

# IMPLEMENTASI CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION DALAM PENGOLAHAN CITRA PADA ALGORITMA GENERATIVE ADVERSARIAL NETWORK

Syukur Iman Attaqwa <sup>1\*</sup>, Eva Yulia Puspaningrum <sup>2</sup>, Wahyu S.J. Saputra <sup>3</sup>

<sup>1,2,3</sup> Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur; Jalan Rungkut Madya No.1 Gunung Anyar, Surabaya, Indonesia

Received: 5 September 2024

Accepted: 5 Oktober 2024

Published: 12 Oktober 2024

## Keywords:

Pengolahan Citra;  
Contrast Limited Adaptive Histogram Equalization;  
Generative Adversarial Network;.

## Correspondent Email:

[20081010026@student.upnja.tim.ac.id](mailto:20081010026@student.upnja.tim.ac.id)

**Abstrak.** Pengolahan citra, terutama teknik peningkatan kontras seperti Contrast Limited Adaptive Histogram Equalization (CLAHE), berperan krusial dalam meningkatkan kinerja model Generative Adversarial Networks (GANs). Penelitian ini mengevaluasi dampak CLAHE pada akurasi klasifikasi gambar menggunakan GANs. Hasil penelitian menunjukkan bahwa penerapan CLAHE berhasil meningkatkan akurasi klasifikasi sebesar 20% dibandingkan dengan model yang tidak menggunakan CLAHE, mencapai akurasi sebesar 76,20%. Temuan ini mengindikasikan bahwa CLAHE efektif dalam meningkatkan kualitas data gambar, sehingga model GAN dapat belajar fitur-fitur yang lebih relevan dan menghasilkan output yang lebih akurat.

**Abstract.** *Image processing, especially contrast enhancement techniques such as Contrast Limited Adaptive Histogram Equalisation (CLAHE), plays a crucial role in improving the performance of Generative Adversarial Networks (GANs) models. This research evaluates the impact of CLAHE on image classification accuracy using GANs. The results showed that the application of CLAHE successfully improved the classification accuracy by 20% compared to the model that did not use CLAHE, achieving an accuracy of 76.20%. This finding indicates that CLAHE is effective in improving the quality of image data, so that the GAN model can learn more relevant features and produce more accurate output.*

## 1. PENDAHULUAN

Pengolahan citra sangatlah berpengaruh khususnya pada saat melakukan pelatihan suatu model yang berhubungan dengan citra seperti klasifikasi gambar. Menurut penelitian yang dilakukan Munir pada tahun 2004, jika suatu gambar mengalami penurunan kualitas seperti *noise*, warna yang terlalu kontras ataupun gambar yang blur membuat informasi yang berada gambar tersebut berkurang yang menyebabkan kualitas model menjadi menurun [1]. Hal ini disebabkan oleh fakta bahwa model pembelajaran mesin pada dasarnya belajar dari pola-pola yang ada dalam data. Ketika data

tersebut terkontaminasi oleh *noise* atau artefak lainnya, model akan cenderung mempelajari pola-pola yang tidak relevan, sehingga menghasilkan prediksi yang kurang akurat. Beberapa algoritma, seperti *Generative Adversarial Networks* (GANs), dikenal sangat sensitif terhadap kualitas data gambar[2]. GANs terdiri dari dua jaringan neural yang saling bersaing: generator yang berusaha menghasilkan data sintesis yang mirip dengan data asli, dan diskriminator yang bertugas membedakan antara data asli dan data sintesis. Kualitas data pelatihan yang buruk dapat menyebabkan kondisi di mana generator hanya

menghasilkan satu jenis output yang monoton, atau bahkan menghasilkan output yang tidak realistis.

Pada penelitian ini mengusulkan teknik pengolahan citra tambahan yaitu *Contrast Limited Adaptive Histogram Equalization* atau disingkat CLAHE. Secara umum, CLAHE merupakan pengembangan lebih lanjut dari proses histogram ekualisasi biasa dengan melakukan pada tiap bagian kecil atau blok gambar dan menambahkan mekanisme pembatasan atau normalisasi kontras pada setiap blok tersebut [3]. Keunggulan dari menggunakan CLAHE terletak pada kemampuannya untuk meningkatkan kontras lokal tanpa memperburuk noise, sehingga menghasilkan citra yang lebih detail dan memiliki dynamic range yang lebih luas [3]. Dengan menambahkan proses ini diharapkan pada proses pelatihan algoritma GANs menjadi lebih stabil pada saat pelatihan dan menghasilkan kualitas gambar yang bagus.

