

PEMBUATAN MOTIF BATIK MENGGUNAKAN CONDITIONAL GENERATIVE ADVERSARIAL NETWORKS (CGAN)

Muhammad Mahdy Al Akbar*

Program Studi Sarjana Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Surabaya

Email : mahdialakbar@gmail.com

Abstrak

Stagnasi inovasi motif batik menjadi salah satu tantangan dalam pelestarian dan pengembangan batik sebagai warisan budaya Indonesia. Penelitian ini bertujuan untuk mengembangkan model *Conditional Generative Adversarial Networks* (CGAN) dalam menghasilkan motif batik baru yang memiliki keragaman pola dan kualitas visual yang baik. Dataset berupa citra motif batik dari berbagai daerah di Indonesia diproses melalui *resizing* ke resolusi 128×128 piksel, normalisasi, serta augmentasi geometris. Model CGAN dilatih menggunakan beberapa konfigurasi parameter, meliputi variasi jumlah *epoch* dan *learning rate*. Evaluasi kinerja model dilakukan secara kuantitatif menggunakan *Inception Score* (IS) dan *Fréchet Inception Distance* (FID). Hasil penelitian menunjukkan bahwa konfigurasi pelatihan dengan 1.000 *epoch* dan *learning rate* 0,0001 menghasilkan performa terbaik dengan nilai IS sebesar $3,10 \pm 0,06$ dan FID sebesar 32,40. Hasil ini mengindikasikan bahwa pemilihan parameter pelatihan yang tepat berpengaruh signifikan terhadap kualitas dan keragaman motif batik yang dihasilkan oleh model CGAN.

Kata Kunci: Batik, *Deep Learning*, *Conditional Generative Adversarial Networks*, *Inception Score*, *Fréchet Inception Distance*.

Abstract

The stagnation of innovation in batik motifs has become a challenge in preserving and developing batik as Indonesia's cultural heritage. This study aims to develop a *Conditional Generative Adversarial Networks* (CGAN) model to generate new batik motifs with improved diversity and visual quality. The dataset consists of batik motif images from various regions in Indonesia, which are preprocessed through *resizing* to 128×128 pixels, normalization, and geometric augmentation. The CGAN model is trained using several parameter configurations, including variations in the number of epochs and learning rate. Model performance is quantitatively evaluated using the *Inception Score* (IS) and *Fréchet Inception Distance* (FID). The experimental results indicate that the training configuration with 1,000 epochs and a learning rate of 0.0001 achieves the best performance, obtaining an IS of 3.10 ± 0.06 and an FID of 32.40. These results demonstrate that appropriate training parameter selection significantly influences the quality and diversity of batik motifs generated by the CGAN model.

Keywords: Batik, *Deep Learning*, *Conditional Generative Adversarial Networks*, *Inception Score*, *Fréchet Inception Distance*.

PENDAHULUAN

Batik merupakan salah satu warisan budaya Indonesia yang tidak hanya berfungsi sebagai busana tradisional, tetapi juga sebagai karya seni yang mengandung nilai filosofis, estetika, dan identitas budaya lokal. Setiap motif batik merepresentasikan makna tertentu yang berkaitan dengan lingkungan, kepercayaan, serta nilai sosial masyarakat pembuatnya (Sularso et al., 2009; Alicia, 2020). Pengakuan batik sebagai Warisan Budaya Tak Benda oleh UNESCO pada tahun 2009 semakin menegaskan pentingnya pelestarian dan pengembangan batik di tengah arus globalisasi budaya (Lutfi, 2018).

Namun demikian, perkembangan motif batik di era modern menghadapi tantangan berupa stagnasi inovasi desain dan menurunnya minat generasi

muda. Banyak pengrajin batik cenderung mempertahankan motif-motif klasik yang sama secara berulang, sementara persaingan dengan batik cetak dan produk massal semakin meningkat (Marzuqi et al., 2015). Kondisi ini menyebabkan batik berpotensi kehilangan daya tariknya, terutama bagi generasi muda yang lebih menyukai desain busana modern dengan motif yang dinamis dan inovatif (Santi et al., 2020). Kurangnya inovasi motif juga dapat mengancam keberlanjutan batik sebagai identitas budaya nasional apabila tidak diimbangi dengan pendekatan kreatif yang relevan dengan perkembangan zaman.

Inovasi menjadi salah satu faktor kunci dalam menjaga keberlanjutan produk budaya dan meningkatkan nilai tambah bagi konsumen (Septyas

et al., 2013). Dalam konteks pengembangan motif batik, pemanfaatan teknologi menjadi alternatif solusi untuk mengatasi keterbatasan eksplorasi desain secara manual. Salah satu teknologi yang berkembang pesat dan memiliki potensi besar dalam bidang kreatif adalah *deep learning*, yaitu cabang dari *machine learning* yang menggunakan *artificial neural networks* untuk mempelajari pola kompleks dalam data (Rita, 2024). *Deep learning* telah banyak diterapkan dalam pengenalan citra, pemrosesan bahasa alami, serta penciptaan karya seni digital (Haris et al., 2021; Aurellio et al., 2023).

