

Evaluasi Kinerja Metode Peningkatan Kontras (CLAHE & HE) pada Klasifikasi Ras Kucing menggunakan VGG16

Wulandari Juslan^{1,*}, Alva Hendi Muhammad¹

¹ Program Studi Informatika, Universitas Amikom Yogyakarta, Indonesia

* Correspondence: wulandarijuslan98@students.amikom.ac.id

Copyright: © 2025 by the authors

Received: 15 Februari 2025 | Revised: 23 Februari 2025 | Accepted: 30 Maret 2025 | Published: 17 April 2025

Abstrak

Klasifikasi ras kucing menjadi tantangan dalam pengolahan citra karena variasi visual yang kompleks akibat persilangan, yang memengaruhi kebutuhan perawatan. Tujuan penelitian kami mengevaluasi efektivitas *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dan *Histogram Equalization* (HE) dalam klasifikasi ras kucing menggunakan *Convolutional Neural Network* (CNN) berbasis VGG16. Dataset berisi 4.656 citra kucing dari enam ras, yang diproses dengan metode peningkatan kontras CLAHE dan HE sebelum pelatihan model VGG16. Dataset dibagi menjadi 70% untuk pelatihan, 15% validasi, dan 15% pengujian, dengan model dilatih selama 10 epoch menggunakan *optimizer Adam*, *learning rate* 0.0001, dan *batch size* 16, 32, 64. Evaluasi berdasarkan akurasi, presisi, recall, dan F1-score menunjukkan bahwa *preprocessing* dengan CLAHE menghasilkan akurasi tertinggi 99,39%, lebih unggul dibandingkan HE (99,17%) dengan selisih 3,29%. CLAHE lebih efektif dalam mempertahankan detail lokal, meningkatkan rata-rata *precision* 78,67%, *recall* 78,33%, dan *F1-score* 78%. Kinerja terbaik dicapai pada ras Sphinx (*F1-score* 92%) dan terendah pada American Shorthair (*F1-score* 72%). Standar deviasi yang tinggi menunjukkan variasi klasifikasi antar ras, namun CLAHE terbukti meningkatkan akurasi model dalam mengenali ras kucing. Temuan kami mengindikasikan bahwa CLAHE lebih efektif dalam meningkatkan akurasi klasifikasi ras kucing dibandingkan HE, serta menjadi pendekatan yang lebih efisien daripada mengganti model dengan arsitektur lebih kompleks.

Kata kunci: *convolution neural network; clahe; histogram equalization; ras kucing; vgg16*

Abstract

Cat breed classification is challenging in image processing due to complex visual variations from crossbreeding, which affect care requirements. This study evaluates the effectiveness of Contrast Limited Adaptive Histogram Equalization (CLAHE) and Histogram Equalization (HE) in cat breed classification using a VGG16-based Convolutional Neural Network (CNN). The dataset consists of 4,656 cat images from six breeds, processed with CLAHE and HE for contrast enhancement before training. It is divided into 70% for training, 15% for validation, and 15% for testing. The model is trained for 10 epochs using the Adam optimizer, a 0.0001 learning rate, and batch sizes of 16, 32, and 64. Evaluation using accuracy, precision, recall, and F1-score shows that CLAHE achieves the highest accuracy (99.39%), surpassing HE (99.17%) by 3.29%. CLAHE is more effective in preserving local details, improving precision (78.67%), recall (78.33%), and F1-score (78%). The highest performance is in the Sphinx breed (F1-score 92%), while the lowest is in American Shorthair (F1-score 72%). A high standard deviation indicates classification variations across breeds, but CLAHE consistently improves model accuracy. These findings suggest that CLAHE is more effective than HE in enhancing cat breed classification and offers a more efficient solution than adopting a complex model architecture.

Keywords: *convolution neural network; clahe; histogram equalization; cat breeds; vgg16*



PENDAHULUAN

Kucing adalah salah satu hewan peliharaan yang sangat digemari diberbagai belahan dunia. Sekitar tahun 6000 SM, kucing diketahui telah hidup berdampingan dengan manusia dan mulai tersebar ke berbagai wilayah dunia (Wisnuyana & Yuniati, 2023). Saat ini, populasi kucing ras hanya mencakup sekitar 1% dari seluruh kucing, sehingga mayoritas kucing adalah hibrida atau kucing domestic (Cahyo et al., 2023) Karena kelangkaannya, kucing ras memiliki harga yang jauh lebih tinggi. Setiap ras kucing memiliki ciri khas tersendiri, namun akibat banyaknya persilangan, identifikasi ras kucing menjadi semakin sulit, dan tidak semua pemilik kucing mengenali jenis kucing peliharaannya (Choirunisa et al., 2021) Setiap kucing memiliki karakteristik unik dan kondisi kesehatan yang berbeda-beda, sehingga perlu memberikan perawatan dan pengobatan yang sesuai (Cahyo et al., 2023). Seorang pemilik kucing dapat memiliki lebih dari satu kucing, baik ras yang sama maupun ras yang berbeda. Namun tidak semua pemilik kucing mengetahui ras kucingnya (Linda et al., 2024). Oleh karena itu, penelitian ini akan membahas tentang klasifikasi ras kucing.

