



Analisis Pengaruh Peningkatan Kualitas Citra Berbasis Histogram terhadap Kinerja ResNet-18 pada Klasifikasi Karakter Katakana

Shella Christanti, Anggraini Puspita Sari*, Budi Nugroho

Fakultas Ilmu Komputer, Program Studi Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur, Surabaya, Indonesia

Email: ¹22081010058@student.upnjatim.ac.id, ^{2,*}anggraini.puspita.if@upnjatim.ac.id, ³budinugroho.if@upnjatim.ac.id

Email Penulis Korespondensi: anggraini.puspita.if@upnjatim.ac.id

Abstrak—Klasifikasi karakter tulisan tangan Katakana masih menghadapi tantangan akibat variasi bentuk tulisan antar individu serta kualitas citra yang kurang optimal, seperti kontras yang rendah dan detail karakter yang kurang jelas. Kondisi tersebut dapat memengaruhi kemampuan model dalam mengekstraksi fitur dan mengenali karakter secara akurat. Penelitian ini bertujuan untuk menganalisis pengaruh teknik peningkatan kualitas citra berbasis histogram, yaitu *Histogram Equalization* (HE), *Adaptive Histogram Equalization* (AHE), dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE), terhadap kinerja model ResNet-18 pada klasifikasi huruf Katakana. Dataset yang digunakan adalah ETL5 yang terdiri dari 9.200 citra tulisan tangan dengan 46 kelas karakter. Dataset kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20. Untuk meningkatkan keragaman data dan mengurangi risiko overfitting, augmentasi data berupa rotasi dan translasi diterapkan pada data latih. Proses klasifikasi dilakukan menggunakan ResNet-18 berbasis *transfer learning* dengan bobot awal dari ImageNet, di mana hanya lapisan *fully connected* yang dilatih ulang menggunakan optimizer Adam selama 50 epoch. Hasil pengujian menunjukkan bahwa metode CLAHE memberikan performa terbaik dengan accuracy sebesar 97,01%, sedangkan metode HE dan AHE masing-masing menghasilkan accuracy sebesar 83,15% dan 76,79%. Temuan penelitian ini menunjukkan bahwa CLAHE lebih efektif dibandingkan HE dan AHE dalam meningkatkan kinerja klasifikasi karakter tulisan tangan Katakana menggunakan ResNet-18, sehingga dapat menghasilkan prediksi yang lebih akurat. Penelitian ini berkontribusi dengan memberikan analisis komparatif mengenai pengaruh tiga metode enhancement berbasis histogram terhadap performa ResNet-18 pada klasifikasi karakter tulisan tangan Katakana.

Kata Kunci: Katakana; ResNet-18; HE; AHE; CLAHE

Abstract—Handwritten Katakana character classification remains a challenging task due to variations in individual writing styles and suboptimal image quality, such as low contrast and unclear character details. These conditions can affect the model's ability to extract discriminative features and accurately recognize characters. This study aims to analyze the impact of histogram-based image enhancement techniques, namely Histogram Equalization (HE), Adaptive Histogram Equalization (AHE), and Contrast Limited Adaptive Histogram Equalization (CLAHE), on the performance of the ResNet-18 model for Katakana character classification. The ETL5 dataset, consisting of 9,200 handwritten character images across 46 character classes, was used in this study. The dataset was divided into training and testing sets with an 80:20 ratio. To increase data diversity and reduce the risk of overfitting, data augmentation using rotation and translation was applied to the training set. The classification process employed a transfer learning-based ResNet-18 model initialized with ImageNet pretrained weights, where only the fully connected layer was fine-tuned using the Adam optimizer for 50 epochs. The experimental results show that CLAHE achieved the best performance with an accuracy of 97.01%, while HE and AHE obtained accuracies of 83.15% and 76.79%, respectively. These findings indicate that CLAHE is more effective than HE and AHE in improving the classification performance of handwritten Katakana characters using ResNet-18, resulting in more accurate predictions. This study contributes by providing a comparative analysis of the effects of three histogram-based image enhancement methods on the performance of ResNet-18 for handwritten Katakana character classification.

Keywords: Katakana; ResNet-18; HE; AHE; CLAHE

1. PENDAHULUAN

Indonesia termasuk salah satu negara dengan jumlah pembelajar bahasa Jepang yang cukup tinggi di dunia. Berdasarkan hasil survei yang dirilis oleh The Japan Foundation pada tahun 2024, Indonesia menempati posisi kedua sebagai negara dengan jumlah pembelajar bahasa Jepang terbanyak setelah China (*Survey Summary on Japanese-Language Education Abroad 2024*, 2025). Minat masyarakat dalam mempelajari bahasa Jepang terus meningkat seiring meluasnya pengaruh budaya populer Jepang, seperti anime, manga, dan J-pop, yang turut meningkatkan ketertarikan masyarakat terhadap bahasa Jepang (Permatasari et al., 2025). Selain itu, kebutuhan akademik dan peluang karier juga menjadi faktor yang mendorong masyarakat untuk mempelajari bahasa Jepang. Oleh karena itu, kemampuan membaca dan menulis aksara Jepang menjadi salah satu kompetensi dasar yang penting untuk dikuasai.

Dalam pembelajaran bahasa Jepang, penguasaan huruf Katakana menjadi salah satu kemampuan yang penting karena aksara ini banyak digunakan untuk menuliskan kata serapan dari bahasa asing, istilah ilmiah, serta berbagai kosakata modern yang sering dijumpai dalam kehidupan sehari-hari (Rusyn et al., 2025). Penggunaan Katakana yang cukup luas menjadikan kemampuan membaca dan mengenali karakter Katakana sebagai salah satu aspek yang perlu dikuasai oleh pembelajar bahasa Jepang.

Meskipun demikian, proses pengenalan karakter tulisan tangan Katakana masih menjadi tantangan. Hal ini disebabkan oleh adanya variasi gaya penulisan setiap individu yang menghasilkan perbedaan bentuk, ukuran, maupun ketebalan garisan karakter. Selain itu, beberapa karakter Katakana memiliki bentuk yang serupa, seperti シ (shi) dan ツ (tsu), ソ (so) dan ノ (no), serta ク (ku) dan タ (ta), sehingga meningkatkan kompleksitas proses klasifikasi karakter tulisan tangan (Swasono et al., 2024). Oleh karena itu, diperlukan model yang mampu mengekstraksi fitur secara efektif agar karakter-karakter yang memiliki kemiripan bentuk tetap dapat dibedakan dengan baik.



Selain dipengaruhi oleh bentuk karakter, keberhasilan klasifikasi juga dipengaruhi oleh kualitas citra masukan. Citra tulisan tangan sering kali memiliki kontras yang rendah, distribusi intensitas yang tidak merata, serta detail guratan yang kurang jelas. Kondisi tersebut dapat menyebabkan informasi visual pada citra tidak terekam secara optimal, sehingga proses ekstraksi fitur menjadi kurang maksimal dan pada akhirnya dapat menurunkan performa klasifikasi (Sianturi & Sitio, 2025). Oleh karena itu, kualitas citra merupakan salah satu faktor yang perlu diperhatikan sebelum proses pembelajaran model dilakukan. Dengan menyediakan citra masukan yang memiliki kualitas lebih baik, model diharapkan dapat memperoleh representasi fitur yang lebih optimal selama proses klasifikasi.