Salah satu metode *deep learning* yang efektif dalam menghasilkan data baru adalah *Generative Adversarial Networks* (GAN), yang pertama kali diperkenalkan oleh Goodfellow et al. pada tahun 2014. GAN terdiri dari dua model utama, yaitu *generator* dan *discriminator*, yang dilatih secara adversarial untuk menghasilkan data sintesis yang menyerupai data asli (Aditya et al., 2023). Dalam konteks seni dan desain, GAN telah dimanfaatkan untuk menghasilkan karya visual baru, seperti pembuatan karakter anime dan karya seni abstrak digital, yang terbukti mampu menghasilkan variasi desain secara otomatis dan efisien (Vika et al., 2022; Eric et al., 2023).

Meskipun demikian, GAN konvensional memiliki keterbatasan karena menghasilkan data secara acak tanpa kendali terhadap karakteristik tertentu. Hal ini menyulitkan penerapannya pada desain motif batik yang membutuhkan pengendalian atribut agar tetap mencerminkan nilai budaya dan estetika tertentu. Untuk mengatasi keterbatasan tersebut, dikembangkan *Conditional Generative Adversarial Networks* (CGAN), yaitu varian GAN yang memungkinkan proses generatif dikondisikan pada label atau atribut tertentu (Masashi, 2023). Dengan pendekatan ini, proses pembuatan motif dapat diarahkan sehingga hasil yang dihasilkan tidak sepenuhnya acak, melainkan memiliki karakteristik yang sesuai dengan kebutuhan desain.

Berdasarkan kajian literatur, sebagian besar penelitian sebelumnya masih terbatas pada penggunaan GAN non-kondisional dalam penciptaan karya seni, sehingga hasil yang dihasilkan kurang terarah dan sulit dikontrol secara sistematis. Penelitian ini menawarkan kebaruan dengan menerapkan CGAN untuk menghasilkan motif batik baru yang memiliki keragaman dan kualitas visual yang baik, sekaligus memberikan

kontrol terhadap karakteristik motif. Selain itu, kualitas hasil generasi motif sangat dipengaruhi oleh parameter pelatihan, seperti jumlah *epoch* dan *learning rate*, yang menentukan kestabilan dan kemampuan model dalam mempelajari distribusi data (Zhang et al., 2017).

Oleh karena itu, tujuan penelitian ini adalah merancang dan mengimplementasikan model CGAN untuk menciptakan motif batik baru, serta menganalisis pengaruh variasi jumlah *epoch* dan *learning rate* terhadap kualitas dan keragaman motif yang dihasilkan.

KAJIAN TEORI

BATIK

Batik merupakan salah satu warisan budaya Indonesia yang memiliki nilai estetika, filosofis, dan simbolik yang kuat. Setiap motif batik merepresentasikan makna tertentu yang berkaitan dengan lingkungan, nilai sosial, serta kepercayaan masyarakat setempat (Sularso et al., 2009; Alicia, 2020). Keberagaman motif batik dari berbagai daerah di Indonesia menunjukkan bahwa batik tidak hanya berfungsi sebagai produk tekstil, tetapi juga sebagai media ekspresi budaya dan identitas lokal. Pengakuan batik sebagai Warisan Budaya Tak Benda oleh UNESCO menegaskan pentingnya upaya pelestarian dan pengembangan batik secara berkelanjutan (Lutfi, 2018).

DEEP LEARNING

Deep learning merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis (*artificial neural networks*) untuk mempelajari pola kompleks dalam data secara hierarkis (Rita, 2024). Pendekatan ini memungkinkan model mengekstraksi fitur dari tingkat sederhana hingga kompleks tanpa memerlukan *feature engineering* secara manual. *Deep learning* telah menunjukkan kinerja unggul dalam berbagai bidang, seperti pengenalan citra, pengenalan suara, dan pemrosesan bahasa alami (Haris et al., 2021). Dalam konteks seni digital, *deep learning* membuka peluang baru dalam proses penciptaan karya visual yang inovatif dan efisien (Aurellio et al., 2023).

