

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Dalam pengembangan metode pemrosesan sistem untuk penelitian ini, beberapa penelitian terkait telah menjadi sumber referensi yang penting. Referensi ini membantu memperkuat dasar teoritis dan metodologis penelitian, serta memberikan wawasan yang berharga dalam merancang pendekatan yang efektif dan inovatif untuk mencapai tujuan penelitian yang ditetapkan. Referensi ini antara lain:

2.1.1. State-of-the-Art in the Architecture, Methods and Applications of StyleGAN[7]

Penelitian dengan judul "*State-of-the-Art in the Architecture, Methods and Applications of StyleGAN*" dilakukan oleh Amit H. Bermano, Rinon Gal, Yuval Alaluf, Ron Mokady, Yotam Nitzan, Omer Tov, Or Patashnik, dan Daniel Cohen-O membahas tentang pengeditan berbasis laten dan penggunaan *StyleGAN* untuk augmentasi data. Penelitian ini memberikan gambaran komprehensif tentang berbagai aspek *GAN* dan *StyleGAN* serta aplikasinya dalam berbagai tugas pengolahan gambar.

StyleGAN pada penelitian ini melibatkan penggunaan *layer-wise style modulations* dan jaringan pemetaan yang baru untuk menciptakan ruang laten yang halus, semantik, dan sangat terdisentangle secara tidak terawasi. Hal ini memungkinkan pengeditan berbasis laten, menghasilkan efek seperti perubahan usia, gaya rambut, atau pose tubuh yang realistis dan masuk akal, serta transformasi menjadi selebriti atau makhluk magis. Namun, *StyleGAN* mengalami kesulitan dengan domain yang tidak menunjukkan struktur yang kuat. Oleh karena itu, penelitian ini menyoroti pentingnya pengembangan lebih lanjut dalam bidang generatif untuk mengatasi keterbatasan tersebut, baik dengan menyesuaikan generator untuk kebutuhan spesifik maupun dengan mengekstrak pengetahuan dari *StyleGAN* untuk keperluan *non-*

generative. Selain itu, penelitian ini juga menyoroti pentingnya eksplorasi ruang laten terstruktur *StyleGAN* untuk mencapai tujuan *self-supervision* dan pembelajaran representasi yang secara alami memisahkan dan memahami elemen-elemen yang menyusun distribusi data. Poin penting dalam penelitian ini antara lain:

- Evaluasi *GAN* menggunakan *recall* dan *precision*: Metode ini memecah evaluasi *GAN* menjadi *recall* dan *precision*, di mana presisi tinggi menunjukkan generasi gambar yang berkualitas tinggi dan realistis dengan menggunakan metrik seperti *SSIM* (*Structural Similarity Index Measure*) atau *PSNR* (*Peak Signal-to-Noise Ratio*) untuk mengevaluasi kualitas visual dari gambar-gambar yang dihasilkan, hasil skor tinggi pada gambar dalam metrik tersebut menyebabkan *precision* dianggap tinggi, sedangkan *recall* tinggi mengacu pada generasi variasi yang besar yang mirip dalam keragaman dengan data asli.
- Penggunaan *CLIP* untuk *blending* gambar: Penggunaan *CLIP* untuk mencampur dua gambar wajah, dengan tujuan mempertahankan identitas asli sambil berhasil mentransfer fitur semantik yang bermakna dari gambar target yang diinginkan.
- Penemuan manipulasi dalam ruang parameter *generator*: Penemuan berbagai metode untuk memanipulasi dan mengedit gambar menggunakan *GAN*, termasuk operasi penyetelan, pengeditan lintas domain, manipulasi parameter *generator*, dan *conditioning model* pada label yang berasal dari ruang laten itu sendiri.
- Penggunaan *StyleGAN* untuk segmentasi gambar: Pemanfaatan pemahaman semantik *StyleGAN* untuk pengeditan ruang laten dan segmentasi tanpa pengawasan, serta penggunaan representasi *StyleGAN* untuk segmentasi gambar.
- Pendekatan *non-linear* untuk editing gambar: Pendekatan *non-linear* untuk pengeditan gambar dengan menggunakan klasifier dan menghasilkan berbagai arah untuk operasi pengeditan, serta

penggunaan *normalizing flows* untuk pendekatan pengeditan yang stabil.