Di zaman modern, terdapat berbagai teknologi canggih yang mampu mengenali wajah, objek, jenis, dan lain sebagainya. Penggunaan deep learning dalam pengolahan citra dinilai lebih akurat daripada machine learning (Marvasti-Zadeh et al., 2021). Klasifikasi gambar menggunakan *Convolutional Neural Network* (CNN) telah menjadi metode yang populer dalam pengenalan pola dan analisis citra. CNN merupakan teknologi canggih yang telah menunjukkan kemampuannya dalam mengekstrak dan mengolah informasi visual dari gambar (Pamungkas & Suhendar, 2024). Arsitektur VGG16, salah satu model CNN yang terkenal (Bhushan et al., 2022), sering digunakan dalam tugas klasifikasi gambar karena kemampuannya dalam mempelajari fitur kompleks dari data gambar (Aulia & Rahmat, 2022). Namun, tantangan akan kebutuhan akurasi yang tinggi mendorong penelitian lebih lanjut dalam meningkatkan performa model ini (Kamal & Ez-Zahraouy, 2023). Oleh karena itu, diperlukan teknik tambahan untuk meningkatkan performa model, salah satunya melalui preprocessing citra dengan metode peningkatan kontras.

Histogram Equalization (HE) dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) adalah teknik peningkatan kontras yang banyak digunakan dalam pemrosesan citra. HE bekerja dengan menyebarkan distribusi intensitas piksel secara merata di seluruh rentang dinamis gambar, sehingga meningkatkan perbedaan antara area terang dan gelap. Metode ini efektif untuk meningkatkan kontras pada gambar dengan pencahayaan rendah tetapi dapat menyebabkan peningkatan noise pada beberapa kasus (Dhal et al., 2021). Sementara itu, CLAHE adalah teknik yang lebih canggih yang membagi gambar menjadi beberapa blok kecil sebelum menerapkan histogram equalization, serta membatasi amplifikasi kontras yang berlebihan dengan menerapkan clipping limit pada histogram. Dengan cara ini, CLAHE dapat mempertahankan detail lokal dan mengurangi efek peningkatan noise yang sering muncul pada HE (Dhal et al., 2021).

Klasifikasi citra yang lebih akurat dapat dicapai dengan meningkatkan kualitas gambar menggunakan Teknik HE dan CLAHE. Citra dengan kontras rendah sering kali disebabkan oleh kondisi pencahayaan yang tidak ideal atau keterbatasan sensor kamera, yang dapat menghambat proses ekstraksi fitur oleh model CNN (Zheng & Luo, 2022). Sebagai pendekatan yang lebih efektif, HE dapat digunakan untuk menyebarkan distribusi intensitas piksel secara merata untuk meningkatkan kontras (Dhal et al., 2021). CLAHE dengan mempertahankan detail lokal dan membatasi amplifikasi kontras yang berlebihan dengan membagi gambar menjadi beberapa blok kecil sebelum menerapkan histogram equalization (Dhal et al., 2021). Peningkatan kontras dengan CLAHE telah terbukti meningkatkan akurasi model CNN pada berbagai tugas pengenalan pola dan segmentasi citra medis (Saifullah & Drezewski, 2023). Namun, efektivitas metode ini dalam klasifikasi ras kucing masih belum dieksplorasi secara mendalam. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi pengaruh CLAHE dan

HE terhadap akurasi klasifikasi ras kucing menggunakan arsitektur VGG16 dengan harapan dapat meningkatkan performa model secara signifikan.

Beberapa penelitian sebelumnya telah mengeksplorasi klasifikasi ras kucing menggunakan berbagai metode (Choirunisa et al., 2021) membandingkan *Support Vector Machine* (SVM) dan *Naïve Bayes* dalam klasifikasi ras kucing dan menemukan bahwa SVM mencapai akurasi tertinggi sebesar 88,4%. Namun, metode ini kurang efektif dalam menangani variasi visual yang kompleks. Penelitian lain oleh (Ramadhan & Setiawan, 2023) menggunakan EfficientNet-B0 dengan dataset 2.700 gambar dan memperoleh akurasi 95%, sementara penelitian mereka yang menguji tiga model transfer learning menemukan bahwa MobileNetV2 memberikan performa terbaik dengan akurasi 82%. (Rumpungan et al., 2023) juga mengeksplorasi *transfer learning* pada klasifikasi kucing dan anjing menggunakan model CNN yang telah disetel sebelumnya, dengan hasil yang bervariasi tergantung pada arsitektur yang digunakan. Sementara itu, beberapa studi telah menunjukkan bahwa peningkatan kontras citra dapat meningkatkan akurasi model CNN (Yang et al., 2021). (Mungra et al., 2020) menunjukkan bahwa HE dapat meningkatkan akurasi sistem pengenalan emosi dari 64,62% menjadi 78,52%, sementara (Saifullah & Drezewski, 2023). menemukan bahwa CLAHE meningkatkan akurasi segmentasi citra medis sebesar 2,82%. Dengan demikian, meskipun metode peningkatan kontras telah terbukti efektif dalam berbagai aplikasi, pengaruhnya terhadap klasifikasi ras kucing belum banyak diteliti secara mendalam.

