

Restorasi Citra Dengan *Image completion* Berbasis Deep Learning

Phie Chyan^{[1]*}, N. Tri Suswanto Saptadi^[2]

Program Studi Teknik Informatika, Fakultas Teknologi Informasi ^{[1],[2]}
Universitas Atma Jaya Makassar
Makassar, Indonesia
Phie_chyan@lecturer.uajm.ac.id^[1], Tri_saptadi@lecturer.uajm.ac.id^[2]

Abstract— Digital images can experience various disturbances in acquisition and storage, one of which is a disturbance indicated by damage to certain areas of the image field and causes the loss of some of the information represented by the image. One of the ways to restore an image experiencing disturbances like this is with image completion technology. Image completion is an image restoration technology capable of filling in or completing missing or corrupted parts of an image. Various methods have been developed for this image completion, starting from those based on basic image processing to the latest relying on artificial intelligence algorithms. This study aims to develop and implement an image completion model based on deep learning with the transfer learning method from the completion.net architecture. Using the Facesrub training dataset consisting of a collection of unique facial photos allows the model to understand facial attributes better. Compared to conventional image completion based on image patches, the method developed in this study can perform image filling in image gaps with more realistic results. Based on visual tests conducted on respondents, the results obtained enable respondents to understand all the information represented by the restored image, similar to the original image.

Keywords— *Image completion, Image restoration, Deep learning, CNN, Completion net*

Abstrak—Citra digital dapat mengalami berbagai gangguan dalam proses akuisisi maupun penyimpanannya, salah satunya adalah gangguan yang diindikasikan dengan rusaknya area tertentu pada bidang citra dan menyebabkan hilangnya sebagian informasi yang direpresentasikan oleh citra tersebut. Salah satu cara untuk merestorasi citra yang mengalami gangguan seperti ini adalah dengan teknologi *image completion*. *Image completion* ini adalah merupakan teknologi restorasi citra yang mampu melakukan pengisian atau melengkapi bagian hilang atau terkorupsi dari citra. Beragam metode telah dikembangkan untuk *image completion* ini mulai dari yang berbasis pengolahan citra dasar hingga yang terbaru mengandalkan algoritma kecerdasan buatan. Penelitian ini bertujuan untuk mengembangkan dan mengimplementasikan model *image completion* berbasis deep learning dengan metode transfer learning dari arsitektur completion.net. Dengan menggunakan dataset latihan *Facesrub* yang terdiri dari koleksi berbagai foto wajah yang unik, memungkinkan model untuk memahami atribut wajah dengan lebih baik. Dibandingkan dengan *image completion* konvensional berbasis tambalan citra, metode yang dikembangkan dalam penelitian ini mampu untuk melakukan pengisian citra pada celah citra dengan hasil yang lebih realistis. Berdasarkan pengujian

visual yang dilakukan kepada responden, hasil yang diperoleh memungkinkan responden dapat memahami keseluruhan informasi yang direpresentasikan oleh citra hasil restorasi serupa dengan citra asli.

Kata Kunci— *Image completion, Restorasi citra, Deep learning, CNN, Completion net*

I. PENDAHULUAN

Citra digital dapat mengalami berbagai gangguan baik pada proses akuisisi maupun penyimpanannya. Gangguan yang dialami dapat berupa *noise* seperti piksel-piksel yang tersebar secara random dan tidak berkesesuaian dengan piksel disekitarnya hingga gangguan yang mengkorupsi bagian tertentu dari citra sehingga dapat menyebabkan sebagian informasi dari citra tidak dapat dipahami secara lengkap [1]–[3].

Merestorasi citra yang memiliki *noise* yang tinggi merupakan permasalahan penelitian yang sampai saat ini terus dieksplorasi, beragam metode telah dikembangkan untuk mengatasi hal ini [4]–[7]. Salah satu metode yang paling populer adalah menggunakan *Generative Adversarial Networks* (GAN), selain itu berbagai metode *patch matching* dan pendekatan non pembelajaran mesin yang berbasis pengolahan citra dasar juga banyak digunakan tetapi belum mendapatkan hasil yang memuaskan.