- Penggunaan *StyleGAN* untuk augmentasi data: Penggunaan *StyleGAN* untuk augmentasi data dengan memanfaatkan pemahaman semantiknya untuk menghasilkan variasi data yang realistis.

2.1.2. Analyzing and Improving the Image Quality of *StyleGAN*[8]

Penelitian dengan judul "*Analyzing and Improving the Image Quality of StyleGAN*" dilakukan oleh Tero Karras, Samuli Laine, Miika Aittala, Janne Hellsten, Jaakko Lehtinen, dan Timo Aila membahas tentang analisis dan perbaikan kualitas gambar dari model *StyleGAN* untuk generasi gambar. Para peneliti melakukan berbagai modifikasi pada arsitektur jaringan, teknik regularisasi, dan optimisasi pelatihan untuk meningkatkan kualitas gambar yang dihasilkan. Mereka menemukan bahwa modifikasi tertentu dapat meningkatkan kualitas gambar dan memperbaiki dinamika pelatihan. Selain itu, penelitian ini juga menyoroti pentingnya regularisasi dalam mengoptimalkan peta kebisingan untuk sintesis gambar. Poin penting pada penelitian ini terdapat pada beberapa cara meningkatkan kualitas gambar dengan menggunakan *StyleGAN*, antara lain:

- Modifikasi pada arsitektur jaringan, termasuk perubahan pada *generator normalization*, *progressive growing*, dan regularisasi *generator* untuk mendorong kondisi yang baik dalam pemetaan dari kode laten ke gambar.
- Penggunaan regularisasi jalur panjang yang mendorong *generator* untuk memiliki kondisi yang baik dalam pemetaan dari kode laten ke gambar, yang juga memberikan manfaat tambahan yaitu kemudahan dalam mengatribusikan gambar yang dihasilkan ke jaringan tertentu.
- Penyesuaian *dataset* secara spesifik, seperti penambahan horizontal *flips* pada *dataset FFHQ* untuk efektif meningkatkan jumlah gambar latihan, serta penyesuaian parameter pelatihan seperti bobot regularisasi.

2.1.3. Synthetic Batik Pattern Generator using Wasserstein Generative Adversarial Network with Gradient Penalty[12]

Penelitian dengan judul "*Synthetic Batik Pattern Generator using Wasserstein Generative Adversarial Network with Gradient Penalty*" dilakukan oleh Kus Andriadi, Yaya Heryadi, Lukas, Wayan Suparta, dan Ilvico Sonata membahas tentang pengembangan model untuk menghasilkan pola batik sintetis menggunakan jaringan adversarial generatif *Wasserstein* dengan penalti gradien (*WGAN-GP*). Penelitian ini bertujuan untuk mengembangkan metode baru dalam menciptakan pola batik yang hampir identik dengan gambar asli dalam dataset yang besar.

Batik, sebagai warisan budaya dunia dari Indonesia, memiliki berbagai macam pola bergantung pada asal daerahnya. Dalam penelitian ini, dua dataset digunakan, yaitu Batik300 dan Batik Nitik 960. Batik300 terdiri dari 300 gambar batik dengan berbagai pola dan latar belakang, sementara Batik Nitik 960 terdiri dari 960 gambar batik dengan latar belakang dan jenis batik yang seragam. Penelitian ini menggunakan platform *Paperspace* dengan spesifikasi GPU 48GB A6000, memori 45GB, dan 8 vCPUs untuk melatih model. Data dipra-proses untuk memastikan ukuran dan format yang konsisten sebelum pelatihan dimulai.