Penelitian ini penting karena masih minimnya studi atau penelitian yang membandingkan efek CLAHE dan HE pada klasifikasi ras kucing menggunakan CNN, khususnya VGG16. Selain itu, penelitian sebelumnya umumnya menggunakan dataset lebih kecil dan berfokus pada transfer learning tanpa mengeksplorasi secara spesifik dampak *preprocessing* kontras terhadap akurasi. Oleh karena itu, penelitian ini mengatasi keterbatasan tersebut dengan menggunakan dataset yang lebih besar (4.656 citra) dan menganalisis perbedaan performa HE dan CLAHE dalam meningkatkan akurasi klasifikasi ras kucing menggunakan VGG16.

Penelitian ini bertujuan untuk mengevaluasi efektivitas metode CLAHE dan HE dalam meningkatkan akurasi klasifikasi ras kucing menggunakan arsitektur VGG16. Dengan membandingkan kedua metode ini, penelitian ini ingin mengetahui teknik peningkatan kontras yang paling optimal dalam memperjelas fitur visual yang khas pada setiap ras kucing, seperti tekstur bulu, bentuk wajah, dan pola warna. Hasil penelitian diharapkan dapat menentukan metode peningkatan kontras yang paling optimal untuk meningkatkan performa model CNN dalam mengidentifikasi ras kucing secara lebih akurat.

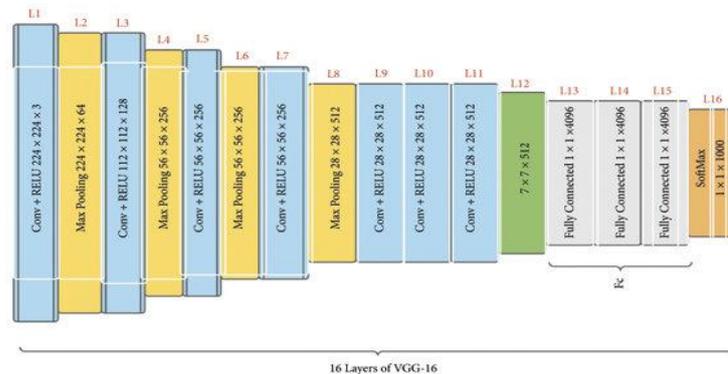
METODE

Penelitian ini menggunakan dataset dari Kaggle yang terdiri dari 4.656 gambar dengan 6 ras kucing: *Scottish fold* (850), *Maine Coon* (781), *Ragdoll* (760), *Bengal* (899), *American shorthair* (832), dan *Sphynx* (659). Dataset ini memiliki variasi dalam pencahayaan, sudut pengambilan gambar, serta latar belakang yang beragam, sehingga dilakukan augmentasi data berupa rotasi ($\pm 15^\circ$), *flipping horizontal*, *zooming* hingga 20%, dan penyesuaian *brightness* dalam rentang $\pm 30\%$. Resolusi gambar disesuaikan menjadi 224×224 piksel, dan nilai piksel dinormalisasi ke rentang $[0,1]$. Untuk meningkatkan kualitas citra, digunakan dua metode peningkatan kontras, yaitu HE yang menyebarkan intensitas piksel secara merata dan CLAHE dengan *clip limit* 2.0 dan *tile grid size* 8×8 untuk menghindari *noise* berlebihan. Dataset kemudian dibagi menjadi 70% pelatihan (3.259 gambar), 15% validasi (699 gambar), dan 15% pengujian (698 gambar) secara acak namun tetap proporsional di setiap kelas. Kategori 6 ras kucing yaitu *Scottish fold*, *Maine Coon*, *Ragdoll*, *Bengal*, *American shorthair*, dan *Sphynx* ditampilkan pada gambar 1.



Gambar 1. Ras kucing

Gambar 2 menunjukkan model yang digunakan adalah VGG16, yang terdiri dari 16 lapisan, yang terdiri dari 5 lapisan konvolusional, 5 lapisan *max-pooling*, 2 lapisan *dropout*, satu lapisan *fully connected* (lapisan padat), dan satu lapisan output menggunakan fungsi aktivasi sigmoid (Yang et al., 2021). lapisan konvolusi terdapat dengan filter 3×3 dan *padding* "same", serta *max pooling* 2×2 untuk ekstraksi fitur. Fungsi aktivasi ReLU digunakan di semua lapisan konvolusi untuk mengatasi *vanishing gradient*, sementara lapisan output menggunakan Softmax untuk klasifikasi multi-kelas. Model ini dilatih menggunakan *optimizer* Adam dengan *learning rate* 0.0001, *loss function* *categorical crossentropy* dengan *dropout* 50% pada *fully connected layer* untuk mencegah *overfitting*.



Gambar 2. Arsitektur vgg16 (Pratama et al., 2024)

Evaluasi model dilakukan menggunakan metrik *Accuracy*, *precision*, *recall*, dan *F1-score* ditunjukkan dengan persamaan (1), (2), (3) dan (4) dengan pendekatan macro-averaging untuk menangani ketidakseimbangan data (Malik, 2023). *Confusion matrix* digunakan untuk menganalisis distribusi kesalahan model, sementara kurva ROC dan AUC membantu mengevaluasi kemampuan model dalam membedakan kelas. Perhitungan *True Positive (TP)*, *False Positive (FP)*, *True Negative (TN)*, dan *False Negative (FN)* dilakukan untuk memahami performa model secara lebih mendalam (Majumdar et al., 2023).