GENERATIVE ADVERSARIAL NETWORKS (GAN)

Generative Adversarial Networks (GAN) adalah arsitektur *deep learning* yang terdiri dari dua model,

yaitu *generator* dan *discriminator*, yang dilatih secara adversarial (Aditya et al., 2023). *Generator* bertugas menghasilkan data sintesis yang menyerupai data asli, sedangkan *discriminator* berfungsi membedakan antara data asli dan data buatan. Proses pelatihan berlangsung hingga tercapai keseimbangan di mana *generator* mampu menghasilkan data yang sulit dibedakan dari data asli oleh *discriminator* (Goodfellow et al., 2014). GAN telah banyak digunakan dalam bidang kreatif untuk menghasilkan citra, karakter digital, dan karya seni visual secara otomatis (Vika et al., 2022; Eric et al., 2023). Salah satu pengembangan dari GAN adalah *Conditional Generative Adversarial Networks* (CGAN), yaitu model GAN yang proses generatifnya dikondisikan pada informasi tambahan berupa label atau atribut tertentu (Masashi, 2023). Dengan menambahkan informasi kondisi pada input model, CGAN memungkinkan pengendalian karakteristik data yang dihasilkan sehingga tidak bersifat sepenuhnya acak seperti GAN konvensional.

GENERATOR DAN DISCRIMINATOR

Generator merupakan komponen dalam GAN yang bertugas menghasilkan data sintesis berdasarkan vektor *noise* dan, pada CGAN, informasi kondisi tertentu, dengan tujuan meniru distribusi data asli (Amir et al., 2019). Sementara itu, *discriminator* berfungsi mengevaluasi keaslian data dengan membedakan antara data asli dan data buatan yang dihasilkan oleh generator (Mardiah et al., 2022). Proses pelatihan berlangsung secara adversarial, di mana *generator* berupaya menipu *discriminator*, sedangkan *discriminator* berusaha meningkatkan kemampuannya dalam melakukan klasifikasi. Interaksi kompetitif antara kedua komponen ini mendorong peningkatan kualitas data sintesis secara bertahap hingga diperoleh hasil generasi yang mendekati data asli. Persamaan matematis dari *generator* dan *discriminator* sesuai dengan yang diusulkan oleh Goodfellow et al. (2014) dalam *Generative Adversarial Networks* (GAN) adalah sebagai berikut:

$$G_{loss} = \log(1 - D(G(z)))$$

$$G_{loss} = \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z^i)))$$

dan

$$D_{loss} = \log(D(x)) + \log(1 - D(G(z)))$$

$$D_{loss} = \frac{1}{m} \sum_{i=1}^m \log(D(x^i)) + \log(1 - D(G(z^i)))$$

Berdasarkan penelitian oleh Ian Goodfellow, *discriminator* dan *generator* berjalan secara bergantian, dimana *generator* berusaha untuk meminimalkan *loss* dan *discriminator* berusaha untuk memaksimalkan *loss*, sehingga persamaan akhirnya dalam bentuk ekspektasinya adalah :

$$\min_G \max_D + DV(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_z \sim p_z(z) [\log(1 - D(G(z)))]$$

$$\max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_z \sim p_z(z) [\log(1 - D(G(z)))]$$

$$\min_G = E_z p_z(z) [\log(1 - D(G(z)))]$$

INCEPTION SCORE (IS)

Inception Score (IS) merupakan metrik evaluasi yang digunakan untuk menilai kualitas dan keragaman citra yang dihasilkan oleh model generatif (Salimans et al., 2016). IS mengukur seberapa jelas dan bervariasi citra hasil generasi berdasarkan distribusi kelas yang diprediksi oleh model Inception. Nilai IS yang lebih tinggi menunjukkan bahwa citra yang dihasilkan memiliki kualitas visual dan variasi yang lebih baik. Berdasarkan penelitian oleh Tim Salimans et al. (2016), persamaan IS adalah :

$$IS = \exp(E_{x \sim p_{data}} [D_{KL}\{p(y|x) || p(y)\}])$$

FRÉCHET INCEPTION DISTANCE (FID)

Fréchet Inception Distance (FID) digunakan untuk mengukur jarak antara distribusi fitur citra asli dan citra hasil generasi (Heusel et al., 2017). Metrik ini membandingkan rata-rata dan kovariansi fitur yang diekstraksi menggunakan model Inception. Nilai FID yang lebih rendah menunjukkan bahwa citra hasil generasi semakin mendekati distribusi citra asli, sehingga mencerminkan kualitas generatif yang lebih baik (Borji, 2018). Persamaan matematis yang diusulkan Ali Borji (2018) yaitu :

$$FID = \left\| \mu_{real} - \mu_{fake} \right\|_2^2 + Tr(\Sigma_{real} + \Sigma_{fake} - 2(\Sigma_{real}\Sigma_{fake})^{1/2})$$

METODE

TEKNIK PENGUMPULAN DATA

Pengumpulan data dilakukan dengan mengambil gambar motif batik dari dataset publik "Indonesian

Batik Motifs” (Dionisius Dharmadi, Kaggle) yaitu <https://www.kaggle.com/datasets/dionisiusdh/indonesian-batik-motifs>. Data tersebut berisi 983 gambar motif batik. Gambar-gambar tersebut juga ditambahkan dengan gambar motif batik dari sumber lain untuk memperkaya variasi data.