Generative Adversarial Network (GAN) yang digunakan terdiri dari dua model, *Generator (G)* dan *Discriminator (D)*, yang dilatih secara bersamaan untuk menghasilkan data yang hampir identik dengan data asli. *WGAN-GP* digunakan untuk meningkatkan stabilitas pelatihan dan menghindari masalah konvergensi. Hasil penelitian menunjukkan bahwa model *WGAN-GP* berhasil menghasilkan pola batik sintetis dengan baik, terutama menggunakan dataset Batik Nitik 960. Dataset yang lebih besar dan lebih seragam memungkinkan model untuk belajar dengan lebih baik, sedangkan dataset dengan variasi pola dan latar

belakang yang lebih besar (Batik300) menghasilkan gambar yang kurang baik karena kurangnya data untuk pelatihan.

Penelitian ini menyimpulkan bahwa *WGAN-GP* mampu menghasilkan pola batik dengan catatan bahwa kualitas gambar yang dihasilkan akan lebih baik jika dataset yang digunakan cukup besar. Sebagai rekomendasi untuk penelitian selanjutnya, disarankan untuk menyesuaikan hyperparameter saat menggunakan Batik300 dan memperbesar dataset ini hingga tiga atau empat kali lipat serta mengklasifikasikan pola berdasarkan jenis batiknya. Adapun poin penting dalam penelitian ini, antara lain:

- Penggunaan Jarak Wasserstein: Model ini menggunakan fungsi objektif berbasis jarak Wasserstein (Earth Mover's Distance) untuk menghitung distribusi data asli dan data yang dihasilkan, memungkinkan generator untuk tetap belajar meskipun discriminator bekerja dengan sangat baik.
- Penalti Gradien (Gradient Penalty): Pengenalan penalti gradien untuk mengatasi masalah weight clipping yang diperkenalkan oleh WGAN. Penalti gradien ini diterapkan untuk menegakkan kendala Lipschitz secara lebih efektif tanpa perlu kliping berat yang agresif.
- Penghapusan Batch Normalization di Discriminator: Lapisan Batch Normalization dihapus dari konfigurasi model discriminator, mengikuti rekomendasi dalam makalah WGAN untuk meningkatkan kinerja dan stabilitas model.
- Pemilihan Optimizer: Penelitian ini menguji beberapa optimizer dan menemukan bahwa RMSProp berkonvergensi lebih cepat dan memberikan hasil gambar yang lebih baik dibandingkan dengan optimizer Adam.
- Stabilitas Pelatihan: WGAN-GP meningkatkan stabilitas pelatihan dan menghindari masalah konvergensi yang sering ditemukan pada GAN tradisional.

2.1.4. Generation of Batik Patterns Using Generative Adversarial Network with Content Loss Weighting[9]

Penelitian dengan judul "Generation of Batik Patterns Using Generative Adversarial Network with Content Loss Weighting" dilakukan oleh Agus Eko Minarno, Toton Dwi Antoko, dan Yufis Azhar membahas tentang penghasilan pola Batik baru menggunakan model GAN yang disempurnakan, yaitu BatikGAN SL. Model ini mengintegrasikan fungsi kerugian konten untuk mempertahankan gaya gambar asli, sehingga memberikan hasil yang lebih baik dibandingkan dengan penelitian sebelumnya. Tujuan utama penelitian ini adalah membantu para pengrajin dalam merancang pola Batik secara lebih efisien. Prosesnya dimulai dengan penggunaan dataset Batik yang beragam, dilanjutkan dengan preprocessing data untuk mempersiapkan dataset tersebut. Kemudian, model BatikGAN SL digunakan dalam proses generasi pola Batik dengan mempertimbangkan fungsi kerugian konten. Evaluasi kinerja model dilakukan menggunakan skor FID, yang menunjukkan peningkatan kinerja yang signifikan. Poin penting dalam penelitian ini antara lain:

