

BAB 1 PENDAHULUAN

1.1 Latar Belakang

Evolusi model generatif dalam ranah Kecerdasan Buatan (*Artificial Intelligence* atau AI), khususnya pada bidang *deep learning*, telah mendorong perkembangan yang signifikan dalam beberapa tahun terakhir. Salah satu pencapaian penting dalam perkembangan tersebut adalah hadirnya model generatif yang mampu mempelajari distribusi data asli sehingga dapat menghasilkan data baru yang memiliki karakteristik serupa dengan data pelatihan. Teknologi ini telah diterapkan pada berbagai bidang, seperti sintesis citra digital, pembuatan karya seni, simulasi data, hingga aplikasi di bidang medis [1].

Di antara berbagai pendekatan model generatif, *Generative Adversarial Network* (GAN) merupakan salah satu metode yang paling banyak digunakan. GAN bekerja melalui mekanisme kompetitif (*adversarial*) antara dua jaringan saraf, yaitu *Generator* dan *Discriminator*. *Generator* bertugas menghasilkan data sintetis, sedangkan *Discriminator* bertugas membedakan antara data asli dan data hasil generasi. Melalui proses pelatihan yang berlangsung secara kompetitif, kedua jaringan tersebut saling meningkatkan kemampuannya sehingga *Generator* mampu menghasilkan citra yang semakin mendekati distribusi data asli [1].

Meskipun memiliki kemampuan yang baik dalam menghasilkan citra sintetis, proses pelatihan GAN konvensional masih menghadapi berbagai kendala, seperti ketidakstabilan proses pelatihan (*training instability*), fenomena *mode collapse*, serta sensitivitas yang tinggi terhadap konfigurasi model. Untuk mengatasi beberapa keterbatasan tersebut dikembangkan *Deep Convolutional Generative Adversarial Network* (DCGAN), yaitu arsitektur GAN yang mengintegrasikan *Convolutional Neural Network* (CNN) sehingga mampu meningkatkan stabilitas pelatihan dan kualitas citra yang dihasilkan. Namun demikian, performa DCGAN tetap sangat dipengaruhi oleh pemilihan *hyperparameter* yang digunakan selama proses pelatihan [2].

Hyperparameter seperti *Latent dimension* dan *Learning rate* memiliki pengaruh yang signifikan terhadap kemampuan *Generator* dalam mempelajari

distribusi data, stabilitas proses pelatihan, serta kualitas citra sintetis yang dihasilkan. Nilai *Latent dimension* menentukan ukuran ruang laten (*latent space*) yang digunakan sebagai representasi awal dalam proses pembangkitan citra, sedangkan *Learning rate* menentukan besarnya langkah pembaruan bobot pada setiap proses optimasi. Pemilihan nilai yang kurang tepat pada kedua *hyperparameter* tersebut dapat menyebabkan proses pelatihan menjadi tidak stabil, memperlambat konvergensi, bahkan menurunkan kualitas citra hasil *image generation*. Hingga saat ini, belum terdapat konfigurasi *hyperparameter* yang dapat dianggap paling optimal untuk seluruh karakteristik dataset [3].

Berdasarkan kondisi tersebut, penelitian ini menerapkan pendekatan analisis komparatif melalui beberapa variasi konfigurasi eksperimen. Variasi yang dimaksud merupakan kombinasi nilai dua *hyperparameter* utama, yaitu *Latent dimension* dan Learning Rate, sehingga setiap konfigurasi dapat dibandingkan secara sistematis untuk mengetahui pengaruh masing-masing *hyperparameter* terhadap stabilitas proses pelatihan maupun kualitas citra yang dihasilkan. Dengan pendekatan ini, penelitian tidak melakukan perubahan pada arsitektur DCGAN, melainkan berfokus pada analisis pengaruh variasi konfigurasi *hyperparameter* terhadap performa model.

Untuk menguji efektivitas setiap konfigurasi eksperimen, penelitian ini menggunakan dataset CelebA sebagai data pelatihan dan pengujian. Dataset tersebut dipilih karena merupakan salah satu *benchmark* dataset yang banyak digunakan dalam penelitian *image generation* serta memiliki karakteristik citra wajah yang beragam sehingga sesuai untuk mengevaluasi kemampuan model DCGAN dalam mempelajari distribusi data dan menghasilkan citra sintetis yang realistis [4].