Data-data ini disusun menggunakan struktur folder bertingkat di mana setiap kelas motif batik ditempatkan pada subfolder terpisah. Dataset ini berisi 25 label yang berbeda dengan 50 gambar motif batik untuk setiap labelnya. Gambar-gambar dalam dataset ini memiliki resolusi bervariasi, sehingga perlu dilakukan penyesuaian ukuran untuk memastikan konsistensi dimensi masukan sebelum memasuki arsitektur jaringan saraf konvolusional untuk melatih model CGAN.

TEKNIK ANALISIS DATA

Teknik analisis data dilakukan melalui tahapan komputasional yang terintegrasi dengan proses pelatihan dan evaluasi model CGAN. Dataset citra motif batik terlebih dahulu dipraproses dengan mengubah ukuran gambar menjadi 128x128 piksel, melakukan normalisasi nilai piksel ke rentang [-1, 1], serta menerapkan augmentasi data berupa rotasi dan *horizontal flip* untuk meningkatkan keragaman data.

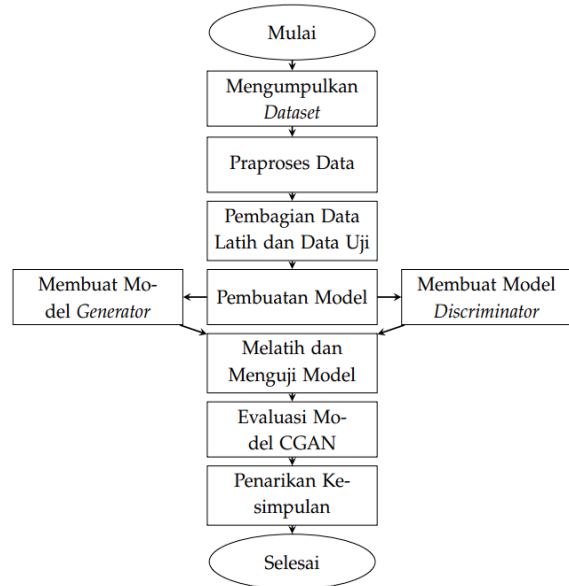
Data yang telah dipraproses kemudian dibagi menjadi data latih dan data uji dengan proporsi 80% dan 20%. Data latih digunakan untuk melatih model CGAN melalui proses adversarial antara *generator* dan *discriminator* dengan beberapa konfigurasi parameter pelatihan, sedangkan data uji digunakan untuk mengevaluasi kinerja model.

Analisis kinerja model dilakukan secara kuantitatif menggunakan *Inception Score* (IS) untuk menilai kualitas visual dan keragaman citra hasil generasi, serta *Fréchet Inception Distance* (FID) untuk mengukur tingkat kemiripan distribusi fitur antara citra hasil generasi dan citra asli. Hasil evaluasi dari setiap konfigurasi parameter dibandingkan untuk menentukan konfigurasi pelatihan yang memberikan performa terbaik.

Perangkat keras yang digunakan memenuhi kebutuhan komputasi *deep learning*, dengan spesifikasi minimal RAM 16 GB, GPU NVIDIA GeForce RTX atau setara, serta prosesor setara Intel Core i7. Perangkat lunak yang digunakan meliputi bahasa pemrograman Python dan pustaka *deep*

learning untuk implementasi CGAN, serta utilitas pendukung untuk perhitungan metrik IS dan FID.

Diagram alur berikut ini menyajikan tahapan yang dilakukan dalam pembuatan model *Conditional Generative Adversarial Networks* (CGAN) untuk membuat pola motif batik




HASIL DAN PEMBAHASAN

PELATIHAN MODEL


Model CGAN dilatih menggunakan dataset motif batik yang dikumpulkan. Model CGAN dilatih menggunakan dataset motif batik yang dikumpulkan. Ujicoba pelatihan model dilakukan sebanyak 1000 *epoch* dengan parameter *learning rate* sebesar $1 * 10^{-4}$ dan ukuran *batch size* 32. Selama proses pelatihan, *generator* dan *discriminator* dilatih secara adversarial secara bergantian pada setiap iterasi. Secara umum, pelatihan berlangsung tidak stabil saat beberapa *epoch* awal, pada awalnya terdapat fluktuasi nilai *loss* yang cukup tinggi, jika arsitektur model yang dibuat sesuai maka model akhirnya mencapai keseimbangan adversarial setelah epoch tertentu. Rata-rata waktu pelatihan per epoch sekitar 1 hingga 2 detik saat menggunakan GPU NVIDIA RTX 3060 MOBILE dan Processor AMD RYZEN 9 6900HX, sedangkan menggunakan Processor tanpa menggunakan GPU untuk rata-rata waktu pelatihan per epoch sekitar 10 hingga 15 detik. Jika menggunakan GPU maka total durasi pelatihan model (1000 *epoch*) mencapai kurang lebih 180 menit. Hal ini menunjukkan bahwa dengan spesifikasi perangkat keras yang digunakan GPU NVIDIA RTX 3060 MOBILE dan RAM 16 GB, pelatihan model

dapat diselesaikan dalam waktu yang cukup lama. Berikut hasil grafik *loss generator* dan *discriminator* saat pelatihan model sebanyak 1000 *epoch* :