- **Penggunaan Dataset Batik:** Penelitian ini menggunakan dataset Batik yang terdiri dari 645 gambar Batik dengan berbagai jenis pola, seperti Ceplok, Kawung, slopes, Nitif, machetes, dan pola campuran.
- **Preprocessing Data:** Data Batik yang digunakan diproses untuk mempersiapkan dataset dengan pola Batik yang berbeda. Proses preprocessing ini penting untuk mempersiapkan data sebelum digunakan dalam model.
- **Penggunaan Model GAN BatikGAN SL:** Model GAN yang disempurnakan, BatikGAN SL, digunakan dalam penelitian ini. Model ini memanfaatkan fungsi kerugian konten untuk mempertahankan gaya gambar asli saat menghasilkan pola Batik baru.
- **Evaluasi Model:** Model dievaluasi menggunakan skor FID (Fréchet Inception Distance) untuk mengukur kinerjanya. Hasil evaluasi

menunjukkan peningkatan kinerja model dibandingkan dengan penelitian sebelumnya.

- Kontribusi Penelitian: Penelitian ini memberikan kontribusi dengan membangun model GAN yang ditingkatkan untuk menghasilkan pola Batik baru menggunakan dua patch. Penambahan fungsi kerugian konten dalam model ini membantu mempertahankan pola atau gaya gambar asli.

2.2 Tinjauan Teori

2.2.1 Batik

Batik merupakan seni gambar di atas kain yang digunakan untuk pakaian. Lebih dari sekadar menggambar, batik juga mengandung makna filosofis dalam setiap motifnya. Filosofi motif batik ini erat kaitannya dengan kebudayaan Jawa yang kaya akan simbol-simbol yang telah mengakar dalam falsafah kehidupan masyarakat Jawa. Pada awalnya, batik hanya dikenakan di lingkungan keraton, tetapi seiring dengan perkembangan zaman dan kebutuhan, penggunaan batik mulai meluas di luar keraton, mengikuti perubahan dari kebutuhan individual menjadi kebutuhan industri [1].

Setelah *UNESCO* mengakui bahwa batik merupakan warisan budaya tak benda yang sah milik Indonesia, hal ini tidak hanya menjadi pengakuan atas nilai budaya yang luar biasa dari seni batik, tetapi juga memberikan peluang yang luas bagi masyarakat Indonesia untuk mengembangkan kreativitas mereka dalam menciptakan motif dan corak unik yang mencerminkan kekhasan budaya dari daerah setempat. Dengan pengakuan ini, masyarakat di berbagai daerah di Indonesia didorong untuk lebih memperkaya dan melestarikan warisan batik Indonesia, serta menghadirkan inovasi baru yang mencerminkan keberagaman budaya dan keindahan seni tradisional batik [9]. Motif batik merujuk pada pola-pola yang terdapat pada kain batik, yang sering kali memiliki makna dan filosofi mendalam dalam konteks budaya tempat batik tersebut berasal. Setiap motif batik memiliki keunikan

tersendiri, yang mencerminkan warisan budaya, tradisi, dan nilai-nilai yang terkandung dalam masyarakat yang menghasilkannya. Dengan beragamnya motif batik dari berbagai daerah di Indonesia, seni batik menjadi cerminan dari kekayaan budaya dan keindahan seni tradisional Indonesia.