Berdasarkan latar belakang tersebut, penelitian ini difokuskan pada analisis komparatif kinerja model DCGAN berdasarkan variasi konfigurasi *hyperparameter*, dengan memvariasikan nilai *Latent dimension* dan Learning Rate, sedangkan arsitektur model, jumlah *epoch*, *batch size*, dan *optimizer* dipertahankan tetap pada seluruh skenario eksperimen. Pendekatan ini bertujuan untuk menganalisis pengaruh variasi kedua *hyperparameter* tersebut terhadap stabilitas proses pelatihan dan kualitas citra hasil *image generation*, serta menentukan konfigurasi

yang memberikan performa terbaik. Berdasarkan fokus penelitian tersebut, tugas akhir ini diberi judul : “ANALISIS KOMPARATIF KINERJA MODEL DCGAN BERDASARKAN VARIASI DAN *HYPERPARAMETER* PADA IMAGE GENERATION”.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas dapat dirumuskan permasalahan utama dalam penelitian ini sebagai berikut:

1. Bagaimana pengaruh variasi *Latent Dimension* terhadap stabilitas konvergensi dan kualitas visual citra yang dihasilkan DCGAN?
2. Bagaimana pengaruh variasi *Learning Rate* terhadap efektivitas interaksi antara *Generator* dan *Discriminator* selama proses pelatihan?
3. Kombinasi *hyperparameter Latent Dimension* dan *Learning Rate* manakah yang menghasilkan performa optimal DCGAN berdasarkan kualitas visual dan stabilitas pelatihan?

1.3 Batasan Masalah

Untuk secara efektif melestarikan konsentrasi dan penggambaran tujuan penelitian, kendala dan keterbatasan yang terkait dengan berbagai masalah yang dibahas dalam penyelidikan ini dapat diartikulasikan sebagai berikut:

1. Kerangka kerja komputasi yang digunakan untuk tujuan upaya penelitian ini diidentifikasi sebagai *Deep Convolutional Generative Adversarial Network* (DCGAN), yang telah diakui karena kemampuannya yang signifikan dalam menghasilkan gambar berkualitas tinggi melalui proses pelatihan permusuhan yang rumit yang melibatkan dua jaringan saraf.
2. Dataset yang digunakan untuk tujuan pengujian dan memvalidasi kinerja model selama penelitian ini adalah koleksi Celeb-A , tolok ukur mapan yang terdiri dari beragam gambar wajah Artis terkait mode yang dirancang khusus untuk memfasilitasi evaluasi algoritma pembelajaran mesin di bidang klasifikasi gambar.
3. Variasi yang dianalisis dalam penelitian ini dibatasi pada dua *hyperparameter* utama, yaitu *Latent dimension* dan *Learning Rate*, yang dijadikan sebagai variabel eksperimen untuk mengamati pengaruhnya

terhadap kualitas citra sintetis dan stabilitas proses pelatihan model DCGAN. Sementara itu, arsitektur DCGAN, jumlah *epoch*, *batch size*, serta *optimizer* dipertahankan tetap pada seluruh skenario eksperimen agar setiap perubahan kinerja model dapat diatribusikan secara langsung kepada variasi kedua *hyperparameter* tersebut.

4. Penilaian kinerja model dilakukan melalui pendekatan kualitatif yang melibatkan analisis visual menyeluruh dari gambar yang dihasilkan, memungkinkan pemeriksaan mendalam tentang kualitas dan realisme output, di samping pengamatan sistematis grafik kerugian yang menggambarkan proses pelatihan dari waktu ke waktu, menggambarkan perilaku konvergensi dan stabilitas algoritma pembelajaran.