Image completion atau *inpainting* merupakan suatu teknologi restorasi citra yang berkaitan dengan beragam teknik yang digunakan untuk mengisi bagian yang hilang atau terkorupsi dari sebuah citra [8]. Saat ini telah banyak penelitian yang mengkaji mengenai metode dalam melakukan *image completion*, meskipun demikian pengembangan metode *image completion* ini tetap menjadi tantangan yang kompleks dalam implementasinya karena umumnya metode ini membutuhkan pemahaman yang tinggi terhadap konteks citra [9]–[11]. Hal ini diperlukan untuk dapat mengisi pola citra yang hilang dan lebih penting lagi pengenalan terhadap konteks citra yang akan diisi [12]–[14]. Pemanfaatan deep learning dalam *image completion* dapat memberikan hasil yang lebih baik karena pendekatan ini memanfaatkan korelasi yang diperoleh antara berbagai pola dari gambar berderau dan gambar asli [15].

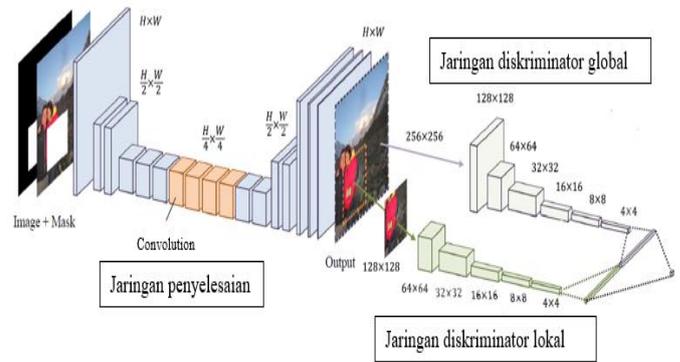
Penelitian ini bertujuan untuk mengembangkan dan mengimplementasikan model *image completion* yang didasarkan pada model berbasis *Fully-Convolutional deep*

learning network (FCN) yang disebut *completion network* model [8]. Arsitektur ini terdiri dari tiga bagian yaitu, jaringan penyelesaian, diskriminator global dan diskriminator lokal. Jaringan penyelesaian adalah merupakan jaringan konvolusi penuh yang digunakan untuk melakukan *image completion* sedangkan diskriminator global dan lokal merupakan jaringan yang akan digunakan untuk proses latih dan menentukan apakah citra telah dikompleksi secara konsisten. Diskriminator global mengambil citra keseluruhan sebagai input untuk mengenali konsisten global dari suatu *scene* sedangkan diskriminator lokal menjangkau area yang lebih kecil disekitar area yang dikompleksi untuk menilai kualitas tampilan yang lebih detail. Diskriminator ini akan diperbarui selama setiap iterasi dalam pelatihan sehingga dapat membedakan dengan baik antara citra asli dan lengkap dari hasil pelatihan. Kemudian setelah itu jaringan penyelesaian akan diperbarui sehingga mengisi area yang hilang pada citra dengan baik dan memenuhi persyaratan dari jaringan diskriminator.

Hasil dari metode *image completion* berbasis *deep learning* ini berupa citra yang telah dikompleksi yang berasal dari citra dengan bagian yang terkorupsi yang telah diisi dengan bagian yang telah diketahui dari citra [16],[17]. Untuk mengevaluasi keluaran dari metode yang digunakan akan dilakukan perbandingan terhadap citra asli dengan citra terkorupsi yang telah dikompleksi dengan metode yang digunakan. Pengembangan model *image completion* menggunakan *transfer learning* dari *completion net* dan dikombinasikan dengan dataset latih *Facesrub*, merupakan kontribusi dari penelitian ini yang memungkinkan model yang dikembangkan mampu melakukan pengisian terhadap berbagai citra objek termasuk wajah.