Gambar 1. Grafik *loss generator* dan *discriminator*


Pada Gambar 1 ditampilkan kurva perubahan nilai *loss* untuk *generator* dan *discriminator* sepanjang proses pelatihan. Terlihat bahwa pada tahap awal pelatihan *epoch* 1 hingga *epoch* 400, nilai *loss generator* cenderung naik sedangkan *loss discriminator* relatif stabil. Hal ini wajar terjadi karena di awal pelatihan *generator* masih menghasilkan gambar motif batik yang kualitasnya rendah atau acak, sehingga mudah dibedakan oleh *discriminator* yang dimana ketika *discriminator* menang, *loss discriminator* kecil. Setelah *epoch* ke-400, kedua kurva *loss* mulai mendekati keadaan stabil. Nilai *loss generator* dan *discriminator* berfluktuasi di sekitar nilai tertentu. Pada titik ini, *generator* mulai menghasilkan gambar yang cukup untuk menipu *discriminator* sehingga sulit dibedakan oleh *discriminator*, sementara *discriminator* tetap dapat mempertahankan kemampuannya untuk membedakan antara gambar asli dan hasil *generator*. Kondisi ini menandakan tercapainya keseimbangan antara *generator* dan *discriminator*, di mana *generator* mampu menipu *discriminator* dengan cukup konsisten, namun *discriminator* tetap mampu mempertahankan kemampuan membedakan pada tingkat yang seimbang. Dengan kata lain, tidak terjadi *mode collapse* atau *divergensi loss* yang ekstrem, yang menunjukkan bahwa proses pelatihan adversarial berhasil dikendalikan dengan baik. Setelah pelatihan model CGAN selesai, hasil gambar dari model CGAN yang dilatih dapat diamati pada gambar berikut:



Gambar 2. Contoh gambar hasil *generator* pada *epoch* ke-1000

Dapat dilihat pada Gambar 2 memperlihatkan contoh visualisasi hasil *generator* dari *epoch* ke-1000. Pada awal pelatihan, gambar yang dihasilkan masih terlihat acak dan tidak memiliki pola yang jelas. Namun, seiring bertambahnya jumlah *epoch*, kualitas gambar yang dihasilkan semakin baik. Pada *epoch* ke-1000, gambar yang dihasilkan sudah mulai menunjukkan pola-pola batik.

Model CGAN juga diuji dengan parameter *epoch* yang berbeda untuk mengeksplorasi pengaruhnya terhadap kualitas gambar yang dihasilkan. Hasil dari model CGAN pada *epoch* ke-500, dan ke-1000 menunjukkan perbedaan kualitas gambar yang signifikan. Pada *epoch* ke-500, gambar yang dihasilkan masih terlihat kasar dan kurang detail, meskipun sudah mulai menunjukkan pola-pola batik. Namun, pada *epoch* ke-1000, gambar yang dihasilkan jauh lebih baik, dengan detail yang lebih halus dan pola yang lebih kompleks. Hal ini menunjukkan bahwa semakin banyak *epoch* yang digunakan untuk melatih model CGAN, semakin baik pula kualitas gambar yang dihasilkan. Berikut hasil gambar dari model CGAN yang dilatih sebanyak 500 *epoch* pada gambar berikut:



Gambar 3. Contoh gambar hasil *generator* pada *epoch* ke-500

Gambar 3 menunjukkan contoh gambar hasil *generator* pada *epoch* ke-500. Pada tahap ini, pola-pola batik mulai terlihat, meskipun masih belum sejelas pada *epoch* ke-1000. Detail dan kompleksitas motif masih terbatas, namun sudah ada kemajuan yang signifikan dibandingkan dengan gambar yang dihasilkan pada *epoch* awal.