Persamaan ini digunakan untuk mengevaluasi kinerja model klasifikasi. *Accuracy* persamaan (1) mengukur proporsi prediksi yang benar terhadap seluruh data. *Precision* persamaan (2) menunjukkan seberapa banyak prediksi positif yang benar. *Recall* persamaan (3) mengukur kemampuan model dalam mendeteksi semua sampel positif. *F1-Score* persamaan (4) menyeimbangkan presisi dan recall, terutama saat terdapat ketidakseimbangan kelas. Keempat metrik ini memastikan model bekerja optimal sesuai kebutuhan aplikasi.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = \frac{2x Recall x Precision}{Recall + Precision} \quad (4)$$

HASIL DAN PEMBAHASAN

Hasil

Proses pelatihan pada penelitian ini dilakukan dengan jumlah *epoch* sebanyak 10, menggunakan variasi ukuran *batch size* (16, 32, 64), dan *learning rate* sebesar $1e-4$ (0.0001) yang dikonfigurasi dalam *Adam optimizer* untuk memastikan pembaruan bobot yang stabil. Penelitian ini juga menerapkan teknik *early stopping* dengan *patience* sebanyak 5 *epoch*, yang memungkinkan pelatihan dihentikan lebih awal jika validasi loss tidak mengalami perbaikan selama 5 *epoch* berturut-turut, guna menghindari *overfitting* dan penghematan waktu daya komputasi yang lebih efisien. Pelatihan pertama dilakukan dengan menerapkan metode peningkatan kontras CLAHE, dan hasilnya disajikan pada tabel 1. Selanjutnya, percobaan kedua menggunakan metode peningkatan kontras HE, dengan hasil yang ditunjukkan pada tabel 2.

Tabel 1. Model vgg16 dengan penerapan clahe

<i>Batch size</i>	<i>Epoch stop</i>	<i>Accuracy</i>	<i>Loss</i>	<i>Accuracy Validation</i>	<i>Loss Validation</i>	<i>VGG16 Accuracy</i>
16	9	97,63%	0,1060	75,21%	0,7478	96,50%
32	10	96,63%	0,1575	74,93%	0,7447	90,01%
64	10	97,71%	0,1262	75,07%	0,7546	99,39%

Tabel 2. Model vgg16 dengan penerapan he

<i>Batch size</i>	<i>Epoch stop</i>	<i>Accuracy</i>	<i>Loss</i>	<i>Accuracy Validation</i>	<i>Loss Validation</i>	<i>VGG16 Accuracy</i>
16	9	96,94%	0,1202	71,06%	0,8847	98,16%
32	10	97,40%	0,1390	72,49%	0,8134	98,90%
64	10	97,54%	0,1466	71,78%	0,8319	99,17%

Berdasarkan hasil evaluasi pada tabel 1 menunjukkan hasil evaluasi model VGG16 dengan penerapan CLAHE menggunakan tiga variasi *batch size*, yaitu 16, 32, dan 64. Pada *batch size* 16 dengan *epoch stop* 9, model mencapai akurasi *training* 97,63% dan akurasi validasi 75,21%, dengan *loss training* 0,1060 serta *loss validasi* 0,7478, menghasilkan akurasi akhir 96,50%. Untuk *batch size* 32 dengan *epoch stop* 10, akurasi *training* sedikit menurun menjadi 96,63%, akurasi validasi mencapai 74,93%, dengan *loss training* 0,1575 dan *loss validasi* 0,7447, menghasilkan akurasi akhir 90,01%. Sementara itu, *batch size* 64 dengan *epoch stop* 10 memberikan hasil terbaik dengan akurasi *training* 97,71%, akurasi validasi 75,07%, *loss training* 0,1262, dan *loss validasi* 0,7546, sehingga mencapai akurasi akhir tertinggi sebesar 99,39%.

Tabel 2 menampilkan hasil evaluasi model VGG16 dengan penerapan HE menggunakan konfigurasi *batch size* yang sama. Pada *batch size* 16 dengan *epoch stop* 9, model memperoleh akurasi *training* 96,94%, akurasi validasi 71,06%, *loss training* 0,1202, dan *loss validasi* 0,8847, dengan akurasi akhir 98,16%. Pada *batch size* 32 dengan *epoch stop* 10, akurasi *training* meningkat menjadi 97,40%, akurasi validasi 72,49%, dengan *loss training* 0,1390 dan

loss validasi 0,8134, menghasilkan akurasi akhir 98,90%. *Batch size* 64 dengan *epoch stop* 10 menunjukkan akurasi *training* 97,54%, akurasi validasi 71,78%, *loss training* 0,1466, dan *loss* validasi 0,8319, dengan akurasi akhir tertinggi dalam model HE sebesar 99,17%.