## 2. TINJAUAN PUSTAKA

*Generative Adversarial Networks* atau disingkat GANs merupakan suatu algoritma pembelajaran mesin generatif yang terdiri dari dua jaringan neural yang saling bersaing yaitu model generator dan diskriminator [4]. Generator bertugas menciptakan data baru yang mirip dengan data pelatihan, sedangkan diskriminator berusaha membedakan antara data asli dan data yang dihasilkan oleh generator. Melalui proses kompetisi yang berkelanjutan ini, GANs mampu menghasilkan data sintesis yang sangat realistis dan beragam, seperti gambar, video, atau bahkan teks.

*Contrast Limited Adaptive Histogram Equalization* atau disingkat menjadi CLAHE adalah sebuah teknik peningkatan kontras citra adaptif yang merupakan pengembangan lebih lanjut dari histogram ekualisasi biasa. Berbeda dengan histogram ekualisasi global yang menerapkan transformasi yang sama pada seluruh citra [5], CLAHE membagi citra menjadi blok-blok kecil (tiles) dan kemudian menerapkan histogram ekualisasi pada setiap blok secara terpisah [3]. Hal ini memungkinkan CLAHE untuk meningkatkan kontras lokal pada setiap bagian citra, sehingga menghasilkan detail yang lebih baik, terutama pada daerah dengan kontras rendah. CLAHE pertama kali diperkenalkan oleh Karel Zuiderveld pada

tahun 1994 dan telah menjadi salah satu teknik peningkatan kontras yang paling populer dalam pengolahan citra digital [6]. CLAHE banyak digunakan dalam berbagai aplikasi, seperti pengolahan citra medis, pengenalan karakter optik, dan pengolahan citra satelit [3].

## 3. METODE PENELITIAN

Dalam penelitian ini, terdapat beberapa langkah yang direncanakan untuk mencapai tujuan yang telah ditetapkan. Langkah pertama adalah proses perancangan. Setelah perancangan selesai, penelitian akan dilanjutkan dengan tahapan pemrosesan data, pelatihan model, dan pengujian.

### 3.1. Pemrosesan data

Pada tahap ini terdapat dua data yang akan digunakan yaitu data Extended Cohn Kanade (CK+) yang akan digunakan sebagai data latih dan data Taiwanese Facial Expression Image Database (TFEID) yang akan digunakan sebagai data uji.

Data CK+ merupakan data gambar ekspresi dari wajah manusia yang berusia sekitar 18 sampai 50 tahun [7]. Total data keseluruhan dari dataset CK+ yaitu 920 gambar yang terdiri dari 8 ekspresi berbeda. Berikut untuk contoh gambar pada data CK+.



Gambar 1 Contoh data CK+

Sementara itu, data TFEID merupakan data ekspresi wajah orang Tionghoa atau wajah orang taiwan dengan total subjek yang didapatkan yaitu 40 orang [4]. Total data TFEID sebesar 336 data yang terdiri dari 8 ekspresi berbeda atau sama dengan data CK+ sebelumnya. Pemilihan data ini didasarkan pada karakteristik yang berbeda dengan data yang akan digunakan pelatihan mode yaitu data CK+ yang lebih ke wajah orang barat. Hal tersebut dapat dilihat pada contoh gambar data TFEID berikut ini.

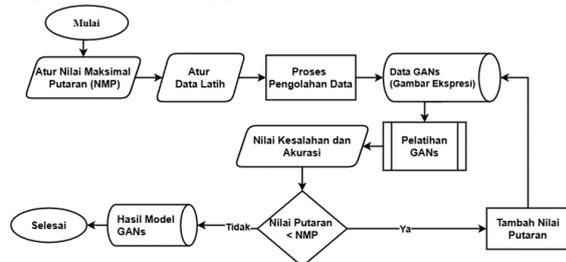


Gambar 2 Contoh data TFEID

Untuk pengolahan gambar, selain menggunakan CLAHE pada penelitian ini

menggunakan beberapa teknik atau langkah tambahan seperti data augmentasi untuk memperbanyak data, konversi gambar ke gray untuk memudahkan pembelajaran model [8], dan *Multi-Task Cascaded Convolutional Network* (MTCNN) untuk memotong gambar pada bagian wajah saja [9].