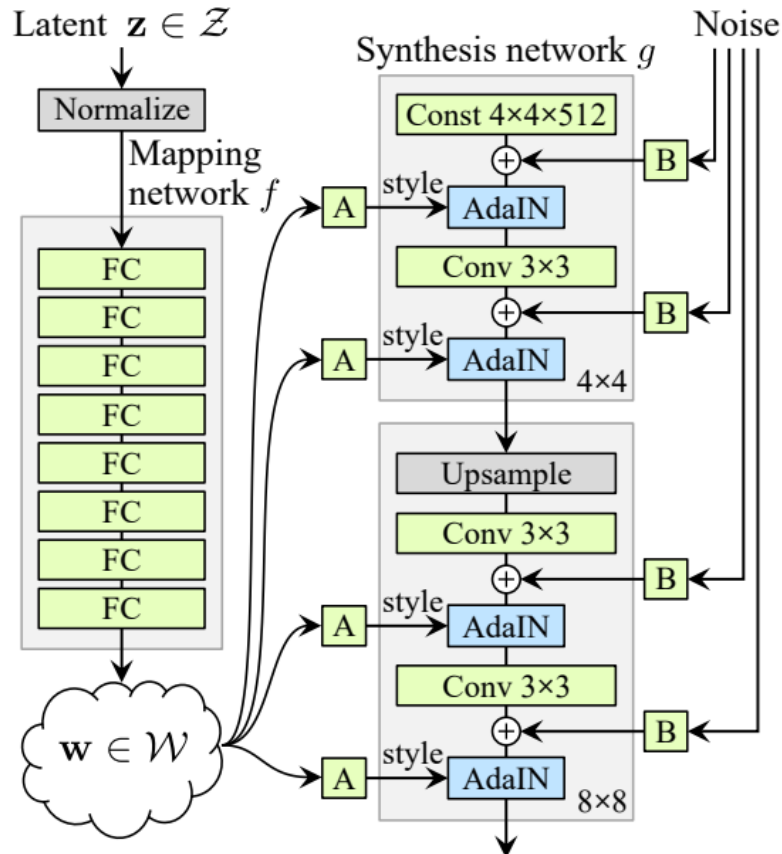
2.2.2 Tensorflow

TensorFlow adalah sistem pembelajaran mesin yang beroperasi dalam skala besar dan dalam lingkungan heterogen. *TensorFlow* menggunakan graf aliran data untuk merepresentasikan komputasi, keadaan bersama, dan operasi-operasi yang mengubah keadaan tersebut [10]. Sistem ini memetakan node-node dari graf aliran data di sepanjang banyak mesin dalam sebuah kluster, dan di dalam sebuah mesin di sepanjang beberapa perangkat komputasi, termasuk *CPU multicore*, *GPU* umum, dan *ASIC (Application-Specific Integrated Circuit)* yang dirancang khusus yang dikenal sebagai *Tensor Processing Units (TPUs)*.

2.2.3 StyleGAN

StyleGAN adalah sebuah model generatif yang menghasilkan gambar realistis dengan kualitas tinggi dan memiliki kemampuan untuk mengontrol atribut-atribut tertentu dari gambar yang dihasilkan. *StyleGAN* memiliki keunggulan utama dalam kontrol yang lebih tinggi atas gaya gambar, peningkatan kualitas gambar yang lebih realistis, kemampuan untuk mengontrol gaya secara spesifik, dan stabilitas yang lebih baik dalam ruang laten dibandingkan dengan *GAN* tradisional. Ini memungkinkan untuk pembangkitan gambar yang lebih realistis dan kreatif dengan tingkat kontrol yang lebih tinggi, menjadikannya alat yang sangat bermanfaat dalam berbagai aplikasi pembangkitan gambar dan manipulasi visual. *StyleGAN* menggunakan *layer-wise style modulations* dan jaringan pemetaan yang baru untuk menciptakan ruang laten yang halus, semantik, dan sangat ter-*disentangle* secara tidak terawasi. Hal ini memungkinkan pengeditan berbasis laten,

menghasilkan efek seperti perubahan usia, gaya rambut, atau pose tubuh yang realistis dan masuk akal, serta transformasi menjadi selebriti atau makhluk lain. *StyleGAN* juga memiliki kemampuan untuk memahami struktur semantik dari gambar yang dihasilkan, sehingga dapat digunakan untuk segmentasi gambar tanpa pengawasan.



Gambar 2. 1 Style-Based Generator

Pada Gambar 2.1 terdapat sebuah grafik alur dari proses *StyleGAN* [10]. Pada *generator*, kode input pertama kali dipetakan ke dalam ruang laten *intermediate* W , yang kemudian mengendalikan *generator* melalui normalisasi *instance adaptif* (*AdaIN*) di setiap lapisan konvolusi. Selain itu, *Noise Gaussian* ditambahkan setelah setiap konvolusi, sebelum mengevaluasi *non-linearitas*. Di sini, "A" merupakan transformasi *affine* yang dipelajari, dan "B" menerapkan faktor skalasi per-*channel* yang dipelajari ke input *noise*. Jaringan pemetaan f terdiri dari 8 lapisan, sementara jaringan sintesis g terdiri dari 18 lapisan, lalu hasil dari

lapisan terakhir dikonversi menjadi *RGB* menggunakan konvolusi terpisah 1×1 .