Akurasi pelatihan dengan nilai rata-rata 97,32% untuk CLAHE dan 97,29% untuk HE tidak memiliki perbedaan signifikan. Mengindikasikan efektivitas keduanya dalam mengenali pola data pelatihan. Namun, Perbedaan performa antara CLAHE dan HE signifikan secara statistik, dibuktikan dengan *paired t-test*, yang menghasilkan *T-statistic* sebesar 6,6716 dengan *p-value* sebesar 0,0217. Karena *p-value* < 0,05, maka hasil ini menunjukkan bahwa perbedaan akurasi antara kedua metode tidak terjadi secara acak, melainkan signifikan secara statistik.

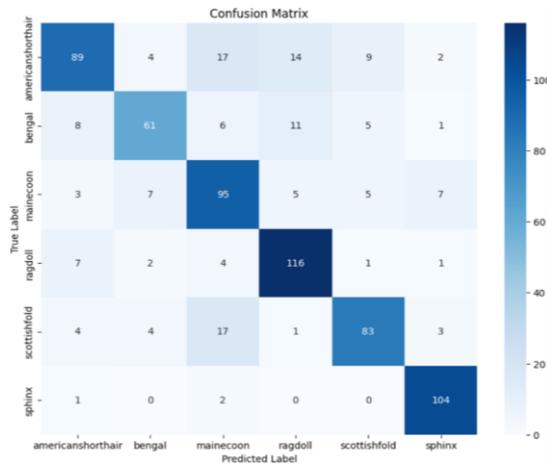
Perbedaan rata-rata akurasi antara CLAHE dan HE adalah 3,2933%, dengan *Confidence Interval* (CI) 95% sebesar (1,1694, 5,4173). Karena interval ini tidak mencakup nol, maka dapat disimpulkan bahwa metode CLAHE secara konsisten lebih unggul dibandingkan HE dalam meningkatkan akurasi klasifikasi ras kucing. Model VGG16 dengan penerapan teknik CLAHE menunjukkan performa terbaik pada ukuran batch 64. Tingkat akurasi tertinggi yang dicapai adalah sebesar 99,39%. Hasil ini menunjukkan bahwa preprocessing menggunakan CLAHE memiliki dampak yang signifikan.

Tabel 3. Performa model berdasarkan *precision*, *recall*, dan *f1-score*

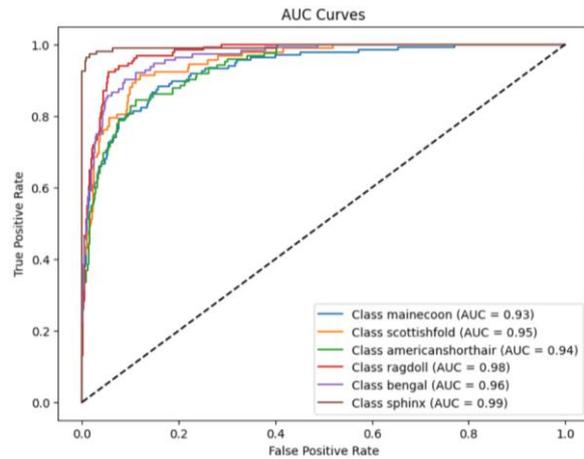
Kelas	Data	Precision	Recall	F1-Score
<i>Mainecoon</i>	781	79%	0,66	72%
<i>Scottish fold</i>	630	78%	0,66	72%
<i>American shorthair</i>	832	67%	0,78	72%
<i>Ragdoll</i>	855	79%	0,89	83%
<i>Bengal</i>	899	81%	0,74	77%
<i>Sphinx</i>	659	88%	0,97	92%
Rata-rata		78,67%	78,33%	78%
Standar deviasi		6,20%	11,42%	7,43%

Hasil evaluasi pada tabel 3. Menunjukkan bahwa model berhasil mengidentifikasi secara akurat 89 sampel dalam kategori *American Shorthair*, 61 sampel dalam kategori *Bengal*, 95 sampel dalam kategori *maine soon*, 116 sampel dalam kategori *ragdoll*, 83 sampel dalam kategori *Scottich fold* dan 104 sampel dalam kategori *Sphinx*. Namun, terdapat 64 sampel dari kategori *American Shorthair* yang salah diklasifikasikan, 31 sampel dari kategori *Bengal* yang salah diklasifikasikan, 27 sampel dari kategori *Maine Soon* yang salah diklasifikasikan, 15 sampel dari kategori *Ragdoll* yang salah diklasifikasikan, 29 sampel dari kategori *Scottich Fold* yang salah diklasifikasikan dan 3 sampel dari kategori *Sphinx* yang salah diklasifikasikan sebagai salah.

Model masih memiliki kesalahan klasifikasi dalam membedakan beberapa ras kucing dengan ciri visual yang mirip, terutama *Maine Coon* dan *Scottish Fold*, yang memiliki *recall* hanya 66%, menunjukkan banyak sampel salah diklasifikasikan. *American Shorthair* juga sering keliru, dengan *precision* 67%, mengindikasikan bahwa ras lain sering diklasifikasikan sebagai *American Shorthair*, kemungkinan karena pola warnanya yang menyerupai *Bengal* atau *Ragdoll*. Sementara itu, *Ragdoll* dan *Bengal* memiliki performa lebih stabil, tetapi masih mengalami kesalahan akibat kemiripan warna dan tekstur bulu dengan ras lain. *Sphynx* memiliki akurasi tertinggi (*precision* 88%, *recall* 97%), karena ciri khasnya yang unik, yaitu tidak berbulu, membuatnya lebih mudah dikenali dibandingkan ras lain. Kesalahan klasifikasi ini menunjukkan bahwa model lebih sulit mengenali ras dengan pola warna dan bentuk wajah serupa, sedangkan ras dengan ciri khas yang sangat berbeda lebih mudah diklasifikasikan. Hal ini dibuktikan melalui visualisasi Evaluasi model menggunakan *confusion matrix* yang ditunjukkan pada gambar 3.