Seiring perkembangan teknologi, metode *deep learning*, khususnya *Convolutional Neural Network* (CNN), banyak digunakan dalam bidang pengolahan citra karena mampu mengekstraksi fitur secara otomatis dan mengenali pola visual dengan baik pada berbagai jenis citra (Rahayu et al., 2024). Salah satu arsitektur CNN yang banyak digunakan untuk Handwriting Character Recognition adalah ResNet, yang memiliki mekanisme *residual connection* untuk menjaga stabilitas proses pelatihan serta mengatasi masalah *vanishing gradient* pada jaringan yang dalam (Respati et al., 2025). Berbagai penelitian sebelumnya menunjukkan bahwa ResNet mampu menghasilkan performa yang baik pada pengenalan karakter, seperti Kanji, Telugu, Jawa, Bangla, Urdu, dan Arab (Alif, 2024; Al-Taani & Ahmad, 2021; Kashif, 2021; Revathi et al., 2024; Rusyn et al., 2025; Sudewo et al., 2024). Hasil tersebut menunjukkan bahwa ResNet memiliki kemampuan yang baik dalam mempelajari karakteristik setiap karakter dan membedakan pola antarhuruf sehingga dapat menghasilkan performa klasifikasi yang optimal. Pada penelitian ini digunakan ResNet-18, yaitu salah satu varian ResNet yang terdiri atas 18 lapisan. Pemilihan ResNet-18 didasarkan pada karakteristik dataset ETL5 yang memiliki jumlah data terbatas. Selain itu, citra Katakana pada dataset tersebut memiliki pola yang tidak terlalu kompleks sehingga penggunaan model yang lebih dalam, seperti ResNet-34 atau ResNet-50, dengan jumlah parameter yang lebih besar berpotensi meningkatkan risiko overfitting. Selain pemilihan arsitektur model yang sesuai, kualitas citra masukan juga menjadi faktor penting yang dapat memengaruhi keberhasilan proses klasifikasi.

Oleh karena itu, tahap preprocessing menjadi bagian penting yang perlu dilakukan sebelum proses klasifikasi. Salah satu pendekatan yang banyak digunakan untuk meningkatkan kualitas citra adalah teknik peningkatan kualitas citra berbasis histogram, yang bekerja dengan memperbaiki distribusi intensitas piksel dan meningkatkan kontras citra. Pada penelitian ini digunakan tiga metode, yaitu Histogram Equalization (HE), Adaptive Histogram Equalization (AHE), dan Contrast Limited Adaptive Histogram Equalization (CLAHE). Ketiga metode tersebut memiliki karakteristik yang berbeda dalam meningkatkan kualitas citra sehingga menghasilkan tampilan visual yang berbeda pada setiap citra masukan. Perbedaan kualitas citra tersebut berpotensi memengaruhi informasi yang dipelajari model selama proses ekstraksi fitur dan pada akhirnya dapat memberikan pengaruh yang berbeda terhadap performa klasifikasi.

Pada penelitian ini, metode peningkatan kualitas citra berbasis histogram dipilih sebagai tahap preprocessing untuk memperbaiki kualitas citra masukan sebelum proses pembelajaran dilakukan. Melalui perbaikan kontras dan distribusi intensitas piksel, detail guratan karakter dapat terlihat lebih jelas sehingga informasi visual yang digunakan selama proses ekstraksi fitur menjadi lebih optimal tanpa mengubah bentuk asli karakter. Pendekatan ini dipilih karena penelitian berfokus pada pengaruh kualitas citra masukan terhadap performa klasifikasi, sehingga diperlukan metode preprocessing yang dapat memperbaiki kualitas visual citra tanpa mengubah karakteristik bentuk huruf yang akan dipelajari oleh model. Dengan kualitas citra yang lebih baik, ResNet-18 diharapkan dapat mempelajari karakteristik setiap huruf secara lebih baik juga. Oleh karena itu, penelitian ini berfokus pada analisis pengaruh perbedaan kualitas citra yang dihasilkan oleh metode HE, AHE, dan CLAHE terhadap performa klasifikasi karakter tulisan tangan Katakana menggunakan ResNet-18.

Berbagai penelitian sebelumnya telah menunjukkan bahwa metode HE, AHE, dan CLAHE telah banyak diterapkan pada berbagai jenis citra dengan karakteristik yang berbeda. Hasil dari penelitian-penelitian tersebut menunjukkan bahwa masing-masing metode memiliki karakteristik yang berbeda dalam meningkatkan kualitas citra, sehingga efektivitasnya sangat bergantung pada karakteristik data yang digunakan. Penelitian oleh Pratama dan Widiarti (2025) yang melakukan perbandingan antara metode HE, AHE, dan CLAHE pada proses perbaikan kualitas citra jalan dengan pencahayaan rendah menunjukkan bahwa ketiga metode tersebut memberikan hasil peningkatan kontras citra yang berbeda. Hasil penelitian menunjukkan bahwa CLAHE menghasilkan kinerja paling baik ditinjau dari nilai MSE dan PSNR karena mampu meningkatkan kontras secara lokal tanpa menyebabkan peningkatan noise yang berlebihan, sehingga detail pada citra menjadi lebih jelas. Temuan tersebut menunjukkan bahwa kualitas citra masukan yang lebih baik dapat membantu model mengenali ciri-ciri penting pada citra dengan lebih baik, sehingga berpotensi meningkatkan hasil klasifikasi.

Temuan tersebut diperkuat oleh penelitian Ernawati dkk (2025) yang membandingkan HE, AHE, dan CLAHE pada citra bawah air. Penelitian tersebut mengevaluasi ketiga metode menggunakan metrik entropy, kontras RMS dan SSIM. Hasil penelitian menunjukkan bahwa AHE memperoleh entropy tertinggi yang menandakan peningkatan detail lokal pada citra secara signifikan. HE menghasilkan kontras paling tinggi, tetapi kurang efektif dalam menjaga struktur asli citra, sedangkan CLAHE memberikan hasil yang lebih seimbang dengan nilai SSIM tinggi serta peningkatan kontras dan detail yang lebih konsisten. Hasil tersebut menunjukkan bahwa setiap metode memiliki karakteristik yang berbeda dalam meningkatkan kualitas citra sehingga pemilihan metode enhancement perlu disesuaikan dengan kebutuhan dan karakteristik data yang digunakan.

Penelitian lain terkait peningkatan kualitas citra dilakukan oleh Lorinez S dkk (2025) pada restorasi foto lama yang mengalami penurunan kualitas akibat faktor usia dan penyimpanan. Penelitian tersebut menerapkan metode HE

dan CLAHE untuk memperbaiki tampilan visual pada foto lama yang mengalami pemudaran. Hasil penelitian menunjukkan bahwa HE dapat meningkatkan kontras secara cukup tinggi, tetapi cenderung menghasilkan peningkatan berlebih (*over-enhancement*). Sementara itu, CLAHE menghasilkan kualitas citra yang lebih seimbang dengan nilai PSNR dan SSIM yang lebih baik dibandingkan metode HE. Penelitian tersebut menunjukkan bahwa CLAHE mampu meningkatkan kualitas citra dengan tetap mempertahankan detail visual secara lebih stabil pada citra berkualitas rendah.