II. METODE PENELITIAN

Metode *image completion* yang digunakan berbasis *deep learning* dengan arsitektur *convolutional neural network*. Arsitektur ini terdiri dari tiga buah jaringan yang terdiri dari jaringan penyelesaian, diskriminator lokal dan diskriminator global. Sebuah jaringan penyelesaian digunakan untuk *image completion* dengan dua jaringan tambahan yaitu diskriminator lokal dan diskriminator global digunakan untuk melatih jaringan untuk menyelesaikan proses pengisian citra. Dalam periode latih, jaringan diskriminator disiapkan untuk memastikan apakah kondisi citra sudah terisi secara lengkap, sementara jaringan penyelesaian dilatih untuk mengelabui jaringan diskriminator. Dengan melatih ketiga jaringan bersama-sama dimungkinkan untuk jaringan penyelesaian dapat menyelesaikan pengisian gambar secara realistis. Ilustrasi dari pendekatan yang dibahas ini disajikan pada gambar 1. Secara garis besar penelitian dibagi menjadi beberapa tahap yaitu pertama, studi literatur, dimana dalam tahap ini peneliti meninjau berbagai metode state-of-the-art untuk *image completion* utamanya yang berbasis *machine* dan *deep learning*, tahap kedua dilanjutkan dengan persiapan dataset dan preprocessing terhadap citra yang akan digunakan, tahap ketiga dilanjutkan dengan pelatihan, validasi dan testing model dan tahap terakhir dilakukan pengujian untuk melihat bagaimana kinerja model dalam melakukan *image completion*.



Gambar 1. Arsitektur model Completion.Net

A. Convolutional Neural Network

Model jaringan yang digunakan didasarkan pada model *Convolutional Neural Network* (CNN). Ada dua model arsitektur CNN yang diterapkan pertama adalah arsitektur standar CNN dan yang kedua adalah Variasi dari standar CNN yang disebut dilated CNN, yang memungkinkan ukuran tiap layer ditingkatkan sebagai input. Hal ini dilakukan tanpa meningkatkan jumlah bobot pembelajaran dengan cara menyebarkan kernel konvolusi pada peta input. Secara matematis operator konvolusi melebar dapat dituliskan untuk setiap piksel sebagai berikut.

$$y_{u,v} = \sigma \left(b + \sum_{i=-k'_h}^{k'_h} \sum_{j=-k'_w}^{k'_w} W_{k'_h+i, k'_w+j} x_{u+\eta i, v+\eta j} \right),$$

$$k'_h = \frac{k_h - 1}{2}, \quad k'_w = \frac{k_w - 1}{2}, \quad (1)$$

Dimana k_w dan k_h adalah lebar dan tinggi kernel, η adalah faktor dilasi, $X_{u,v} \in \mathbb{R}^C$ dan $Y_{u,v} \in \mathbb{R}^C$ adalah komponen piksel dari layer input dan output. $W_{s,t}$ adalah matriks kernel $C' \times C$ dan $b \in \mathbb{R}^C$ adalah vektor layer bias. Kedua jaringan konvolusi dilatih untuk meminimalkan fungsi loss dengan propagasi mundur dan dilatih dengan dataset yang terdiri dari pasangan input dan output. Fungsi loss bertujuan untuk meminimalkan jarak jaringan output dengan pasangan output yang bersesuaian pada dataset [18].

B. Jaringan Penyelesaian

Jaringan penyelesaian merupakan jaringan yang berbasis konvolusional penuh. Input dari jaringan penyelesaian adalah citra RGB dengan *channel* biner yang mengindikasikan masking *image completion* dan output juga merupakan citra RGB. Arsitektur umum mengikuti struktur *encoder-decoder* yang dapat mengurangi penggunaan memori dan waktu komputasi dengan menurunkan resolusi di awal pemrosesan sebelum memproses citra. Setelah itu kemudian output dikembalikan ke resolusi asli menggunakan layer dekonvolusi [8]. Berbeda dengan arsitektur umumnya yang memanfaatkan banyak layer pooling untuk menurunkan resolusi, pada arsitektur ini hanya menurunkan resolusi dua kali menggunakan

stride konvolusi $\frac{1}{4}$ kali dari ukuran asli yang penting untuk menghasilkan tekstur yang tidak blur pada area yang hilang pada citra. Layer konvolusi terdilasi juga biasa digunakan pada layer tengah. Layer ini menggunakan kernel yang tersebar dan dapat menghitung setiap piksel output dengan input area yang lebih lebar tetapi tetap dengan pemanfaatan jumlah parameter dan waktu komputasi yang sama. Hal ini penting dalam menghadirkan realisme dalam image completion karena dengan menggunakan konvolusi terdilasi pada resolusi rendah, model dapat menjangkau area input yang lebih luas secara efektif dalam menghitung setiap piksel output dibandingkan dengan layer konvolusi biasa.