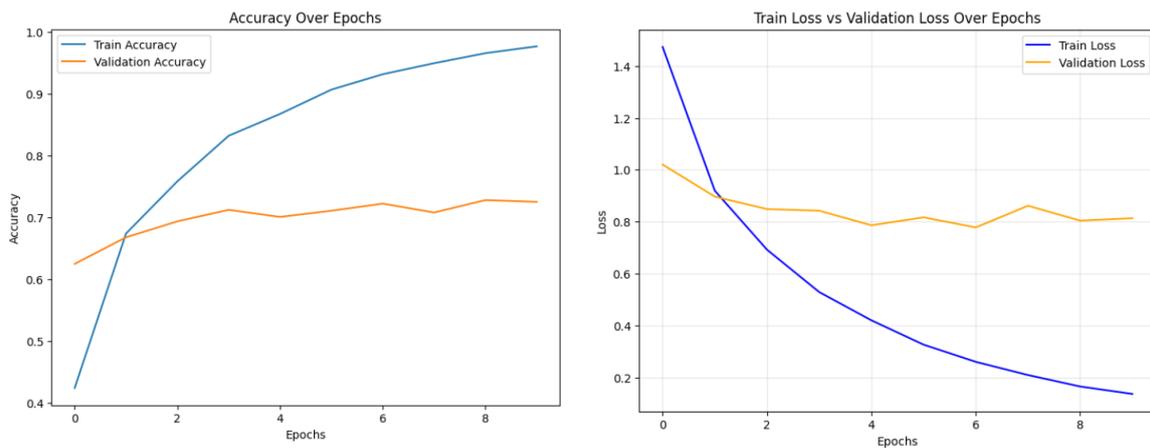


Gambar 3. Confusion matrix



Gambar 4. Kurva auc-roc model vgg16

Gambar 4 menggambarkan kurva ROC untuk model VGG16 dalam mengklasifikasi enam kategori, yaitu *American Shorthair*, *Bengal*, *Maine Soon*, *Ragdoll*, *Scottich Fold*, dan *Sphinx*. Keenam kurva menunjukkan performa yang sangat baik, dengan nilai AUC tertinggi sebesar 0,99 dan nilai AUC terendah sebesar 0,93. Nilai ini mencerminkan bahwa model memiliki kemampuan klasifikasi yang sangat tinggi, dengan sensitivitas dan spesifisitas yang optimal di berbagai ambang batas. Hasil ini menegaskan bahwa model VGG16 memiliki kinerja yang luar biasa dalam membedakan antara kategori *American Shorthair*, *Bengal*, *Maine Soon*, *Ragdoll*, *Scottich Fold*, dan *Sphinx*.



Gambar 5. Akurasi dan loss

Hasil klasifikasi pada gambar 5 menunjukkan akurasi model selama pelatihan. Akurasi data latih meningkat secara konsisten hingga mendekati 100%, sementara akurasi validasi hanya mencapai sekitar 70-75% dan cenderung stagnan setelah beberapa epoch. Grafik nilai *loss* pada data latih mengalami penurunan signifikan dan terus menurun hingga mendekati nol, sementara *loss* pada data validasi hanya menurun di awal lalu cenderung stabil dengan sedikit fluktuasi. *Loss* pada data latih terus menurun drastis, sedangkan *loss* validasi hanya sedikit menurun di awal lalu cenderung stabil dengan fluktuasi kecil.

Pembahasan

Pada penelitian ini, dilakukan evaluasi dengan tiga variasi *batch size* (16, 32, dan 64) untuk mengamati pengaruhnya terhadap performa model. *Batch size* 64 dengan CLAHE memberikan hasil terbaik dengan akurasi validasi 75,07% dan akurasi akhir 99,39%,

menunjukkan bahwa *batch size* yang lebih besar dapat meningkatkan kestabilan pembelajaran model. Namun, pada model dengan HE, meskipun *batch size* 64 juga memberikan akurasi akhir tertinggi 99,17%, akurasi validasinya lebih rendah dibandingkan CLAHE, yaitu 71,78%. Ini menunjukkan bahwa HE tidak dapat meningkatkan kontras gambar seefektif CLAHE, yang berdampak pada daya generalisasi model terhadap data baru. Selain itu, *early stopping* terjadi pada epoch ke-9 hingga ke-10, menandakan bahwa model telah mencapai titik optimal. Hal ini terlihat dari nilai *loss* validasi yang relatif stabil setelah epoch ke-9. Dengan kata lain, model dengan *preprocessing* CLAHE mampu mencapai konvergensi lebih cepat, yang berarti fitur yang dihasilkan dari citra telah cukup informatif bagi model untuk membedakan setiap ras kucing dengan akurasi tinggi.