Selain pada restorasi citra, metode peningkatan kontras juga diterapkan pada penelitian Muhammad Naufal dkk (2024) dalam deteksi wajah pengemudi untuk mengidentifikasi kondisi mengantuk saat berkendara. Penelitian tersebut menerapkan metode HE dan AHE pada citra wajah pengemudi sebelum proses deteksi dilakukan. Hasil penelitian menunjukkan bahwa HE memberikan performa yang lebih baik dibandingkan AHE berdasarkan nilai MSE, PSNR, dan SNR. Peningkatan kontras yang dihasilkan HE mampu membuat fitur wajah terlihat lebih jelas sehingga membantu meningkatkan akurasi deteksi. Hasil tersebut menunjukkan bahwa teknik *enhancement* citra memiliki pengaruh penting terhadap kualitas fitur visual yang dihasilkan dan dapat memengaruhi performa sistem pengolahan citra secara keseluruhan.

Berdasarkan berbagai penelitian terdahulu, metode peningkatan kualitas citra berbasis histogram terbukti mampu memberikan hasil yang berbeda pada berbagai jenis citra. Penelitian oleh Pratama dan Widiarti (2025), Ernawati dkk. (2025), Lorinez S dkk. (2025), serta Muhammad Naufal dkk. (2024) menunjukkan bahwa efektivitas metode HE, AHE, dan CLAHE sangat bergantung pada karakteristik citra yang digunakan. Namun, penelitian-penelitian tersebut umumnya hanya berfokus pada evaluasi kualitas citra menggunakan metrik seperti MSE, PSNR, SSIM, entropy, dan SNR, atau diterapkan pada objek selain karakter tulisan tangan, seperti citra jalan, citra bawah air, restorasi foto lama, dan deteksi wajah. Di sisi lain, berbagai penelitian mengenai ResNet telah membuktikan kemampuannya dalam klasifikasi karakter tulisan tangan pada berbagai bahasa dan aksara, tetapi belum banyak yang mengkaji pengaruh teknik *enhancement* citra sebagai tahap *preprocessing* terhadap performa model tersebut, khususnya pada karakter tulisan tangan Katakana. Dengan demikian, terdapat *research gap* berupa belum adanya kajian yang secara komprehensif membandingkan pengaruh metode HE, AHE, dan CLAHE terhadap performa ResNet-18 berbasis *transfer learning* pada klasifikasi karakter tulisan tangan Katakana menggunakan dataset ETL5. Selain itu, hubungan antara peningkatan kualitas citra hasil *enhancement* dengan peningkatan performa klasifikasi karakter tulisan tangan juga masih belum dijelaskan secara memadai dalam penelitian-penelitian sebelumnya.

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk menganalisis dan membandingkan pengaruh metode HE, AHE, dan CLAHE terhadap performa ResNet-18 berbasis *transfer learning* pada klasifikasi karakter tulisan tangan Katakana menggunakan dataset ETL5. Kebaruan penelitian ini terletak pada analisis komprehensif mengenai pengaruh tiga metode peningkatan kualitas citra berbasis histogram terhadap kemampuan ResNet-18 dalam mengenali karakter tulisan tangan Katakana, yang hingga saat ini masih jarang dikaji secara khusus. Adapun kontribusi penelitian ini adalah memberikan analisis komparatif mengenai efektivitas metode HE, AHE, dan CLAHE terhadap performa klasifikasi karakter tulisan tangan Katakana, mengidentifikasi metode *enhancement* yang paling efektif untuk meningkatkan kinerja sistem pengenalan karakter berbasis *deep learning*, serta menyediakan referensi dalam pemilihan teknik *preprocessing* yang sesuai untuk pengembangan sistem Handwritten Character Recognition pada karakter Jepang.

2. METODOLOGI PENELITIAN

Tahapan penelitian dirancang secara terstruktur untuk menggambarkan alur pelaksanaan penelitian agar dapat mencapai tujuan, yaitu menganalisis pengaruh metode HE, AHE, dan CLAHE terhadap performa klasifikasi karakter tulisan tangan Katakana menggunakan model ResNet-18. Berdasarkan Gambar 1, setiap tahapan penelitian dirancang saling berkaitan mulai dari identifikasi masalah, pengumpulan data, *preprocessing* citra, perancangan model, pelatihan dan pengujian model, hingga evaluasi performa klasifikasi. Setiap tahapan memiliki peran penting dalam menghasilkan sistem klasifikasi karakter tulisan tangan Katakana yang optimal.



Gambar 1. Alur Tahapan Penelitian

2.1 Identifikasi Masalah

Tahap identifikasi masalah dilakukan untuk mengidentifikasi permasalahan utama dalam proses pengenalan karakter tulisan tangan Katakana. Karakter Katakana memiliki beberapa bentuk huruf yang mirip, seperti シ (shi) dan ツ (tsu), sehingga sering menyebabkan kesalahan klasifikasi, terutama pada tulisan tangan. Selain itu, kualitas citra tulisan tangan yang rendah, seperti kontras yang kurang jelas, pencahayaan tidak merata, serta variasi gaya penulisan antar individu juga mempengaruhi proses ekstraksi fitur dan menurunkan performa model klasifikasi. Untuk mengatasi permasalahan tersebut, diperlukan metode *preprocessing* yang mampu meningkatkan kualitas citra sebelum proses klasifikasi dilakukan. Pada penelitian ini digunakan HE, AHE, dan CLAHE yang dikombinasikan dengan model ResNet-18 berbasis *transfer learning* untuk meningkatkan performa klasifikasi karakter tulisan tangan Katakana.

2.2 Pengumpulan Data

Proses pengumpulan data dilakukan untuk memperoleh data yang diperlukan dalam penelitian sehingga kualitas data perlu diperhatikan karena dapat memengaruhi hasil penelitian (Puspita et al., 2024). Pada penelitian ini, digunakan dataset ETL5 yang merupakan bagian dari koleksi ETL *Character Database* yang dikembangkan oleh *Electrotechnical Laboratory* (ETL) Jepang dan berisi karakter tulisan tangan bahasa Jepang (Katakana). Dataset ETL5 terdiri dari citra *grayscale* berformat PNG berukuran 72×76 piksel dengan 46 kelas huruf Katakana dasar. Setiap kelas memiliki 200 citra sehingga total data berjumlah 9.200 citra. Jumlah data yang seimbang pada setiap kelas bertujuan untuk menjaga distribusi data agar model tidak bias terhadap kelas tertentu. Seluruh data kemudian digunakan pada tahap *preprocessing*, pelatihan, dan pengujian model dalam penelitian ini. Contoh citra dataset ETL5 Katakana pada Gambar 2 berikut.



Gambar 2. Sampel Citra ETL5

2.3 Preprocessing Data

Tahap ini dilakukan sebelum data digunakan oleh model untuk mempersiapkan citra agar sesuai dengan kebutuhan proses pelatihan. Kualitas citra sangat mempengaruhi kemampuan model dalam mengekstraksi fitur dan menghasilkan klasifikasi yang akurat, sehingga diperlukan proses peningkatan kualitas dan penyeragaman data.

Pada tahap ini, data dibagi menjadi data latih dan data uji dengan rasio 80:20. Pada setiap kelas, sebanyak 160 citra digunakan sebagai data latih dan 40 citra sebagai data uji. Seluruh citra pada dataset ETL5 berupa citra *grayscale* satu kanal. Citra terlebih dahulu melalui proses *enhancement* sesuai skenario penelitian, yaitu tanpa *enhancement*, HE, AHE, atau CLAHE. Setelah proses *enhancement* dilakukan, citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan ukuran input ResNet-18. Selanjutnya, citra *grayscale* dikonversi menjadi citra tiga kanal (RGB) untuk menyesuaikan spesifikasi input model ResNet-18 pretrained yang dilatih menggunakan citra berwarna pada dataset ImageNet.