C. Jaringan Diskriminator Konteks

Diskriminator konteks lokal dan global bertujuan untuk mengidentifikasi bilamana suatu citra itu masih asli atau telah selesai diisi. Jaringan diskriminator ini didasarkan pada jaringan konvolusional yang memampatkan citra menjadi fitur vektor. Keluaran dari jaringan digabungkan bersama oleh rangkaian layer yang memperkirakan nilai kontinyu yang sesuai dengan probabilitas citra menjadi nyata. Jaringan diskriminator global menerima input dan di skalakan ke 256×256 piksel. Jaringan ini juga terdiri dari 6 layer konvolusi dan sebuah layer terkoneksi penuh yang menghasilkan sebuah 1024 vektor dimensional. Jaringan diskriminator lokal memiliki pola yang sama dengan diskriminator global kecuali untuk input menggunakan tambalan citra 128×128 piksel yang berpusat pada area citra yang akan diisi.

Output dari jaringan diskriminator lokal dan global dihubungkan bersama kedalam 2048 vektor dimensional yang kemudian diproses oleh sebuah layer terkoneksi penuh untuk menghasilkan nilai kontinyu. Fungsi transfer sigmoid digunakan agar nilai berada dalam range 0 dan 1 yang merepresentasikan probabilitas citra adalah asli atau apakah citra dikompleksi dengan isian.

D. Proses Latih

Secara garis besar proses latih dari jaringan *image completion* dinyatakan melalui diagram alir pada gambar 2. Untuk melatih jaringan dalam mengkompleksi citra input secara realistis maka dua fungsi loss digunakan bersama-sama yaitu *weighted mean squared error* (MSE) untuk stabilitas latih dan *Generative Adversarial Networks* (GAN) untuk meningkatkan realisme pada citra hasil [19], [20]. Dengan menggunakan gabungan dari kedua fungsi *loss* ini memungkinkan pelatihan stabil pada model jaringan berkinerja tinggi. Untuk menstabilkan pelatihan, MSE *loss* yang digunakan memperhitungkan *mask* kompleksi *region* yang dipakai. MSE *loss* didefinisikan sebagai

$$L(x, M_c) = \| M_c \odot (C(x, M_c) - x) \|^2 \quad (2)$$

Jaringan diskriminator konteks juga merupakan fungsi *loss* yang umum dikenal sebagai GAN *loss* dan merupakan bagian yang penting untuk mengubah *neural network* dengan optimasi standar ke optimalisasi min-max dimana pada setiap iterasi jaringan diskriminator diperbarui bersama dengan jaringan penyelesaian. Optimalisasi kedua jaringan tersebut dinyatakan

menjadi

$$\min_C \max_D \mathbb{E} [\log D(x, M_d) + \log(1 - D(C(x, M_c), M_c))] \quad (3)$$

Dengan menggabungkan kedua fungsi *loss* menjadi

$$\min_C \max_D \mathbb{E} [L(x, M_c) + \alpha \log D(x, M_d) + \alpha \log(1 - D(C(x, M_c), M_c))], \quad (4)$$

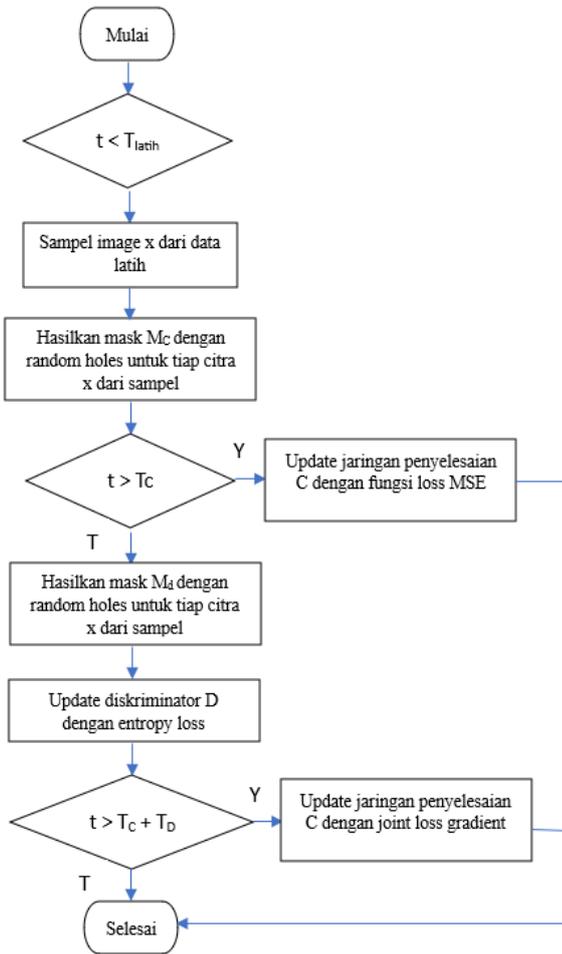
Dimana C dan D adalah jaringan diskriminator, M_d adalah *random mask*, M_c adalah *input mask*, α adalah *hyper parameter* dan nilai ekspektasi merupakan nilai rata-rata atas citra latih x. ADADELTA digunakan sebagai algoritma optimasi yang mengatur laju pembelajaran untuk setiap bobot pada jaringan secara otomatis.