Hasil performa klasifikasi kelas menunjukkan bahwa model dapat mengenali ras kucing dengan baik, terutama *Sphinx* yang memiliki akurasi tertinggi (*precision* 88%, *recall* 97%) karena ciri khasnya yang unik. Namun, beberapa ras seperti *Maine Coon* dan *Scottish Fold* memiliki *recall* rendah (66%) akibat kemiripan pola warna dan bentuk wajah dengan ras lain. Analisis *confusion matrix* diketahui bahwa *American Shorthair* juga sering salah diklasifikasikan, kemungkinan karena kemiripan warna, tekstur dan bulunya dengan *Bengal* atau *Ragdoll*. Evaluasi kinerja model yang dihasilkan menggunakan kurva ROC memiliki performa klasifikasi yang sangat baik, dengan nilai AUC berkisar antara 0,93 hingga 0,99. Grafik akurasi dan *loss* selama pelatihan menunjukkan bahwa meskipun akurasi data latih meningkat hingga hampir 100%, akurasi validasi cenderung stagnan pada 70-75%, menandakan adanya keterbatasan dalam generalisasi model.

Penelitian Fawwaz et al. (2020) telah melakukan klasifikasi ras pada Kucing menggunakan CNN menghasilkan akurasi 93,75% dengan model Xception, sedangkan dengan model VGG16 hanya mencapai akurasi sebesar 60,85% dan Choirunisa et al. (2021) yang menggunakan EfficientNet-B0 untuk klasifikasi ras kucing tanpa *preprocessing* tambahan dapat mencapai akurasi 95%. Perbedaan hasil evaluasi tersebut terjadi karena pengaruh peningkatan kualitas citra oleh CLAHE sebelum diproses oleh CNN memungkinkan model yang lebih sederhana seperti VGG16 mengungguli arsitektur yang lebih canggih.

Penelitian sebelumnya hanya berfokus pada pemilihan model CNN terbaik, penelitian kami membuktikan bahwa peningkatan kualitas data sebelum diterapkan pada model dapat memberikan dampak yang lebih signifikan. Hasil penelitian ini dapat menjadi kontribusi baru dalam bidang pengolahan citra berbasis *deep learning*, terutama dalam aplikasi klasifikasi hewan peliharaan, sistem identifikasi otomatis, dan pengembangan model CNN yang lebih efisien secara komputasi. Meskipun penelitian ini menunjukkan peningkatan akurasi yang signifikan, namun penelitian ini masih memiliki keterbatasan pada kemungkinan model mengalami *overfitting* dikarenakan dataset citra kucing memiliki latar belakang gambar yang tidak terkontrol, sehingga mengurangi generalisasi model. Selain itu, penelitian ini juga menggunakan ukuran sampel yang terbatas.

SIMPULAN

Penerapan metode peningkatan kontras CLAHE pada model VGG16 secara signifikan meningkatkan akurasi klasifikasi ras kucing dibandingkan dengan metode HE. Dengan akurasi tertinggi mencapai 99,39%, CLAHE terbukti lebih efektif dalam mempertahankan detail visual dan menghindari peningkatan kontras yang berlebihan, sehingga meningkatkan kemampuan model dalam mengenali ciri khas setiap ras. Selain itu, evaluasi menggunakan metrik *precision*, *recall*, dan F1-score menunjukkan bahwa model masih memiliki tantangan dalam membedakan ras dengan kemiripan pola warna dan bentuk wajah, meskipun performa klasifikasi secara keseluruhan sangat baik dengan nilai AUC mencapai 0,99. Hasil penelitian membuktikan bahwa peningkatan kualitas citra melalui *preprocessing* yang optimal dapat memberikan dampak lebih besar terhadap akurasi model dibandingkan dengan sekadar mengganti arsitektur

CNN yang lebih kompleks. Hasil penelitian ini berdampak nyata, seperti penerapan dalam aplikasi mobile untuk mengenali ras kucing serta mendukung penelitian genetik dan pelestarian ras secara otomatis. Untuk pengembangan lebih lanjut, disarankan menggunakan arsitektur lain seperti *Vision Transformer* (ViT) dengan menerapkan teknik peningkatan kontras untuk meningkatkan akurasi. Selain itu, eksperimen dengan teknik segmentasi menghilangkan latar belakang dapat dilakukan untuk mengurangi *overfitting* dan meningkatkan ketahanan model terhadap variasi citra.