Pada data latih, diterapkan data augmentation berupa random rotation sebesar $\pm 10^\circ$ dan random translation sebesar 5% untuk meningkatkan variasi data pelatihan serta membantu mengurangi risiko *overfitting*. Setelah itu, citra dikonversi ke bentuk tensor dan dinormalisasi menggunakan nilai mean dan standard deviation dari ImageNet sebelum digunakan pada proses pelatihan dan pengujian model.

Penelitian ini menerapkan empat skenario *preprocessing*, yaitu tanpa *enhancement* (*baseline*), HE, AHE, dan CLAHE. Penerapan keempat skenario tersebut bertujuan untuk membandingkan pengaruh masing-masing metode terhadap performa klasifikasi model.

2.3.1 Histogram Equalization (HE)

Histogram Equalization merupakan teknik peningkatan kualitas citra yang bertujuan untuk meningkatkan kontras dengan cara meratakan distribusi intensitas piksel secara global (Saifullah, 2020). Metode ini bekerja dengan mentransformasikan nilai intensitas seluruh piksel sehingga distribusi histogram citra menjadi lebih merata dan detail citra yang sebelumnya kurang jelas akibat kontras rendah dapat terlihat lebih jelas. HE menggunakan histogram citra untuk menghitung probabilitas kemunculan setiap tingkat intensitas piksel. Probabilitas tersebut dihitung menggunakan persamaan berikut:

$$p(i) = \frac{n_i}{n} \quad (1)$$

Dimana $p(i)$ adalah probabilitas kemunculan intensitas ke- i , n_i jumlah piksel dengan intensitas ke- i , dan n jumlah seluruh piksel dalam citra. Selanjutnya dihitung fungsi distribusi kumulatif (CDF) menggunakan persamaan:

$$CDF(i) = \sum_{j=0}^i p(j) \quad (2)$$

Dimana $CDF(i)$ merupakan akumulasi probabilitas dari intensitas 0 hingga i . Nilai CDF kemudian digunakan untuk memetakan ulang intensitas piksel:

$$s(i) = \text{round}(CDF(i) \times (L - 1)) \quad (3)$$

2.3.2 Adaptive Histogram Equalization (AHE)

AHE merupakan pengembangan dari HE yang meningkatkan kontras citra secara lokal pada citra. Berbeda dengan HE yang melakukan pemerataan histogram secara global, AHE membagi citra menjadi beberapa bagian kecil (*tile*) kemudian melakukan proses *equalization* pada masing-masing bagian tersebut.

Perhitungan pada AHE tetap menggunakan konsep yang sama seperti HE, yaitu melalui histogram, probabilitas intensitas, fungsi distribusi kumulatif, dan pemetaan ulang nilai piksel. Perbedaanannya terletak pada ruang lingkup



perhitungan, di mana seluruh proses tersebut dilakukan secara lokal pada setiap blok citra, bukan pada keseluruhan citra. Setelah proses *equalization* pada setiap blok, hasilnya digabungkan kembali menggunakan interpolasi untuk menghasilkan transisi yang halus antar bagian citra.

2.3.3 Contrast Limited Adaptive Histogram Equalization (CLAHE)

CLAHE merupakan pengembangan dari AHE yang dirancang untuk mengatasi kelemahan dalam peningkatan noise berlebih. Seperti AHE, CLAHE bekerja secara lokal dengan membagi citra menjadi bagian-bagian kecil dan melakukan proses *equalization* pada setiap bagian citra. Perbedaan utama CLAHE terletak pada penggunaan *clip limit* untuk membatasi distribusi histogram pada setiap blok citra (Suharyanto & Frieyadie, 2020). Histogram yang melebihi batas tertentu akan dipotong, kemudian kelebihan nilainya didistribusikan kembali secara merata ke seluruh tingkat intensitas. Proses ini bertujuan untuk mencegah peningkatan kontras yang terlalu tinggi pada area tertentu yang dapat menyebabkan *noise* menjadi lebih menonjol.

Setelah proses *clipping* dan redistribusi, tahap selanjutnya tetap menggunakan fungsi distribusi kumulatif (*CDF*) dan pemetaan ulang intensitas piksel seperti pada AHE. Pembatasan histogram pada CLAHE dapat dinyatakan menggunakan persamaan berikut:

$$\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (S_{max} - 1) \right) \quad (4)$$

Dimana β adalah nilai batas (*clip limit*), M adalah jumlah piksel dalam satu blok, N adalah jumlah tingkat keabuan, α adalah parameter pengatur *clip limit*, dan S_{max} adalah nilai maksimum skala histogram.

Pada penelitian ini, metode AHE menggunakan parameter *grid size* sebesar 4×4 , sedangkan metode CLAHE menggunakan *clip limit* sebesar 2.0 dan *tile grid size* 4×4 . Parameter tersebut ditentukan berdasarkan pengujian awal (*preliminary experiment*) terhadap beberapa kombinasi nilai *clip limit* dan *tile grid size*. Setiap kombinasi diuji menggunakan konfigurasi model yang sama, kemudian dipilih parameter yang menghasilkan performa klasifikasi terbaik pada dataset ETL5. Berdasarkan hasil pengujian tersebut, digunakan *grid size* 4×4 untuk AHE serta *clip limit* 2.0 dan *tile grid size* 4×4 untuk CLAHE karena memberikan performa klasifikasi yang paling baik pada dataset yang digunakan. Konfigurasi parameter pada setiap metode *enhancement* citra ditunjukkan pada Tabel 1.

Tabel 1. Konfigurasi Enhancement Citra

Metode	Parameter	
	Grid Size	Clip Limit
HE	-	-
AHE	4×4	-
CLAHE	4×4	2.0

2.4 Perancangan Model

Model yang digunakan dalam penelitian ini adalah ResNet-18. Model ini dipilih karena mampu mengekstraksi fitur citra secara efektif serta menjaga stabilitas pelatihan melalui mekanisme *residual connection* dengan kompleksitas yang relatif ringan dibandingkan varian ResNet lainnya (Poningsih et al., 2026). ResNet merupakan arsitektur CNN yang menggunakan konsep *residual learning* untuk mengatasi permasalahan *vanishing gradient* pada jaringan yang dalam. Arsitektur ini menggunakan mekanisme *skip connection* yang memungkinkan informasi dari lapisan sebelumnya diteruskan secara langsung ke lapisan selanjutnya sehingga proses pelatihan menjadi lebih stabil (Thiodorus et al., 2021). Konsep utama pada ResNet adalah mempelajari fungsi residual, yaitu selisih antara input dan output yang dihasilkan oleh jaringan. Secara matematis, konsep *residual learning* dapat dinyatakan sebagai berikut:


$$y = F(x) + x \quad (5)$$

Dimana x menyatakan data masukan, $F(x)$ merupakan hasil pembelajaran dari beberapa lapisan jaringan, dan y adalah output. Pendekatan ini membuat model tidak secara langsung mempelajari hubungan antara input dan output, tetapi hanya mempelajari perubahan atau residual (selisih) dari input tersebut sehingga proses pelatihan menjadi lebih mudah dan stabil.