**3.2. Pelatihan Model**



Gambar 4 Alur pelatihan model

Proses pelatihan model GAN dimulai dengan menyiapkan data dan menetapkan jumlah maksimum iterasi. Model dilatih secara iteratif dengan membandingkan gambar asli dan gambar palsu yang dihasilkan oleh generator. Kinerja model dievaluasi menggunakan metrik *cross-entropy* untuk mengukur perbedaan antara distribusi probabilitas hasil prediksi dengan data asli [10]. Secara umum, fungsi *cross-entropy* bekerja dengan menghitung perbedaan distribusi probabilitas dari hasil prediksi model, yang dapat dihitung menggunakan probabilitas kejadian dari P dan Q sebagai berikut ini [11].

$$H(P, Q) = - \sum_x P(x) \log(Q(x)) \quad (1)$$

Di mana:

- H(P, Q) adalah fungsi cross entropy
- P(x) distribusi target probabilitas dari data
- Q(x) distribusi perkiraan yang dihasilkan model

Untuk menghitung kesalahan pada model generator, terdapat beberapa perhitungan tambahan, salah satunya adalah Mean Square Error (MSE), yang membandingkan data baru dengan gambar asli yang digunakan sebagai data ekspresi pada model generator[12]. Mean Square Error (MSE) adalah fungsi kesalahan yang digunakan untuk mengukur sejauh mana garis regresi menyimpang dari kumpulan titik data, dengan menghitung selisih kuadrat antara data aktual dan data yang diprediksi oleh model [11]. Karena MSE menghitung rata-rata kuadrat dari perbedaan antara nilai aktual dan prediksi, fungsi ini lebih sensitif terhadap outlier dibandingkan fungsi kesalahan lainnya. Rumus MSE adalah sebagai berikut [7]:

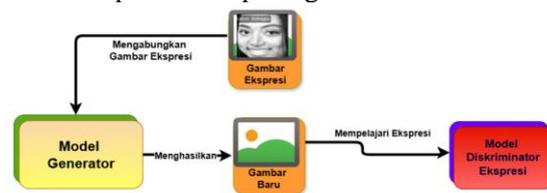
$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2)$$

Di mana:

- N merupakan jumlah total data atau sampel
- $y_i$  nilai aktual pada data ke-i
- $\hat{y}_i$  nilai prediksi model pada data ke-i
- $(y_i - \hat{y}_i)^2$  Selisih kuadrat antara nilai aktual dan nilai prediksi, yang diambil untuk setiap data i.

**4. HASIL DAN PEMBAHASAN**

Pada tahap pelatihan model, model GAN akan mempelajari data yang telah ditentukan sebelumnya yang berisi klasifikasi 8 ekspresi wajah. Maka dari itu model diskriminator selain membedakan data asli dan data palsu pada penelitian ini juga digunakan untuk membedakan 8 ekspresi tersebut yang pada penelitian ini berfokus hanya 5 ekspresi saja. Selain itu, tujuan dengan klasifikasi ini agar mengetahui akurasi yang didapatkan pada algoritma GANs dalam hal mempelajari suatu gambar. Secara umum untuk alur algoritma GANs dapat dilihat pada gambar berikut ini.

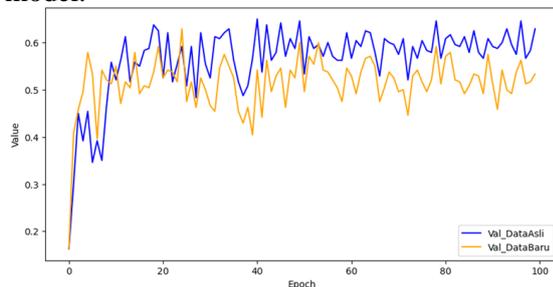


Gambar 3 Gambaran umum algoritma GANs

Pada penelitian ini, model generator dibuat berbeda dengan memerlukan gambar ekspresi sebagai gambar acuan untuk membuat gambar baru. Tujuan dari model generator ini adalah untuk memastikan kualitas pengolahan citra apakah masih sama dengan gambar sebelumnya.

Secara umum, model GAN dalam penelitian ini dibagi menjadi dua kategori: model yang menggunakan teknik peningkatan kontras Contrast Limited Adaptive Histogram Equalization (CLAHE) dan model yang menggunakan histogram ekualisasi biasa. Proses pelatihan dilakukan selama 100 iterasi, dengan evaluasi kinerja model dilakukan setiap 10 iterasi untuk memantau perkembangan model. Analisis mendalam akan difokuskan pada model yang menggunakan CLAHE, sedangkan model yang menggunakan histogram ekualisasi biasa akan digunakan sebagai pembanding dalam tahap pengujian. Sebagai tahap awal, berikut disajikan hasil validasi yang membandingkan akurasi antara

data asli dan data baru yang dihasilkan oleh model.

