dibandingkan dengan model yang menerapkan augmentasi data. Hasil uji coba menunjukkan bahwa model Xception tanpa augmentasi mencapai akurasi tertinggi sebesar 98%, diikuti oleh VGG16 tanpa augmentasi dengan akurasi 95%. Sebaliknya, model dengan augmentasi data, baik VGG16 maupun Xception, menunjukkan akurasi yang lebih rendah, yaitu 94% dan 92% secara berturut-turut.

Model tanpa augmentasi data lebih efektif dalam konteks dataset terbatas, di mana augmentasi dapat menyebabkan overfitting dengan membuat model terlalu menyesuaikan diri dengan data pelatihan dan tidak mampu beradaptasi dengan data baru secara efektif. Secara khusus, kelas BukanGMB menunjukkan hasil sempurna di semua model, sedangkan kelas-kelas lainnya menunjukkan performa yang bervariasi. Hasil ini menekankan pentingnya memilih strategi yang tepat berdasarkan karakteristik dataset dan arsitektur model untuk mencapai hasil klasifikasi yang optimal.

REFERENSI

- [1] D. Effendi and D. A. Wahidy, "Pemanfaatan Teknologi Dalam Proses Pembelajaran Menuju Pembelajaran Abad 21," *Prosiding Seminar Nasional Pendidikan Program Pascasarjana Universitas Pgri Palembang*, pp. 125–129, 2019.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun ACM*, vol. 60, no. 6, pp. 84–90, 2017, doi: 10.1145/3065386.
- [3] Bambang Sriyadi, "Analisis kemiripan morfologi daun beberapa klon teh generasi pertama Analysis of leaves morphology similarity of several first-generation tea clones Bambang Sriyadi," *Jurnal Penelitian Teh dan Kina*, vol. 15, no. 2, pp. 51–58, 2012.
- [4] Rima Dias Ramadhani, A. Nur Aziz Thohari, C. Kartiko, A. Junaidi, T. Ginanjar Laksana, and N. Alim Setya Nugraha, "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 312–318, 2021, doi: 10.29207/resti.v5i2.2754.
- [5] Y. B. E. Purba, N. F. Saragih, A. P. Silalahi, and ..., "Perancangan Alat Pendeteksi Kematangan Buah Nanas Dengan Menggunakan Mikrokontroler Dengan Metode Convolutional Neural Network (CNN)," *Jurnal Ilmiah Teknik ...*, vol. 2, no. 1, pp. 13–21, 2022.
- [6] W. M. Pradnya D and A. P. Kusumaningtyas, "Analisis Pengaruh Data Augmentasi Pada Klasifikasi Bumbu Dapur Menggunakan Convolutional Neural Network," *Jurnal Media Informatika Budidarma*, vol. 6, no. 4, p. 2022, 2022, doi: 10.30865/mib.v6i4.4201.
- [7] N. Ibrahim *et al.*, "Jurnal Sains Teh dan Kina Klasifikasi Citra Klon Teh Seri GMB Menggunakan Convolutional Neural Network (CNN) dengan Arsitektur Resnet, Vgg-net, dan Alexnet Classification of Gmb Series Tea Clone Image Using Convolutional Neural Network (CNN) with Resnet," *Jurnal Sains Teh dan Kina*, vol. 1, no. 2, 2022.
- [8] R. Rikendry and A. Maharil, "Perbandingan Arsitektur Vgg16 Dan Resnet50 Untuk Rekognisi Tulisan Tangan Aksara Lampung," *Jurnal Informatika dan Rekayasa Perangkat Lunak*, vol. 3, no. 2, pp. 236–243, 2022, doi: 10.33365/jatika.v3i2.2030.
- [9] A. A. Jaelani, F. Y. Supratman, and N. Ibrahim, "Perancangan Aplikasi Untuk Klasifikasi Klon Daun Teh Seri Gambung (GMB) Menggunakan Algoritma Convolutional Neural Network," *eProceedings of Engineering*, vol. 7, no. 2, pp. 2920–2928, 2020.
- [10] I. Pratama, Y. Pristyanto, and P. T. Prasetyaningrum, "Imbalanced Class handling and Classification on Educational Dataset," *ICOIACT 2021 - 4th International Conference on Information and Communications Technology*:

- The Role of AI in Health and Social Revolution in Turbulence Era*, pp. 180–185, 2021, doi: 10.1109/ICOIACT53268.2021.9563968.
- [11] I. Pratama and P. T. Prasetyaningrum, "Pemetaan Profil Mahasiswa Untuk Peningkatan Strategi Promosi Perguruan Tinggi Menggunakan Predictive Apriori," *Jurnal Eksplora Informatika*, vol. 10, no. 2, pp. 159–166, 2021, doi: 10.30864/eksplora.v10i2.505.
- [12] M. Rahman and A. Pambudi, "Identifikasi Citra Daun Selada Dalam Menentukan Kualitas Tanaman Menggunakan Algoritma Convolutional Neural Network (Cnn)," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, pp. 851–858, 2023.
- [13] I. W. Suartika E. P., "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101," *Jurnal Teknik ITS*, vol. 5, no. 1, p. 76, 2016.
- [14] S. Roopashree and J. Anitha, "DeepHerb: A Vision Based System for Medicinal Plants Using Xception Features," *IEEE Access*, vol. 9, pp. 135927–135941, 2021, doi: 10.1109/ACCESS.2021.3116207.
- [15] N. Hardi and J. Sundari, "Pengenalan Telapak Tangan Menggunakan Convolutionall Neural Network (CNN)," *Reputasi: Jurnal Rekayasa Perangkat Lunak*, vol. 4, no. 1, pp. 10–15, 2023, doi: 10.31294/reputasi.v4i1.1951.