Pada penelitian ini, ResNet-18 diimplementasikan menggunakan pendekatan *transfer learning* dengan memanfaatkan model yang telah melalui proses pelatihan sebelumnya sebagai *feature extractor* untuk mengenali pola dan bentuk pada citra tulisan tangan huruf Katakana. Melalui pendekatan ini, pengetahuan yang telah dipelajari model pada dataset ImageNet dapat dimanfaatkan untuk membantu proses ekstraksi fitur pada dataset Katakana. Pendekatan *transfer learning* dipilih karena jumlah data pada dataset ETL5 relatif terbatas untuk melatih seluruh parameter ResNet-18 dari awal. Oleh karena itu, seluruh layer feature extraction dipertahankan menggunakan bobot *pretrained* ImageNet dan tidak diperbarui selama proses pelatihan, sedangkan layer *fully connected* pada bagian klasifikasi disesuaikan dengan jumlah kelas pada dataset Katakana dan dilatih ulang. Pendekatan ini memungkinkan model memanfaatkan fitur umum yang telah dipelajari sebelumnya sekaligus membantu mengurangi risiko *overfitting* pada data pelatihan.

Citra input berukuran 224×224 piksel diproses melalui lapisan konvolusi awal berukuran 7×7 dengan 64 filter dan *stride* 2, kemudian dilanjutkan dengan proses *max pooling* untuk mengurangi dimensi citra. Arsitektur ResNet-18

terdiri dari beberapa *residual block* yang tersusun dalam empat tahap konvolusi, yaitu Conv2 hingga Conv5, dengan jumlah filter yang meningkat secara bertahap dari 64 hingga 512. Setiap blok dilengkapi dengan *skip connection* untuk menjaga aliran informasi selama proses pelatihan. Arsitektur ResNet-18 yang diterapkan pada penelitian ini ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur ResNet-18

Detail konfigurasi layer pada arsitektur ResNet-18 yang digunakan dalam penelitian ini ditunjukkan pada Tabel 2.

Tabel 2. Struktur Layer Arsitektur ResNet-18

Stages	Layer	Input Size
Feature Extraction Layer	Conv 1	7x7, 64, stride 2
	Max Pool	
	Conv2	3x3, 64
	Conv3	3x3, 64
		3x3, 128
	Conv4	3x3, 128
		3x3, 256
	Conv5	3x3, 256
		3x3, 512
	Conv5	3x3, 512
Classification Layer	Avg Pool	7x7
	FC	512 → n class

Proses ekstraksi fitur dilakukan melalui *residual block* yang memungkinkan model mengekstraksi fitur dari tingkat sederhana hingga kompleks. Peningkatan jumlah filter pada setiap tahap membantu model mengenali pola karakter tulisan tangan secara lebih detail, sedangkan *skip connection* membantu menjaga stabilitas pelatihan dan mengurangi risiko *vanishing gradient*. Setelah tahap ekstraksi fitur dilakukan, keluaran diproses menggunakan *avg pooling* untuk merangkum informasi fitur, kemudian diteruskan ke lapisan *fully connected* sesuai dengan 46 kelas huruf Katakana. Tahap akhir menerapkan fungsi aktivasi softmax untuk menghasilkan nilai probabilitas pada masing-masing kelas karakter.


2.5 Pelatihan dan Pengujian Model

Tahap pelatihan model menggunakan data training yang sebelumnya telah melewati proses *preprocessing* untuk mempelajari pola karakter huruf Katakana. Model yang digunakan adalah ResNet-18 *pretrained* yang dioptimalkan menggunakan pendekatan *transfer learning*. Pada penelitian ini diterapkan *transfer learning* dengan membekukan (*freeze*) seluruh layer *feature extraction* yang telah memiliki bobot *pretrained* dari ImageNet, sedangkan layer *fully connected* pada bagian klasifikasi diganti dan dilatih ulang sesuai dengan 46 kelas huruf Katakana. Pendekatan ini digunakan untuk memanfaatkan fitur umum yang telah dipelajari model sekaligus mengurangi risiko overfitting akibat jumlah data pelatihan yang relatif terbatas.

Tabel 3. Konfigurasi hyperparameter

Rasio Split Data	Optimizer	Batch Size	Learning Rate	Epoch	Loss Function
80:20	Adam	16	0.001	50	Cross Entropy

Konfigurasi *hyperparameter* yang diterapkan pada penelitian ini disajikan pada Tabel 3. Proses pelatihan memanfaatkan optimizer Adam dengan *learning rate* 0,001 untuk mengatur pembaruan bobot selama pelatihan. *Batch size* sebesar 16 dipilih untuk menjaga keseimbangan antara kebutuhan komputasi dan kestabilan pelatihan, sedangkan jumlah *epoch* ditetapkan sebanyak 50 agar model memiliki waktu yang cukup untuk mempelajari pola data secara optimal, serta fungsi *loss* yang digunakan adalah *cross entropy*.



Gambar 4. Diagram Alur Pelatihan dan Pengujian Model

Berdasarkan alur pada Gambar 4, tahap pelatihan diawali dengan penggunaan data training yang sebelumnya telah melewati proses *preprocessing*, lalu diproses menggunakan model ResNet-18 untuk menghasilkan model terlatih. Setelah tahap pelatihan selesai, dilakukan proses pengujian menggunakan data testing yang tidak ikut digunakan pada tahap pelatihan untuk mengukur kemampuan model dalam mengenali data baru. Citra uji terlebih dahulu melalui tahap *preprocessing* yang sama seperti pada data training, kemudian dimasukkan ke dalam model ResNet-18 yang telah dilatih untuk menghasilkan prediksi kelas.

Hasil prediksi yang diperoleh selanjutnya dibandingkan dengan label sebenarnya untuk mengetahui kinerja model. Penilaian dilakukan menggunakan metrik akurasi, serta didukung oleh confusion matrix dan classification report untuk memberikan informasi yang lebih detail terkait kemampuan model dalam mengklasifikasikan karakter tulisan tangan Katakana.

2.6 Evaluasi Model

Tahap evaluasi dilakukan untuk mengukur performa model ResNet-18 dalam mengenali karakter tulisan tangan Katakana pada setiap skenario *preprocessing*. Evaluasi dilakukan menggunakan *confusion matrix* serta metrik *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* digunakan untuk mengukur tingkat ketepatan prediksi secara keseluruhan, *precision* menunjukkan ketepatan prediksi pada setiap kelas, *recall* mengukur kemampuan model dalam mengenali seluruh data pada suatu kelas, sedangkan *F1-score* digunakan untuk menilai keseimbangan antara *precision* dan *recall*. Persamaan masing-masing metrik ditunjukkan sebagai berikut:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (7)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (8)$$


$$\text{F1 - Score} = \frac{2 \times (\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (9)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian

Penelitian ini menerapkan empat skenario *preprocessing* citra sebelum proses klasifikasi menggunakan model ResNet-18 berbasis *transfer learning*, yaitu tanpa *enhancement* (*baseline*), HE, AHE, dan CLAHE. Tujuan pengujian ini adalah untuk menganalisis pengaruh masing-masing metode *enhancement* terhadap kualitas citra masukan, proses pembelajaran model, serta performa klasifikasi karakter tulisan tangan Katakana yang dihasilkan.