Dalam proses optimasi, jaringan penyelesaian dan diskriminator dinyatakan sebagai perubahan nilai C dan D yang berarti bahwa bias dan bobot jaringan berubah. Pada gradien stokhastis turunan persamaan optimasi min-max berarti bahwa untuk latih C, diambil nilai gradien dari fungsi *loss* terhadap θ_c dan memperbarui parameter agar nilai dari fungsi *loss* berkurang. Persamaan gradien adalah sebagai berikut

$$\mathbb{E} [\nabla_{\theta_c} L(x, M_c) + \alpha \nabla_{\theta_c} \log(1 - D(C(x, M_c), M_c))]. \quad (5)$$

Dalam implementasinya dilakukan cara yang lebih efisien dengan menjaga nilai gradien diskriminator untuk membantu menstabilkan proses pembelajaran.

Dalam proses latih, Diskriminator dilatih untuk membedakan gambar asli dan palsu, sementara jaringan penyelesaian dilatih untuk mengelabui diskriminator. Karena optimisasi terdiri dari menggabungkan fungsi min dan max menyebabkan jaringan ini tidak begitu stabil sehingga untuk meningkatkan kestabilannya maka metode ini tidak dapat digunakan untuk menggenerate citra dari citra yang berderau. Gambaran mengenai prosedur latih seperti yang tersaji pada gambar 2 adalah proses latih terbagi menjadi 3 tahap yaitu pertama, jaringan penyelesaian dilatih menggunakan fungsi MSE *loss* dari persamaan (2) untuk iterasi sebanyak T_c . Setelah itu jaringan penyelesaian ditetapkan dan jaringan diskriminator yang berikutnya dilatih dari awal sebanyak iterasi T_D dan fase terakhir atau yang ketiga, jaringan penyelesaian dan diskriminator dilatih bersama-sama hingga akhir proses latih. Proses latih dilakukan dengan mengatur ukuran citra agar titik terkecil merupakan nilai random dalam $[256, 384]$ rentang piksel. Setelah itu tambalan random 256×256 piksel diekstraksi dan digunakan sebagai citra input. Untuk *mask*, digunakan lubang random dengan rentang piksel antara $[96, 128]$ dan diisi dengan nilai piksel rata-rata dari dataset latih.