Fungsi dari *Adaptive Instance Normalization (AdaIN)* dalam *StyleGAN* adalah untuk mengontrol "style" dari gambar yang dihasilkan dengan menyesuaikan statistik dari peta fitur sepanjang jalur generatif [7]. Lapisan ini dirancang untuk memungkinkan kontrol terhadap "style" dari gambar yang dihasilkan dengan menyesuaikan statistik dari peta fitur. Pada versi awal arsitektur *StyleGAN*, lapisan injeksi ini menggunakan mekanisme *Adaptive Instance Normalization (AdaIN)*, di mana setiap saluran dari peta fitur pertama dinormalisasi menjadi rata-rata nol dan varians satuan, diikuti dengan penskalaan ulang menggunakan rata-rata dan varians baru yang diprediksi dari kode laten yang diberikan.

2.2.4 Evaluasi Metrik

Evaluasi kualitas model generatif adalah langkah penting dalam pengembangan model untuk memastikan bahwa model tersebut menghasilkan gambar-gambar yang berkualitas dan sesuai dengan distribusi data yang diinginkan. Dua metrik evaluasi yang umum digunakan untuk model generatif adalah *Frechet Inception Distance (FID)* dan *Inception Score (IS)*. Penggunaan FID (Fréchet Inception Distance) dalam penelitian ini bertujuan untuk mengevaluasi kualitas gambar yang dihasilkan oleh model generatif dengan membandingkan distribusi statistik antara gambar asli dan gambar hasil generasi. FID mengukur perbedaan antara distribusi fitur dari gambar nyata dan gambar yang dihasilkan dalam ruang fitur yang didapat dari jaringan InceptionV3. Evaluasi FID dilakukan selama proses pelatihan, mulai dari ukuran gambar kecil sampai ke resolusi target, untuk memastikan peningkatan kualitas gambar secara bertahap. Sebagai contoh, ketika model dilatih dengan gambar beresolusi rendah atau berukuran kecil, nilai FID dihitung untuk mengevaluasi kualitas gambar yang dihasilkan. Seiring peningkatan resolusi gambar selama pelatihan, nilai FID terus

dievaluasi untuk memastikan distribusi fitur gambar yang dihasilkan semakin mendekati distribusi fitur gambar asli, yang ditunjukkan dengan nilai FID yang lebih rendah, menandakan kualitas gambar yang lebih baik

FID (Frechet Inception Distance) adalah metrik evaluasi yang digunakan untuk mengukur kesamaan antara distribusi fitur (features) dari gambar-gambar yang dihasilkan oleh model generatif dengan distribusi fitur dari gambar-gambar nyata. *FID* memberikan informasi tentang seberapa baik model generatif mereplikasi statistik gambar-gambar nyata.

$$ssdiff = \sum_{i=1}^N (\mu_{real,i} - \mu_{generated,i})^2$$

Rumus 2. 1 Rumus ssdiff

- $\mu_{real,i}$ dan $\mu_{generated,i}$: Rata-rata fitur dari gambar-gambar nyata dan yang dihasilkan oleh model generatif pada dimensi fitur ke- i .

Perhitungan *ssdiff* mengukur perbedaan kuadrat antara rata-rata fitur dari gambar-gambar nyata dan yang dihasilkan oleh model generatif. Ini dilakukan dengan menghitung selisih kuadrat antara setiap dimensi fitur dari distribusi fitur nyata dan distribusi fitur yang dihasilkan oleh model generatif, kemudian menjumlahkan semua selisih tersebut.

$$covmean = \sqrt{\sum real \cdot \sum generated (real \cdot generated)}$$

Rumus 2. 2 Rumus Covmean

- Σ_{real} dan $\Sigma_{generated}$: Matriks kovarian dari fitur-fitur gambar nyata dan yang dihasilkan.
- $real \cdot generated$: Hasil kali titik antara fitur-fitur gambar nyata dan yang dihasilkan.