Tabel 4. Perbandingan Citra Hasil Enhancement dan Kinerja Model pada Empat Skenario Preprocessing

	ResNet-18	ResNet-18 + HE	ResNet18 + AHE	ResNet18 + CLAHE
Sampel Citra				
Accuracy (%)	89.51%	82.61%	78.97%	96.68%
Precision (%)	90.48%	85.05%	81.12%	96.93%
Recall (%)	89.51%	82.61%	78.97%	96.68%
F1-Score (%)	89.48%	82.39%	78.77%	96.68%


Tabel 4 menampilkan contoh hasil *preprocessing* pada masing-masing metode beserta hasil evaluasi model yang diperoleh. Berdasarkan visualisasi sampel karakter, terlihat bahwa setiap metode menghasilkan perubahan kontras yang

berbeda terhadap citra masukan. Pada skenario baseline, karakter masih dapat dikenali dengan baik meskipun kontras antara karakter dan latar belakang relatif rendah. Penerapan HE meningkatkan kontras secara global sehingga karakter terlihat lebih tegas, namun pada saat yang sama *noise* pada latar belakang ikut diperkuat sehingga muncul bercak tambahan di sekitar karakter. Sementara itu, AHE melakukan peningkatan kontras secara lokal pada setiap blok citra sehingga menghasilkan perubahan yang lebih agresif dibandingkan HE. Hal tersebut menyebabkan munculnya pola terang dan gelap pada area latar belakang yang menyerupai tekstur tambahan dan mengubah distribusi intensitas di sekitar karakter utama. Sebaliknya, CLAHE menghasilkan peningkatan kontras yang lebih seimbang sehingga karakter terlihat lebih jelas sementara latar belakang tetap relatif homogen dan bersih.

Hasil pengujian menunjukkan bahwa model baseline memperoleh *accuracy* sebesar 89,51%, sedangkan penerapan HE dan AHE menghasilkan *accuracy* masing-masing sebesar 82,61% dan 78,97%. Hasil tersebut mengindikasikan bahwa peningkatan kontras tidak selalu memberikan dampak positif terhadap proses klasifikasi karakter tulisan tangan. Pada citra Katakana, informasi yang paling penting terletak pada bentuk goresan, arah garis, posisi lengkungan, serta hubungan antar bagian karakter. Proses peningkatan kontras secara lokal yang dilakukan oleh AHE menyebabkan variasi intensitas pada area di sekitar karakter menjadi lebih menonjol sehingga menghasilkan pola tekstur tambahan yang sebelumnya tidak terlihat pada citra asli. Perubahan distribusi intensitas tersebut menyebabkan lapisan konvolusi awal pada ResNet-18 tidak hanya merespons tepi karakter utama, tetapi juga ikut mengaktifkan pola-pola lokal pada latar belakang yang tidak berkaitan dengan identitas karakter. Akibatnya, fitur yang dipelajari pada lapisan awal model menjadi kurang berfokus pada bentuk karakter utama sehingga kemampuan model dalam melakukan klasifikasi ikut menurun.

Berbeda dengan HE dan AHE, CLAHE menerapkan mekanisme *clip limit* yang membatasi peningkatan kontras pada setiap blok citra sehingga perubahan intensitas tidak terjadi secara berlebihan. Hasilnya, karakter Katakana terlihat lebih jelas dan memiliki perbedaan intensitas yang lebih tegas terhadap latar belakang. Kondisi tersebut membantu lapisan konvolusi awal pada ResNet-18 untuk lebih fokus mengenali bentuk karakter, seperti tepi, arah goresan, dan pola garis, tanpa terganggu oleh tekstur tambahan pada area latar belakang. Dengan demikian, proses ekstraksi fitur menjadi lebih optimal sehingga model dapat melakukan klasifikasi dengan lebih baik.

Hasil evaluasi pada Tabel 4 menunjukkan bahwa ResNet-18 dengan preprocessing CLAHE memperoleh performa terbaik dengan *accuracy* sebesar 96,68%, *precision* sebesar 96,93%, *recall* sebesar 96,68%, dan *F1-score* sebesar 96,68%. Sementara itu, baseline memperoleh *accuracy* sebesar 89,51%, HE sebesar 82,61%, dan AHE sebesar 78,97%. Hasil tersebut menunjukkan bahwa peningkatan kualitas visual citra tidak selalu berbanding lurus dengan peningkatan performa klasifikasi. Meskipun HE dan AHE menghasilkan tampilan karakter yang lebih tegas, perubahan intensitas yang terlalu agresif justru menurunkan performa klasifikasi. Sebaliknya, CLAHE mampu mempertahankan bentuk karakter sekaligus menghasilkan perbedaan yang lebih jelas antara objek utama dan latar belakang, sehingga model dapat mempelajari fitur karakter dengan lebih baik selama proses ekstraksi fitur.




Gambar 6. Grafik perbandingan training acc dan loss (a) Training Accuracy, (b) Training Loss

Proses pembelajaran model selama pelatihan ditunjukkan pada Gambar 6 melalui grafik training accuracy dan training loss. Berdasarkan grafik tersebut, model dengan preprocessing CLAHE memiliki laju konvergensi paling cepat dan menghasilkan nilai loss yang paling rendah dibandingkan metode lainnya. Hal ini menunjukkan bahwa fitur yang dihasilkan setelah preprocessing CLAHE lebih mudah dipelajari oleh model selama proses pelatihan. Sementara itu, baseline menunjukkan proses pembelajaran yang relatif stabil, namun menghasilkan akurasi akhir yang masih berada di bawah CLAHE. Sebaliknya, HE dan terutama AHE menunjukkan peningkatan akurasi yang lebih lambat serta mempertahankan nilai loss yang lebih tinggi hingga akhir pelatihan, yang mengindikasikan bahwa model mengalami kesulitan dalam mempelajari pola karakter secara optimal. Kondisi tersebut menunjukkan bahwa kualitas citra masukan berpengaruh langsung terhadap kemudahan model dalam mempelajari pola karakter selama proses pelatihan.

Untuk memperjelas pengaruh masing-masing metode terhadap hasil klasifikasi, Gambar 7 menampilkan contoh prediksi model pada keempat skenario pengujian. Terlihat bahwa jumlah kesalahan klasifikasi pada HE dan terutama AHE lebih banyak dibandingkan baseline maupun CLAHE. Sebaliknya, pada skenario CLAHE sebagian besar karakter

berhasil diprediksi dengan benar dengan jumlah kesalahan yang jauh lebih sedikit dibandingkan metode lainnya. Hal ini menunjukkan bahwa peningkatan kontras yang terkontrol mampu membantu model dalam memisahkan informasi karakter dari area latar belakang.

Secara keseluruhan, hasil penelitian menunjukkan bahwa CLAHE merupakan metode enhancement yang paling efektif untuk klasifikasi karakter tulisan tangan Katakana menggunakan ResNet-18 berbasis transfer learning. Penerapan clip limit pada CLAHE mampu menghasilkan pemisahan yang lebih jelas antara karakter sebagai objek utama dan area latar belakang sehingga informasi penting pada karakter dapat dipertahankan dengan lebih baik selama proses ekstraksi fitur. Kondisi tersebut membuat ResNet-18 lebih mudah mempelajari pola karakter dan menghasilkan performa klasifikasi yang lebih tinggi dibandingkan metode enhancement lainnya maupun skenario tanpa enhancement.



Gambar 7. Perbandingan label aktual dan hasil prediksi karakter katakana (a) Baseline, (b) HE, (c) AHE, (d) CLAHE

3.2 Pembahasan

Berdasarkan hasil pengujian, metode CLAHE memberikan performa klasifikasi terbaik dibandingkan baseline, HE, dan AHE dengan accuracy sebesar 96,68%, sedangkan baseline, HE, dan AHE masing-masing memperoleh accuracy sebesar 89,51%, 82,61%, dan 78,97%. Hasil tersebut menunjukkan bahwa keberhasilan suatu metode enhancement tidak hanya ditentukan oleh kemampuannya meningkatkan kontras citra, tetapi juga oleh kemampuannya mempertahankan bentuk asli karakter. Pada penelitian ini, CLAHE mampu meningkatkan kontras tanpa memperkuat noise secara berlebihan sehingga karakter lebih mudah dibedakan dari latar belakang. Kondisi tersebut membantu ResNet-18 mengekstraksi fitur karakter dengan lebih baik dan menghasilkan akurasi klasifikasi yang lebih tinggi. Sebaliknya, HE dan terutama AHE menghasilkan peningkatan kontras yang lebih agresif sehingga variasi intensitas pada latar belakang ikut diperkuat dan mengganggu proses ekstraksi fitur.