Selain itu, model CGAN juga diuji dengan variasi parameter *learning rate* untuk mengeksplorasi pengaruhnya terhadap kualitas gambar yang dihasilkan. Hasil dari model CGAN pada *learning rate* $1 * 10^{-4}$ dan $2 * 10^{-4}$ menunjukkan perbedaan kualitas gambar yang signifikan. Pada *learning rate* $1 * 10^{-4}$, gambar yang dihasilkan terlihat lebih halus dan detail, sedangkan pada *learning rate* $2 * 10^{-4}$, gambar yang dihasilkan terlihat lebih kasar dan kurang detail. Pemilihan nilai *learning rate* yang tepat sangat penting dalam pelatihan model CGAN untuk menghasilkan gambar yang berkualitas tinggi. Berikut hasil gambar model yang dilatih dengan *learning rate* $2 * 10^{-4}$:



Gambar 4. Contoh gambar hasil *generator* pada *epoch* ke-500

Hasil gambar model-model dari parameter yang berbeda dapat dilihat pada Gambar 2 dan Gambar 4, model menunjukkan bahwa *learning rate* $1 * 10^{-4}$, gambar yang dihasilkan terlihat lebih halus dan detail, dengan pola-pola batik yang lebih jelas. Namun, pada *learning rate* $2 * 10^{-4}$, gambar yang dihasilkan terlihat tidak konsisten, dengan hasil yang tidak jelas dan kurang terdefinisi. Pemilihan nilai *learning rate* yang tepat sangat penting dalam pelatihan model CGAN untuk menghasilkan gambar yang berkualitas tinggi. Nilai *learning rate* yang terlalu tinggi dapat menyebabkan model tidak stabil dan menghasilkan gambar yang tidak konsisten, sedangkan nilai *learning rate* yang terlalu rendah

dapat memperlambat proses pelatihan dan menghasilkan gambar yang kurang detail.

Dari uji coba parameter yang dilakukan, untuk tahap akhir model dilatih pada *epoch* ke-50.000 dengan *learning rate* $1 * 10^{-4}$ untuk menghasilkan gambar-gambar baru berdasarkan label yang ditentukan. Gambar-gambar ini dihasilkan oleh *generator* dengan memberikan label sebagai masukan. Hasilnya, model CGAN mampu menghasilkan gambar-gambar motif batik dengan label yang diberikan. Pada pengujian model menunjukkan telah berhasil belajar dari data latih dan mampu menghasilkan gambar berdasarkan label yang diberikan. Berikut adalah contoh gambar yang dihasilkan oleh model CGAN berdasarkan label yang diberikan:



Gambar 5. Hasil *generator* pada dua label berbeda : Batik Ciamis dan Batik Gentongan

EVALUASI KUALITAS GAMBAR

Pada tahap ini, kualitas gambar yang dihasilkan oleh model CGAN dievaluasi secara kuantitatif menggunakan dua metrik populer dalam bidang model generatif, yaitu *Inception Score* (IS) dan *Fréchet Inception Distance* (FID). Kedua metrik ini umum digunakan untuk menilai kinerja model *Generative Adversarial Network* (GAN), di mana masing-masing memberikan perspektif berbeda. IS berfokus pada keragaman dan kejelasan gambar yang dihasilkan, sedangkan FID mengukur seberapa mirip distribusi gambar hasil generatif terhadap distribusi data asli. Evaluasi dengan kedua metrik ini dapat memberikan gambaran menyeluruh tentang kualitas hasil model CGAN yang telah dibangun. Untuk menguji pengaruh berbagai konfigurasi pelatihan terhadap kualitas gambar yang dihasilkan, telah dilakukan serangkaian eksperimen dengan beberapa variasi parameter. Secara khusus, percobaan dilakukan dengan mengubah jumlah *epoch* pelatihan dan nilai *learning rate* pada model CGAN.

Tabel 1: Hasil evaluasi IS dan FID pada model CGAN dengan berbagai konfigurasi

Konfigurasi	Epoch	LR	IS	FID
Model A	1000	$1 * 10^{-4}$	3.10 ± 0.06	32.40
Model B	500	$1 * 10^{-4}$	2.7 ± 0.07	40.85
Model C	1000	$2 * 10^{-4}$	2.3 ± 0.06	48.10
Model D	500	$2 * 10^{-4}$	1.95 ± 0.05	58.25

Berdasarkan Tabel 1 menunjukkan perubahan konfigurasi pelatihan berdampak signifikan terhadap kualitas gambar yang dihasilkan (ditunjukkan oleh perubahan nilai IS dan FID).

Pengurangan jumlah *epoch* dari 1000 menjadi 500 (Model A dan Model B dengan *learning rate* yang sama $1 * 10^{-4}$) tidak terbukti meningkatkan kualitas hasil. Nilai FID naik dari sekitar 32.40 menjadi 40.85, menunjukkan bahwa distribusi gambar yang dihasilkan Model B lebih jauh dari distribusi data asli dibandingkan Model A. Selain itu, nilai IS juga menurun dari 3.10 ± 0.06 menjadi 2.7 ± 0.07 , menunjukkan bahwa gambar hasil Model B kurang beragam dan kurang jelas dibandingkan Model A.