1.4 Tujuan

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Menganalisis pengaruh variasi *Latent Dimension* terhadap stabilitas konvergensi dan kualitas visual citra yang dihasilkan DCGAN.
2. Menganalisis pengaruh variasi *Learning Rate* terhadap efektivitas interaksi antara *Generator* dan *Discriminator* selama proses pelatihan.
3. Menentukan kombinasi *hyperparameter Latent Dimension* dan *Learning Rate* yang menghasilkan performa optimal DCGAN berdasarkan kualitas visual dan stabilitas pelatihan.

1.5. Manfaat

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:


1. Manfaat Teoretis Penelitian ini diharapkan mampu memperkaya literatur dan pemahaman konseptual di bidang *deep learning*, khususnya pada model *Generative Adversarial Network* (GAN). Secara spesifik, studi ini memberikan kontribusi ilmiah mengenai sejauh mana variasi *hyperparameter* memengaruhi performa arsitektur DCGAN dalam menghasilkan citra (*image generation*).
2. Manfaat Praktis Hasil penelitian ini diproyeksikan menjadi panduan teknis bagi para pengembang maupun peneliti dalam mengoptimalkan konfigurasi *hyperparameter* pada DCGAN. Tujuannya adalah untuk mencapai stabilitas pelatihan yang lebih baik serta meningkatkan kualitas visual citra

yang dihasilkan. Selain itu, temuan ini dapat menjadi fondasi bagi pengembangan model generatif di masa mendatang.

3. Manfaat Metodologis Studi ini menawarkan kerangka kerja metodologis terkait penerapan eksperimen terkontrol untuk menguji kinerja model generatif. Prosedur evaluasi yang diterapkan dapat diadaptasi sebagai referensi standar bagi penelitian selanjutnya yang berfokus pada pengujian efektivitas model *image generation*.

1.6 Kerangka Berfikir

Kerangka berpikir penelitian ini dirancang untuk memetakan alur logis penelitian secara sistematis, mulai dari identifikasi konteks yang lebih luas hingga luaran spesifik yang diharapkan, sebagaimana divisualisasikan pada Gambar 2.1.



Gambar 2.1 kerangka pemikiran

Alur pemikiran dalam penelitian ini berpijak pada pesatnya kemajuan *deep learning* yang mendorong pemanfaatan model generatif, khususnya *Generative Adversarial Network* (GAN), untuk memproduksi citra sintetis. Meskipun GAN memiliki potensi besar dalam tugas *image generation*, model ini masih memiliki kendala krusial seperti ketidakstabilan selama fase pelatihan, risiko *mode collapse*, serta ketergantungan yang tinggi terhadap konfigurasi *hyperparameter*, khususnya *Learning rate* dan Latent Dimension.

Sebagai upaya mitigasi, studi literatur menunjukkan bahwa *Deep Convolutional Generative Adversarial Network* (DCGAN) dikembangkan dengan mengintegrasikan struktur *Convolutional Neural Network* (CNN) untuk meningkatkan stabilitas dan kualitas visual citra. Kendati demikian, efektivitas DCGAN tetap sangat bergantung pada variasi desain jaringan dan ketepatan pemilihan *hyperparameter* yang diimplementasikan [5].

Fokus utama penelitian ini diarahkan pada minimnya informasi mengenai dampak fluktuasi *hyperparameter* terhadap arsitektur DCGAN yang bersifat tetap dalam proses sintesis citra. Sebagai solusi, penelitian ini mengimplementasikan analisis komparatif untuk menguji performa model dengan memodifikasi parameter kunci seperti *latent dimension* dan *learning rate*. Pendekatan yang digunakan adalah eksperimen terkontrol berbasis dataset Celeb-A, di mana setiap konfigurasi model dilatih serta dievaluasi secara independen.

Evaluasi keberhasilan model dilakukan melalui penilaian visual pada citra hasil generasi serta pemantauan kurva *loss* pada *Generator* dan *Discriminator* sepanjang fase pelatihan. Hasil akhir dari studi ini diharapkan mampu memberikan pemahaman mendalam mengenai korelasi antara variasi *hyperparameter* dan kinerja DCGAN, sekaligus merumuskan rekomendasi konfigurasi parameter paling ideal untuk menghasilkan citra berkualitas tinggi dengan proses pelatihan yang stabil.