Hasil penelitian ini sejalan dengan penelitian Pratama dan Widiarti (2025) yang menyatakan bahwa CLAHE memberikan hasil yang lebih baik dibandingkan HE dan AHE pada citra jalan dengan pencahayaan rendah. Pada penelitian tersebut, CLAHE mampu meningkatkan kontras lokal tanpa menimbulkan noise yang berlebihan sehingga detail objek tetap terjaga. Hasil yang sama juga diperoleh pada penelitian ini, di mana CLAHE menghasilkan performa klasifikasi tertinggi dibandingkan baseline, HE, dan AHE. Meskipun objek yang digunakan berbeda, yaitu citra jalan pada penelitian Pratama dan Widiarti serta karakter tulisan tangan Katakana pada penelitian ini, kedua penelitian menunjukkan bahwa CLAHE lebih efektif karena mampu meningkatkan kualitas citra tanpa menghilangkan informasi penting pada objek. Pada penelitian ini, kemampuan tersebut membantu ResNet-18 mengekstraksi fitur karakter dengan lebih baik sehingga menghasilkan akurasi klasifikasi yang lebih tinggi.

Temuan penelitian ini juga sesuai dengan penelitian Ernawati dkk. (2025) dan Lorinez S dkk. (2025), yang menunjukkan bahwa CLAHE menghasilkan keseimbangan yang lebih baik antara peningkatan kontras dan mempertahankan struktur citra dibandingkan metode histogram lainnya. Pada kedua penelitian tersebut, evaluasi dilakukan menggunakan metrik SSIM, PSNR, dan entropy, yang menunjukkan bahwa CLAHE mampu meningkatkan kualitas citra tanpa menyebabkan distorsi yang berlebihan. Hasil yang serupa juga ditemukan pada penelitian ini, di mana CLAHE memberikan performa klasifikasi terbaik dibandingkan metode lainnya. Meskipun penelitian Ernawati dkk. menggunakan citra bawah air dan Lorinez S dkk. menggunakan foto lama, sedangkan penelitian ini menggunakan karakter tulisan tangan Katakana, ketiga penelitian menunjukkan bahwa kemampuan CLAHE dalam mempertahankan detail objek memberikan hasil yang lebih baik dibandingkan metode histogram lainnya. Pada penelitian ini, karakteristik tersebut membantu ResNet-18 memperoleh representasi fitur yang lebih baik sehingga proses klasifikasi menjadi lebih akurat.

Hasil penelitian ini juga memiliki kesamaan dengan penelitian Muhammad Naufal dkk. (2024), yang menunjukkan bahwa metode HE memberikan performa yang lebih baik dibandingkan AHE. Pola yang sama juga ditemukan pada penelitian ini, di mana HE menghasilkan accuracy lebih tinggi dibandingkan AHE. Meskipun objek yang digunakan berbeda, yaitu citra wajah pada penelitian Muhammad Naufal dkk. dan karakter tulisan tangan Katakana pada penelitian ini, kedua penelitian menunjukkan bahwa AHE cenderung memberikan hasil yang lebih rendah dibandingkan HE. Pada penelitian ini, peningkatan kontras secara lokal yang dilakukan oleh AHE memperkuat variasi intensitas pada area latar belakang sehingga proses ekstraksi fitur oleh ResNet-18 menjadi kurang optimal. Sementara itu, pada penelitian Muhammad Naufal dkk., HE dinilai lebih mampu memperjelas fitur wajah dibandingkan AHE. Temuan tersebut menunjukkan bahwa meskipun alasan yang memengaruhi performa dapat berbeda sesuai karakteristik objek yang digunakan, pola bahwa HE menghasilkan performa yang lebih baik dibandingkan AHE tetap konsisten pada kedua penelitian.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa efektivitas metode enhancement dipengaruhi oleh karakteristik citra dan tujuan penggunaannya. Berbeda dengan penelitian-penelitian sebelumnya yang umumnya mengevaluasi metode HE, AHE, dan CLAHE berdasarkan kualitas visual citra menggunakan metrik seperti MSE, PSNR, SSIM, atau entropy, penelitian ini mengevaluasi pengaruh ketiga metode tersebut terhadap performa klasifikasi karakter tulisan tangan menggunakan ResNet-18. Hasil penelitian menunjukkan bahwa peningkatan kualitas visual citra belum tentu diikuti oleh peningkatan performa klasifikasi apabila metode enhancement mengubah informasi penting yang dibutuhkan model selama proses ekstraksi fitur. Oleh karena itu, CLAHE merupakan metode preprocessing yang paling efektif di antara metode yang diuji untuk klasifikasi karakter tulisan tangan Katakana menggunakan ResNet-18 berbasis transfer learning. Temuan ini juga melengkapi penelitian-penelitian sebelumnya dengan menunjukkan bahwa pemilihan metode enhancement sebaiknya tidak hanya didasarkan pada kualitas visual citra, tetapi juga pada pengaruhnya terhadap performa model klasifikasi.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa pemilihan metode *enhancement* citra memiliki pengaruh yang signifikan terhadap performa klasifikasi karakter tulisan tangan Katakana menggunakan ResNet-18 berbasis *transfer learning*. Hasil penelitian menunjukkan bahwa metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) memberikan performa terbaik dibandingkan baseline, *Histogram Equalization* (HE), dan *Adaptive Histogram Equalization* (AHE) karena mampu meningkatkan kontras citra sekaligus mempertahankan bentuk asli karakter. Sebaliknya, peningkatan kontras yang terlalu agresif pada HE dan terutama AHE menyebabkan *noise* dan variasi intensitas pada latar belakang ikut diperkuat sehingga mengganggu proses ekstraksi fitur pada lapisan konvolusi awal ResNet-18. Kondisi tersebut menyebabkan fitur yang dipelajari model tidak lagi berfokus pada karakter utama sehingga performa klasifikasi mengalami penurunan. Temuan ini menunjukkan bahwa metode enhancement yang meningkatkan kualitas visual citra belum tentu mampu meningkatkan performa model *deep learning*, khususnya pada dataset karakter tulisan tangan yang memiliki detail goresan tipis dan struktur yang sensitif terhadap perubahan intensitas lokal. Oleh karena itu, HE dan terutama AHE kurang sesuai diterapkan pada jenis dataset tersebut, sedangkan CLAHE lebih sesuai digunakan karena mampu menghasilkan pemisahan yang lebih jelas antara karakter dan latar belakang tanpa menimbulkan distorsi lokal yang berlebihan. Selain mengidentifikasi CLAHE sebagai metode *enhancement* yang paling efektif, penelitian ini juga memberikan kontribusi berupa analisis komparatif mengenai pengaruh tiga teknik peningkatan kualitas citra berbasis histogram terhadap performa ResNet-18 pada klasifikasi karakter tulisan tangan Katakana. Temuan tersebut diharapkan



dapat menjadi referensi dalam pemilihan teknik *preprocessing* yang sesuai untuk meningkatkan performa sistem *Handwritten Character Recognition*, khususnya pada pengenalan karakter Jepang berbasis *deep learning*. Keterbatasan penelitian ini terletak pada penggunaan satu jenis arsitektur *deep learning* dan satu jenis dataset sehingga hasil yang diperoleh belum tentu menunjukkan pola yang sama pada model maupun dataset lainnya. Penelitian selanjutnya dapat menguji penerapan CLAHE pada arsitektur *deep learning* lain serta pada dataset karakter tulisan tangan yang berbeda untuk mengetahui konsistensi efektivitas metode tersebut.