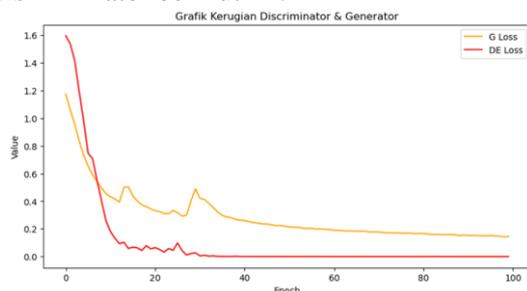


Gambar 5 Grafik validasi model

Berdasarkan pengamatan pada grafik akurasi model diskriminator, terdapat beberapa poin penting yang cukup menarik:

- **Peningkatan awal yang signifikan.** Pada iterasi awal model diskriminator menunjukkan peningkatan akurasi yang cukup tajam. Hal ini mengindikasikan bahwa pada tahap awal pelatihan, model dengan cepat belajar membedakan antara data asli dan data sintesis yang dihasilkan oleh generator.
- **Ketidakstabilan.** Setelah iterasi ke-10, kinerja model diskriminator menjadi tidak stabil, dengan fluktuasi yang cukup besar. Bahkan, pada beberapa titik, akurasi turun hingga sekitar 40%.
- **Mode Collapse.** Generator mungkin mulai menghasilkan data yang sangat mirip satu sama lain, sehingga sulit bagi diskriminator untuk membedakannya.

Untuk memahami lebih lanjut dua poin tersebut maka dilakukan analisis tambahan dengan melakukan pengamatan pada grafik kerugian model generator dan model diskriminator berikut ini.



Gambar 6 Grafik kerugian model

Berdasarkan gambar 7, dapat dilihat model dapat mempelajari dengan cepat pada 10 putaran awal dan secara bertahap turun setelah putaran 40. Terdapat sedikit lonjakan kerugian pada pertengahan putaran 20 sampai 40 dengan nilai maksimal 0.6 pada model generator dan

0.2 pada model diskriminator. Dari hal tersebut terdapat beberapa poin penting yang didapatkan yaitu:

- **Kapasitas Model.** Model belum mencapai kapasitas maksimumnya dalam mempelajari kompleksitas data, sehingga masih memiliki ruang untuk perbaikan.
- **Ketidakseimbangan Antara Generator dan Diskriminator.** Penurunan kinerja juga bisa disebabkan oleh ketidakseimbangan dalam pelatihan antara generator dan diskriminator. Jika salah satu model terlalu dominan, dapat menghambat pembelajaran model lainnya.
- **Overfitting.** Overfitting terjadi ketika model terlalu menghafal data pelatihan sehingga tidak dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

Secara umum, baik itu menggunakan CLAHE ataupun tanpa CLAHE hasil yang didapatkan model sama saja bahkan sedikit lebih baik jika menggunakan CLAHE.

Untuk memahami lebih detail maka dilakukan proses pengujian untuk memastikan kembali hasil model GANs. Pada bagian pengujian terdapat beberapa skenario yaitu skenario “Alpha” menggunakan sebagian data latih atau 10% dari total keseluruhan data latih.

Untuk memvalidasi hasil ini lebih lanjut, pada penelitian ini melakukan pengujian tambahan yaitu pada skenario Beta dan Delta. Skenario Beta menggunakan data uji yang telah disiapkan sebelumnya, sedangkan skenario Delta merupakan skenario kontrol tanpa menggunakan CLAHE. Hasil pengujian pada kedua skenario ini diharapkan dapat memberikan gambaran yang lebih jelas mengenai efektivitas CLAHE dalam meningkatkan kinerja model GAN.

Tabel 1. Hasil Pengujian Model

Skenario	Akurasi	Presisi	Recall	F1 Skor
Alpha	76,20%	76,59%	75,34%	74,55%
Beta	54,17%	56,45%	55,60%	49,54%
Delta	50,42%	44,07%	53,70%	45,84%

Berdasarkan hasil tersebut, data asli terbukti lebih akurat dalam klasifikasi dibandingkan data sintesis yang dihasilkan oleh model generator. Hal ini disebabkan oleh keterbatasan model generator dalam mempelajari detail kompleks dari data pelatihan. Akibatnya, data

baru yang dihasilkan cenderung memiliki karakteristik yang berbeda secara signifikan dari data asli, sehingga sulit bagi model diskriminator untuk mengklasifikasikannya dengan benar. Hal tersebut terbukti jika model generator menggunakan data latih akan menghasilkan gambar berikut ini.



Gambar 7 Contoh hasil skenario Alpha

Detail yang didapatkan cukup akurat baik itu dari mata, hidung hingga bagian mulutnya. Hal tersebut membuat secara umum model generator dapat bekerja dengan baik dalam hal membuat data baru berdasarkan data latih. Akan tetapi jika model generator menggunakan data uji atau data yang benar - benar berbeda didapatkan hasil berikut ini.