Peningkatan *learning rate* dari $1 * 10^{-4}$ menjadi $2 * 10^{-4}$ (Model A dan Model C dengan *epoch* yang sama 1000) juga tidak memberikan hasil yang baik. Nilai FID meningkat dari 32.40 menjadi 48.10, menunjukkan bahwa gambar hasil Model C lebih jauh dari distribusi data asli dibandingkan Model A dan model B. Selain itu, nilai IS juga menurun dari 3.10 ± 0.06 menjadi 2.3 ± 0.06 , menunjukkan bahwa gambar hasil Model C kurang beragam dan kurang jelas dibandingkan Model A.

Kombinasi pengurangan *epoch* dan peningkatan *learning rate* (Model B dan Model D) juga tidak memberikan hasil yang baik. Nilai FID meningkat dari 40.85 menjadi 58.25, menunjukkan bahwa gambar hasil Model D lebih jauh dari distribusi data asli dibandingkan model-model lainnya. Selain itu, nilai IS juga menurun dari 2.7 ± 0.07 menjadi 1.95 ± 0.05 , menunjukkan bahwa gambar hasil Model D kurang beragam dan kurang jelas dibandingkan model-model lainnya.

PENUTUP

SIMPULAN

Dari pembahasan diatas, dapat disimpulkan bahwa pelatihan model CGAN dengan jumlah *epoch* yang lebih banyak (1000) dan *learning rate* yang lebih kecil ($1 * 10^{-4}$) memberikan hasil terbaik dalam hal

kualitas gambar yang dihasilkan. Nilai IS tertinggi (3.10 ± 0.06) dan FID terendah (32.40) menunjukkan bahwa gambar yang dihasilkan oleh model ini memiliki keragaman yang baik dan mendekati distribusi data asli. Pelatihan dengan lebih banyak *epoch* memungkinkan model untuk belajar pola-pola dalam data dengan lebih baik, sehingga menghasilkan gambar yang lebih realistis dan berkualitas tinggi. Sebaliknya, pengurangan jumlah *epoch* atau peningkatan *learning rate* cenderung mengurangi kualitas gambar yang dihasilkan, karena model tidak memiliki cukup waktu untuk belajar dari data atau terlalu cepat beradaptasi terhadap pola-pola dalam data. Oleh karena itu, pemilihan parameter pelatihan yang tepat sangat penting untuk mencapai hasil generatif yang optimal.

SARAN

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, beberapa saran dapat diajukan untuk pengembangan penelitian selanjutnya. Penelitian selanjutnya disarankan untuk mengeksplorasi variasi parameter pelatihan yang lebih luas, seperti ukuran *batch*, arsitektur jaringan yang lebih dalam, serta penggunaan fungsi aktivasi dan optimizer yang berbeda. Variasi tersebut berpotensi meningkatkan stabilitas pelatihan dan kualitas visual motif batik yang dihasilkan oleh model CGAN. Dataset yang juga digunakan dapat diperluas baik dari segi jumlah maupun keragaman motif, termasuk penambahan label kondisi yang lebih spesifik, seperti asal daerah, jenis motif, atau elemen visual tertentu. Dengan dataset yang lebih kaya dan terstruktur, model CGAN diharapkan mampu menghasilkan motif batik yang lebih representatif dan memiliki kontrol karakteristik yang lebih baik. Evaluasi kualitas hasil generasi dapat dilengkapi dengan metode penilaian kualitatif, seperti penilaian oleh ahli batik atau perancang motif, untuk melengkapi evaluasi kuantitatif menggunakan *Inception Score* dan *Fréchet Inception Distance*. Pendekatan ini dapat memberikan perspektif estetika dan budaya yang tidak sepenuhnya tercermin melalui metrik numerik.

DAFTAR PUSTAKA

- Adisukma, W. (2013). Makna Pendhapa Ageng Mangkunegaran Sebagai Bangunan Adat Jawa. *Jurnal Brikolase*, 5(1), 1-13. <https://repository.isi-ska.ac.id/1048/>