Gambar 2. Diagram alir proses latihan jaringan *image completion*

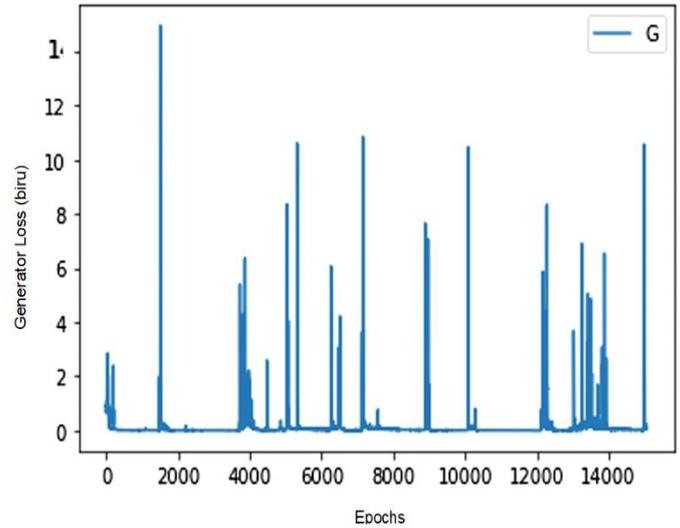
III. HASIL DAN PEMBAHASAN

A. Model dan Dataset

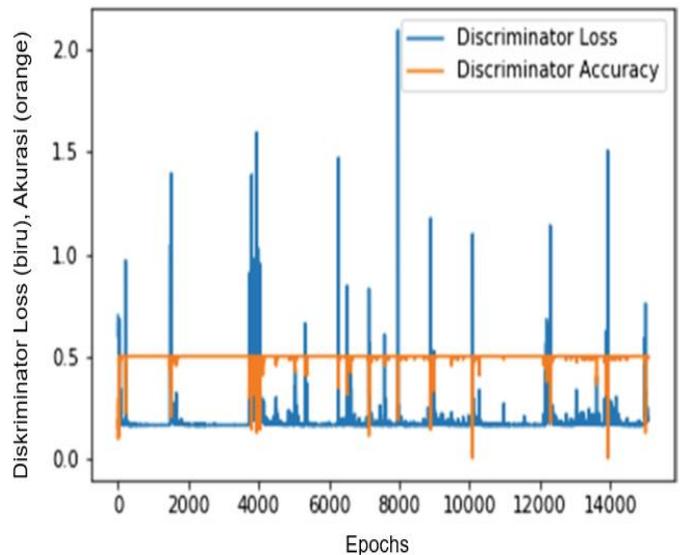
Untuk *image completion* ini, model yang digunakan adalah model pra-latih *Completion Net* yang diimplementasi melalui proses *transfer learning*. Kemudian model ini ditambahkan dengan dataset open-source *Facescrub* dari winklebros.net [21]. Dataset ini terdiri dari 100.000 citra yang berasal dari 500 wajah *public figure* yang unik. Model dilatih dengan dataset ini dengan tujuan untuk membuat kemampuan model dalam memahami atribut wajah semakin baik. Citra berkualitas tinggi sangat berperan penting dalam proses latihan dan memberikan generalisasi yang baik. Dari dataset ini citra *dicrop* dan *resize* ke dimensi 64 x 64 piksel untuk membatasi hanya wajah saja yang tersimpan untuk setiap citra. Model akan menerima inputan citra dan mask (sebagai bagian yang hilang dari citra) dan akan mencoba memprediksi dan melengkapi bagian yang hilang tersebut berdasarkan informasi yang diberikan oleh citra yang tidak lengkap tersebut. Dataset dilatih pada komputer dengan GPU NVIDIA GTX 960M 4GB hingga 13000 *epoch* dimana setiap *epoch* terdiri dari 1000 batch citra dari dataset. Gambar 3 menunjukkan hasil dari generator yang dihitung dengan fungsi loss diatas 13000 *epoch*. Dari gambar tersebut juga terlihat peningkatan seragam pada interval reguler dari nilai *loss* yang cukup sesuai untuk menggambarkan kehandalan dari model. Puncak dari nilai *loss* secara bertahap

berkurang yang menandakan pembelajaran model yang terjadi secara bertahap. Menggunakan jumlah *epoch* yang sangat tinggi, proses latihan butuh waktu sekitar 38 jam untuk diselesaikan. Generator dan diskriminator mengikuti mekanisme paralel karena waktu training meningkat secara eksponensial.

Nilai akurasi diskriminator konstan sepanjang *epoch*. Hanya terjadi reduksi minor pada diskriminator yang disebabkan oleh arsitektur model. Nilai kumulatif rata-rata loss meningkat menunjukkan ketika jumlah data meningkat pada sisi latihan maka kemampuan model untuk mempelajari pola menjadi berkurang. Gambar 4 menunjukkan hasil yang diperoleh dari nilai loss diskriminator.