Gambar 8 Contoh hasil skenario Beta

Berdasarkan gambar tersebut, model generator kesulitan dalam mensintesis wajah pada beberapa bagian seperti bagian mulut yang tidak sempurna dan pada bagian mata yang hasil didapatkan tidak jelas antara pupil mata dengan garis mata.

## 5. KESIMPULAN

Dari beberapa penjelasan sebelumnya dapat disimpulkan bahwa CLAHE secara umum dapat membantu peningkatan sekitar 20%, akan tetapi pada kondisi tertentu hasil yang didapatkan tidak dapat meningkatkan akurasi terlalu signifikan pada data yang benar - benar baru. Selain itu terdapat beberapa catatan pada model GANs diantaranya yaitu:

- a. **Memperbanyak waktu latihan.** Pada penelitian ini dirasa hasil yang didapatkan kurang maksimal karena hanya melakukan 100 iterasi pada proses pelatihan.
- b. **Memperbaiki alur pelatihan model.** Pada penelitian ini, untuk alur pelatihan kurang kompleks dan arsitektur model yang umum yang menyebabkan model GANs menjadi *overfitting* dan memasuki mode collapse.
- c. **Memperbanyak variasi data.** Selain dari faktor model, faktor data yang kurang bervariasi dan kualitas yang standar

membuat model secara umum tidak dapat memahami secara utuh perbedaan tiap fitur pada gambar khususnya jika dihadapkan data yang benar - benar baru.

## UCAPAN TERIMA KASIH

Ucapan terima kasih yang sebesar-besarnya penulis sampaikan kepada kedua orang tua tercinta, dosen pembimbing yang telah memberikan arahan yang sangat berharga, serta rekan-rekan seperjuangan yang telah bersedia meluangkan waktu untuk berbagi pandangan dan saran. Dukungan dan kontribusi dari seluruh pihak sangat berarti dalam menyempurnakan karya tulis ini.

## DAFTAR PUSTAKA

- [1] R. Munir, Pengolahan Citra Digital, Westriningsih: Penerbit Andi, 2010. \.
- [2] P. D. Kusuma, "Machine Learning Teori, Program, Dan Studi Kasus," Deepub, 2020.
- [3] S. M. A. A. Garima Yadav, "Contrast limited adaptive histogram equalisation based enhancement for real time video system," 2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI), pp. 2392-2397, 2014.
- [4] H. H. Y. C. Siyue Xie, "Facial Expression Recognition with Two-branch Disentangled Generative Adversarial Network," IEEE Transactions on Circuits and Systems for Video Technology, vol. 31, no. 6, p. 2021, 2359-2371.
- [5] I. M. O. W. I. D. D. H. Gusti Ngurah Agung Meyhendra Wijaya, "Ekualisasi Histogram Dan Algoritma Kultural Untuk Segmentasi Citra Pantai," SISFOTEK, vol. 6, no. 1, pp. 111-116, 2022.
- [6] Zuiderveld, K. (1994). Contrast limited adaptive histogram equalisation. Graphics gems IV, 474-485.
- [7] P. Lucey, J. F. Cohn, T. Kanade, J. Saragih, Z. Ambadar and I. Matthews, "The Extended Cohn-Kanade Dataset (CK+): A complete dataset for action unit and emotion-specified expression," 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Workshops, San Francisco, CA, USA, 2010, pp. 94-101
- [8] C. N. Santi, "Mengubah Citra Berwarna Menjadi Gray-Scale dan Citra biner," Jurnal Teknologi Informasi DINAMIK, vol. 16, no. 1, pp. 14-19, 2011
- [9] D. P. K. F. A. B. Krisna Dwi Anggara, "Implementasi Algoritma MTCNN dalam Mekanisme Autentikasi berbasis Pengenalan Wajah," Jurnal Pengembangan Teknologi

Informasi Dan Ilmu Komputer, vol. 7, no. 8, pp. 3613-3621, 2023.

- [10] A. N. Sriani, "IMPLEMENTASI DEEP LEARNING UNTUK MENGIDENTIFIKASI UMUR MANUSIA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)," ITET (Jurnal Informatika dan Teknik Elektro Terapan), vol. 12, no. 3, pp. 1836-1843, 2024.
- [11] A. Nisha, "Loss Functions: An Explainer," KDnuggets, 2022.
- [12] G. E. S. Anugrah Akbar Praramashan, "Cycle Generative Adversarial Networks Algorithm With Style Transfer For Image Generation," arXiv preprint arXiv:2101.03921., 2021.