- Borji, A. (2018). Pros and Cons of GAN Evaluation Measures. *ArXiv Preprint ArXiv:1802.03446*. <https://arxiv.org/abs/1802.03446>
- Diva, K. (2024). *Peran Seni Rupa dalam Membangun Identitas Budaya*. <https://sci.telkomuniversity.ac.id/peran-seni-rupa-dalam-membangun-identitas-budaya/>
- Firosya, B. H. (2023). *Mengenal Karya Seni Rupa, Seni Musik, dan Seni Tari*. <https://www.detik.com/edu/detikpedia/d-7101837/mengenal-karya-seni-rupa-seni-musik-dan-seni-tari>
- Furyana, S. A., Wahyudi, E., & Handini, Y. D. (2013). Inovasi Produk Batik Pesisiran pada Perusahaan Batik Virdes di Banyuwangi. *Artikel Ilmiah Hasil Penelitian Mahasiswa*. <https://repository.unej.ac.id/bitstream/handle/123456789/58809/Septyas%20Arum%20F.pdf?sequence=1&isAllowed=y>
- GeeksforGeeks. (2023). *Conditional Generative Adversarial Network*. <https://www.geeksforgeeks.org/conditional-generative-adversarial-network/>
- Gramedia Literasi. (2024). *Memahami Tentang Sejarah Batik Indonesia dan Ragam-ragamnya*. <https://www.gramedia.com/literasi/sejarah-batik/>
- Gunasekaran, A. (2023). Generative Adversarial Networks: A Brief History and Overview. *Journal of Student Research*, 12(1). <https://www.jsr.org/index.php/path/article/view/1848/1227>
- Husein, A. M., Arsyah, M., Sinaga, S., & Syahputra, H. (2019). Generative Adversarial Networks Time Series Models to Forecast Medicine Daily Sales in Hospital. *Sinkron: Jurnal Dan Penelitian Teknik Informatika*, 3(2), 1–6. <https://jurnal.polgan.ac.id/index.php/sinkron/article/view/10044/188>
- Inspektorat Jenderal Kementerian Pendidikan Kebudayaan Riset dan Teknologi. (2023). *Menilik Sejarah Batik, Salah Satu Duta Budaya Indonesia*. <https://itjen.kemdikbud.go.id/web/menilik-sejarah-batik-salah-satu-duta-budaya-indonesia/>
- Larasati, M. (2021). Pelestarian Budaya Batik Nusantara sebagai Identitas Kultural melalui Pameran di Museum Batik Pekalongan pada Masa COVID-19. *Tornare: Journal of Sustainable and Research*, 3(1), 46–50. <https://jurnal.unpad.ac.id/tornare/article/view/29849>
- Mardiah, A., Hartati, S., & Sihabuddin, A. (2022). Face Image Generation and Enhancement Using Conditional Generative Adversarial Network. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 16(1), 1–10. <https://jurnal.ugm.ac.id/ijccs/article/view/58327/33158>
- Marzuqi, A., Fianto, A. Y. A., & Hidayat, W. (2015). Penciptaan Motif Batik Sebagai Ikon Kabupaten Lumajang. *Jurnal Art Nouveau*, 4(1), 27–38. <https://jurnal.dinamika.ac.id/index.php/ArtNouveau/article/view/754/0>
- Nurdevi, I. (2018). Batik sebagai Warisan Budaya Indonesia. *Seminar Nasional Bahasa Dan Sastra*. http://simkatmawa.kemdikbud.go.id/v3/assets/upload/foto_non_lomba_061016_1560707203096194000.pdf
- PNG, P. (2023). *Sejarah dan Perkembangan Batik di Indonesia*. <https://www.batikprabuseno.com/artikel/edukasi/sejarah-dan-perkembangan-batik-di-indonesia/>
- Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *ArXiv Preprint ArXiv:1511.06434*. <https://arxiv.org/abs/1511.06434>
- Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., & Chen, X. (2016). Improved Techniques for Training GANs. *ArXiv Preprint ArXiv:1606.03498*. <https://arxiv.org/abs/1606.03498>
- Sandi, S. P. H., Hasanah, R. U., Nurhasanah, & Lesmana, D. (2020). Pengembangan dan Pelestarian EB Batik di Era Modern. *Jurnal Mahasiswa Manajemen & Akuntansi*, 1(1), 1–7. <https://journal.ubpkarawang.ac.id/mahasiswa/index.php/JMMA/article/view/29>
- Sari, R. P. (2024). *Apa itu Deep Learning? Cara Kerja dan Contohnya*. <https://www.cloudcomputing.id/pengetahuan-dasar/apa-itu-deep-learning/>
- School of Information Systems BINUS University. (2023). *Mengenal Deep Learning Beserta Contoh Penerapannya*. <https://sis.binus.ac.id/2023/07/18/mengenal-deep-learning-beserta-contoh-penerapannya/>
- Shastri, K. A., Manjunatha, B. A., Kumar, T. G. M., & Karthik, D. U. (2023). Generative Adversarial Networks Based Scene Generation on Indian Driving Dataset. *Journal of ICT Research and Applications*, 17(2), 181–200. <https://journals.itb.ac.id/index.php/jictra/article/view/19162/6296>
- Sularso. (2009). *60 Tahun Gabungan Koperasi Batik Indonesia*. Koperasi Pusat Gabungan Koperasi Batik Indonesia.
- Trixie, A. A. (2020). Peran Seni Rupa dalam

Membangun Identitas Budaya. *Folio*, 2(1), 1-10.
<https://journal.uc.ac.id/index.php/FOLIO/article/view/1380>