REFERENCES

- Alif, M. A. R. (2024). State-of-the-Art Bangla Handwritten Character Recognition Using a Modified Resnet-34 Architecture. *International Journal of Innovative Science and Research Technology*, 9(1). <https://doi.org/https://doi.org/10.5281/zenodo.10538255>
- Al-Taani, A. T., & Ahmad, S. T. (2021). Recognition of Arabic Handwritten Characters Using Residual Neural Networks. *Jordanian Journal of Computers and Information Technology (JJCIT)*, 07(02). <https://doi.org/10.5455/jjcit.71-1615204606>
- Ernawati, Oktoeberza, W. K., Andreswari, D., Sari, J. P., Erlansari, A., Coastera, F. F., & Jayanto, P. D. (2025). Analisis Komparatif Metode Peningkatan Kontras Citra Bawah Air Menggunakan HE, AHE, dan CLAHE. *Rekursif Jurnal Informatika*, 13(1), 59–66. www.ejournal.unib.ac.id/index.php/rekursif
- Kashif, M. (2021). Urdu Handwritten Text Recognition Using ResNet18. *ArXiv*. <http://arxiv.org/abs/2103.05105>
- Lorinez S, Y., Al Hafiz, A. Y., Nasution, A. K., Sitepu, A. D., & Syahputra, H. (2025). Implementasi Teknik Histogram Equalization untuk Meningkatkan Kualitas Citra pada Foto Lama yang Pudar. *Jurnal Mahasiswa Teknik Informatika*, 9(5). <https://doi.org/https://doi.org/10.36040/jati.v9i5.14723>
- Naufal, M., Firmansyah, G. A., Handayani, N. M. K. K., & Al Azies, H. (2024). Penerapan Teknik Adaptive dan Histogram Equalization dalam Pengolahan Citra. 5(1), 9–18. <https://doi.org/https://doi.org/10.24127/ilmukomputer.v5i1.5345>
- Permatasari, K. M., Thamrin, M., & Robihim. (2025). The Consumption of Popular Pop Culture in Japanese Language Culture Learning at the University. *Jurnal Pembelajaran Bahasa Dan Sastra*, 4(3), 517–527. <https://doi.org/10.55909/jpbs.v4i3.732>
- Poningsih, Suhendra, & Zamsuri, A. (2026). Machine Learning with Lightweight CNN (ResNet-18) for Early Detection of Rice Leaf Diseases. 11(4). <https://doi.org/10.33480/jitk.v11i4.7358>
- Pratama, F. P., & Widiarti, A. R. (2025). Enhancing Visibility in Low-Illumination Street Images Using HE, AHE, and CLAHE Techniques. *JITE (Journal of Informatics and Telecommunication Engineering)*, 9(1), 261–270. <https://doi.org/10.31289/jite.v9i1.15451>
- Puspita, A., Dwi, S. *, Prasetya, A., Aditiawan, F. P., Muharrom, M., & Haromainy, A. (2024). Prediksi Gangguan Kesehatan Mental pada Kalangan Mahasiswa Menggunakan Metode Pseudo-Labeling dan Algoritma Regresi Logistik. 4(2). [https://doi.org/10.46880/tamika.Vol4No2\(SEMNASTIK\).pp40-48](https://doi.org/10.46880/tamika.Vol4No2(SEMNASTIK).pp40-48)
- Rahayu, D. W., Setiadi, D., & Yuniarto, D. (2024). Penerapan Deep Learning untuk Klasifikasi Buah Berdasarkan Citra dengan Metode Convolutional Neural Networks. *Indonesian Journal of Education And Computer Science*, 2(3). <https://doi.org/https://doi.org/10.60076/indotech.v2i3.978>
- Respati, R. D., Soim, S., & Fadhli, M. (2025). Development of a Distributed Gradient Boosting Forest Algorithm with Residual Connections in Data Classification. *Jurnal Teknik Informatika (Jutif)*, 6(4), 1811–1830. <https://doi.org/10.52436/1.jutif.2025.6.4.4899>
- Revathi, B., Raju, B. N. V. N., Siva Rama Krishna, B. L. V., Marapatla, A. D. K., & Suryanarayanaraju, S. (2024). Efficient deep learning models for Telugu handwritten text recognition. *Indonesian Journal of Electrical Engineering and Computer Science*, 36(3), 1564–1572. <https://doi.org/10.11591/ijeecs.v36.i3.pp1564-1572>
- Rusyn, V., Boichuk, A., & Mochurad, L. (2025). Cross-Language Transfer-Learning Approach via a Pretrained Preact ResNet-18 Architecture for Improving Kanji Recognition Accuracy and Enhancing a Number of Recognizable Kanji. *Applied Sciences (Switzerland)*, 15(9). <https://doi.org/10.3390/app15094894>
- Saifullah, S. (2020). Analisis Perbandingan HE dan CLAHE pada Image Enhancement dalam Proses Segmenasi Citra untuk Deteksi Fertilitas Telur. *JANAPATI*, 9(1). <https://doi.org/https://doi.org/10.23887/janapati.v9i1.23013>
- Sianturi, F. A., & Sitio, A. S. (2025). Pengaruh Peningkatan Kontras Citra terhadap Akurasi Model Deep Learning dalam Pengenalan Ekspresi Wajah. *Teknik Komputer Dan Teknologi Pendidikan (JUSTIKPEN)*, 5(1). <https://doi.org/10.55338/justikpen.v5i1.326>
- Sudewo, E. D. B., Biddinika, M. K., & Fadlil, A. (2024). Javanese Script Hanacaraka Character Prediction with ResNet-18 Architecture. *JURTEKSI (Jurnal Teknologi Dan Sistem Informasi)*, 10(2), 363–370. <https://doi.org/10.33330/jurteks.v10i2.3017>
- Suharyanto, & Frieyadie. (2020). Analisis Komparasi Perbaikan Kualitas Citra Bawah Air Berbasis Kontras Pemerataan Histogram. *INTI Nusa Mandiri*, 15(1), 95–102. <https://doi.org/10.33480/inti.v15i1.1501>
- Survey Summary on Japanese-Language Education Abroad 2024. (2025, September 3). <https://www.jpj.go.jp/e/>



- Swasono, N. E., Himamunanto, A. R., & Budiati, H. (2024). Pengenalan Karakter Huruf Pada Gambar Tulisan Tangan Menggunakan Algoritma Convolutional Neural Network dan K-Means Clustering. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(4), 1646–1656. <https://doi.org/10.57152/malcom.v4i4.1451>
- Thiodorus, G., Prasetya, A., Ardhani, L. A., & Yudistira, N. (2021). Klasifikasi Citra Makanan/Non Makanan Menggunakan Metode Transfer Learning dengan Model Residual Network. *Teknologi*, 11(2), 74–83. <https://doi.org/10.26594/teknologi.v11i2.2402>