Perhitungan *covmean* melibatkan penghitungan akar kuadrat dari hasil kali matriks kovarian antara fitur-fitur gambar nyata dan yang dihasilkan oleh model generatif. Ini dilakukan dengan mengalikan setiap pasangan dimensi fitur dari distribusi fitur nyata dengan distribusi fitur yang dihasilkan, kemudian menjumlahkan hasilnya, dan menghitung akar kuadrat dari jumlah tersebut.

$$FID = ssdiff + \text{trace}(\sum real + \sum generated - 2 covmean)$$

Rumus 2. 3 Rumus Frechet Inception Distance

- *trace* : Jejak dari matriks.

Perhitungan terakhir merupakan kalkulasi *FID*, *FID* adalah jumlah dari perbedaan kuadrat antara rata-rata fitur dari gambar-gambar nyata dan yang dihasilkan, serta jejak dari jumlah kovarian dari fitur-fitur tersebut. Namun, kedua kali *covmean* dikurangi dari hasil penjumlahan ini. Ini memberikan informasi tentang seberapa baik model generatif mereplikasi statistik gambar-gambar nyata, dengan memperhitungkan kedekatan antara distribusi fitur dari keduanya.

IS (Inception Score), di sisi lain, digunakan untuk mengukur kualitas gambar-gambar yang dihasilkan oleh model generatif. *IS* memberikan indikasi tentang seberapa baik model generatif menghasilkan gambar-gambar yang bervariasi dan memiliki kualitas yang baik.

$$KL(p(y|x)||p(y)) = \sum_y p(y|x) \log \frac{p(y|x)}{p(y)}$$

Rumus 2. 4 Rumus KL Divergence

- *KL* : *Divergensi Kullback-Leibler*, mengukur jarak antara dua distribusi probabilitas.
- $p(y|x)$: Distribusi probabilitas label y pada gambar x .
- $p(y)$: Distribusi probabilitas rata-rata dari label y pada seluruh dataset.

Perhitungan *KL Divergence* mengukur jarak antara distribusi probabilitas aktual $p(y|x)$ dari label pada gambar x dengan distribusi probabilitas rata-rata $p(y)$ dari label. Ini dilakukan dengan mengalikan nilai probabilitas aktual dengan logaritma dari rasio antara probabilitas aktual dan probabilitas rata-rata untuk setiap label, kemudian menjumlahkan hasilnya. Ini memberikan ukuran tentang seberapa jauh distribusi probabilitas aktual berbeda dari distribusi probabilitas rata-rata.

$$IS = \exp\left(\frac{1}{N} \sum_{i=1}^N KL(p(y_i|x_i)||p(y))\right)$$

Rumus 2. 5 Rumus Inception Score

- *exp* : Fungsi eksponensial, menghasilkan nilai eksponensial dari argumennya.
- *N* : Jumlah total gambar dalam dataset.

Perhitungan *Inception Score (IS)* adalah eksponensial dari rata-rata *KL Divergence* untuk setiap gambar dalam dataset. Ini dilakukan dengan menghitung rata-rata dari *KL Divergence* untuk setiap gambar, kemudian hasilnya dieksponensial. *IS* memberikan informasi tentang seberapa baik model generatif menghasilkan gambar-gambar yang memiliki variasi label dan kualitas yang baik, dengan nilai yang lebih tinggi menunjukkan kualitas yang lebih baik.

Dalam evaluasi ini, kedua metrik tersebut digunakan untuk memberikan pemahaman yang komprehensif tentang kualitas gambar-gambar yang dihasilkan oleh model generatif. Evaluasi yang komprehensif ini membantu peneliti dan praktisi dalam memahami seberapa baik model generatif mereka dalam mereplikasi distribusi data yang diinginkan dan menghasilkan gambar-gambar berkualitas.