REFERENSI

- Aulia, S., & Rahmat, D. (2022). Brain tumor identification based on VGG-16 architecture and CLAHE method. *JOIV: International Journal on Informatics Visualization*, 6(1), 96-102. <https://doi.org/10.30630/joiv.6.1.864>
- Bhushan, S., Alshehri, M., Keshta, I., Chakraverti, A. K., Rajpurohit, J., & Abugabah, A. (2022). An Experimental Analysis of Various Machine Learning Algorithms for Hand Gesture Recognition. *Electronics*, 11(6). <https://doi.org/10.3390/electronics11060968>
- Cahyo, D. D. N., Fauzi, M. A., Nugroho, J. T., & Kusriani, K. (2023). Analisis Perbandingan Optimizer pada Arsitektur NASNetMobile Convolutional Neural Network untuk Klasifikasi Ras Kucing. *Jurnal Teknologi*, 15(2), 171–177. <https://doi.org/10.34151/jurtek.v15i2.4025>
- Choirunisa, N. A., Karlita, T., & Asmara, R. (2021). Deteksi Ras Kucing Menggunakan Compound Model Scaling Convolutional Neural Network. *Technomedia Journal*, 6(2), 236–251. <https://doi.org/10.33050/tmj.v6i2.1704>
- Dhal, K. G., Das, A., Ray, S., Gálvez, J., & Das, S. (2021). Histogram Equalization Variants as Optimization Problems: A Review. *Archives of Computational Methods in Engineering*, 28(3), 1471–1496. <https://doi.org/10.1007/s11831-020-09425-1>
- Fawwaz, M. A. A., Ramadhani, K. N., & Sthevanie, F. (2020). Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network (CNN). *E-Proceedings of Engineering*, 8(1), 715–730.
- Kamal, K., & Ez-Zahraouy, H. (2023). A comparison between the VGG16, VGG19 and ResNet50 architecture frameworks for classification of normal and CLAHE processed medical images. *Research Square*. 1-16. <https://doi.org/10.21203/rs.3.rs-2863523/v1>
- Linda, K. D., Kusriani, K., & Hartanto, A. D. (2024). Studi Literatur Mengenai Klasifikasi Citra Kucing Dengan Menggunakan Deep Learning: Convolutional Neural Network (CNN). *Journal of Electrical Engineering and Computer (JEECOM)*, 6(1), 129–137. <https://doi.org/10.33650/jeeecom.v4i2>
- Majumdar, S., Pramanik, P., & Sarkar, R. (2023). Gamma function based ensemble of CNN models for breast cancer detection in histopathology images. *Expert Systems with Applications*, 213, 119022. <https://doi.org/10.1016/j.eswa.2022.119022>
- Malik, Y. (2023). Akurasi dan Presisi Analisis Kadar Nikel (Ni) pada Sampel Nikel Laterit Menggunakan X-Ray Fluorescence Spectrometry (XRF). *Sains: Jurnal Kimia dan Pendidikan Kimia*, 12(2), 87-94.
- Marvasti-Zadeh, S. M., Ghanei-Yakhdan, H., & Kasaei, S. (2021). Adaptive exploitation of pre-trained deep convolutional neural networks for robust visual tracking. *Multimedia Tools and Applications*, 80(14), 22027–22076. <https://doi.org/10.1007/s11042-020-10382-x>
- Mungra, D., Agrawal, A., Sharma, P., Tanwar, S., & Obaidat, M. S. (2020). PRATIT: a CNN-based emotion recognition system using histogram equalization and data augmentation. *Multimedia Tools and Applications*, 79(3–4), 2285–2307. <https://doi.org/10.1007/s11042-019-08397-0>

- Pamungkas, N. B., & Suhendar, A. (2024). Penerapan Metode Convolutional Neural Network pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 675–684. <https://doi.org/10.29408/edumatic.v8i2.27958>
- Pratama, G. A., Puspaningrum, E. Y., & Maulana, H. (2024). Convolutional Neural Network dan Faster Region Convolutional Neural Network untuk Klasifikasi Kualitas Biji Kopi Arabika. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3), 2776–2785. <https://doi.org/10.23960/jitet.v12i3.4887>
- Ramadhan, A. T., & Setiawan, A. (2023). Catbreedsnet: An Android Application for Cat Breed Classification Using Convolutional Neural Networks. *Jurnal Online Informatika*, 8(1), 52–60. <https://doi.org/10.15575/join.v8i1.1007>
- Rumpungan, J. L., On, C. K., Hijazi, M. H. A., & Karim, S. A. B. A. (2023). Image Classification of Occluded and Non-Occluded Cats and Dogs Datasets with Machine Learning. *Symposium on Computers & Informatics (ISCI)*, 19–24. <https://doi.org/10.1109/ISCI58771.2023.10391871>
- Saifullah, S., & Drezewski, R. (2023). Modified Histogram Equalization for Improved CNN Medical Image Segmentation. *Procedia Computer Science*, 225, 3021-3030. <https://doi.org/10.1016/j.procs.2023.10.295>
- Wisnuyana, B., & Yuniati, E. (2023). Kehadiran Kucing Sebagai Hewan Peliharaan di Masa Pandemi Covid-19 (Studi Kasus Masyarakat Kota Surabaya dan Sidoarjo). *SOLIDARITY*, 12(2), 414–428. <https://doi.org/10.15294/solidarity.v12i2.76749>
- Yang, H., Ni, J., Gao, J., Han, Z., & Luan, T. (2021). A novel method for peanut variety identification and classification by Improved VGG16. *Scientific Reports*, 11(1), 15756. <https://doi.org/10.1038/s41598-021-95240-y>
- Zheng, M., & Luo, W. (2022). Underwater Image Enhancement Using Improved CNN Based Defogging. *Electronics*, 11(1), 1–21. <https://doi.org/10.3390/electronics11010150>