Gambar 3. Generator loss terhadap jumlah epochs



Gambar 4. Diskriminator loss dan akurasi terhadap epochs

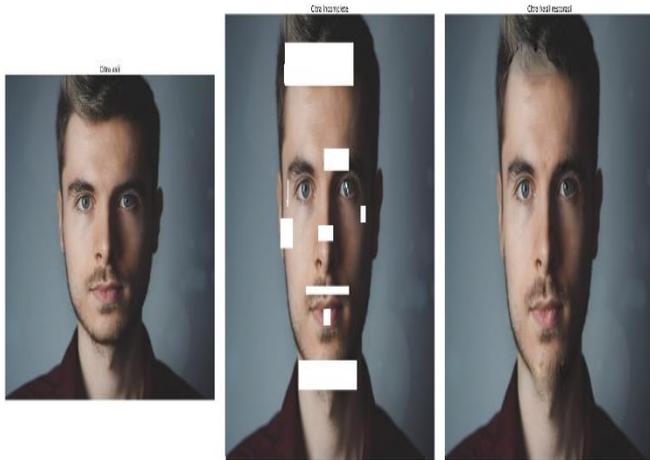
B. Hasil Perbandingan Visual

Gambar 5 dan Gambar 6 menampilkan hasil restorasi citra yang menyajikan hasil perbandingan antara gambar asli, *masking* dan gambar hasil *completion*, berdasarkan perbandingan visual yang diperoleh model yang digunakan

dapat mengisi atau melengkapi bagian hilang dari citra dengan hasil yang cukup baik. Untuk pengujian visual peneliti menggunakan 10 responden yang dipilih secara acak melalui media sosial, setelah responden menyatakan kesediaan untuk berpartisipasi, maka peneliti mengirimkan 2 sampel citra hasil restorasi yaitu gambar 5 dan gambar 6. Setiap responden diberi pertanyaan apakah dapat mengenali gambar yang diberikan dan apakah terdapat kecacatan visual pada gambar yang mempengaruhi persepsi responden. Dari 10 orang responden yang diberi pertanyaan tersebut, seluruhnya dapat memahami objek pada gambar hasil restorasi dan mengaku dapat mengenali semua objek pada gambar hasil restorasi tanpa ada kecacatan yang mempengaruhi persepsi visual responden.



Gambar 5. Hasil restorasi citra pemandangan dengan *image completion*



Gambar 6. Hasil restorasi citra wajah dengan *image completion*

Dari hasil yang diperoleh, model dapat digunakan untuk merestorasi citra dengan beragam resolusi tetapi berdasarkan pengujian yang dilakukan semakin besar ukuran celah loss informasi pada citra maka akan semakin berkurang kualitas pengisian yang diperoleh bahkan dapat menyebabkan kegagalan untuk melakukan pengisian. Hal ini karena

keterbatasan dari model arsitektur CNN yang digunakan, tetapi dengan meningkatkan ukuran layer akan dimungkinkan untuk mendapatkan hasil pengisian yang lebih baik tetapi dengan timbal balik waktu pemrosesan yang lebih lama.

C. Pembahasan dan Limitasi

Berdasarkan pengujian model yang digunakan dapat mengisi celah dengan ukuran bervariasi, tetapi untuk celah yang berukuran besar belum dapat diisi dengan baik. Limitasi ini hanya berlaku pada mask berbentuk persegi, area yang luas pada persegi masih dapat diisi selama tingginya tidak terlalu besar karena informasi dari bagian atas dan bawah citra akan digunakan untuk melengkapi gambar. Sehingga bila celah dalam citra terlalu besar atau terlalu tinggi maka akan sangat membatasi proses ekstrapolasi citra dimana mask akan berada di batas dari citra. Hal ini akan menyebabkan kegagalan dalam pengisian celah citra. Pendekatan lain yang memanfaatkan dictionary learning dapat mengatasi masalah ini sepanjang database citra yang digunakan mengandung kemiripan dengan citra input. Untuk pendekatan ini ekstrapolasi lebih mudah daripada inpainting karena lebih sedikit yang harus dicocokkan pada tepian citra akan tetapi metode ini lebih cocok digunakan untuk menghasilkan ekstensi citra dibanding inpainting yang berfokus untuk melakukan restorasi pada citra yang mengalami kerusakan. Beberapa contoh kegagalan pengisian gambar dapat dilihat pada gambar 7 dan 8. Kegagalan pengisian yang terjadi umumnya terjadi pada citra yang memiliki objek yang kompleks yaitu citra yang didalamnya hanya memiliki sedikit pola informasi yang berulang dan atau citra memiliki celah yang menutupi keseluruhan dari bagian objek yang dapat digunakan untuk pembelajaran sehingga akhirnya model gagal untuk memperoleh informasi untuk mengisi celah pada citra tersebut. Pada gambar 7 model gagal untuk mengisi gambar kepala pada gambar anak yg bagian kepalanya terhapus karena lebih memprioritaskan untuk merekonstruksi citra pohon pada latar belakang dibandingkan kepala dari orang dan pada gambar 8 model gagal untuk mengisi gambar anjing.



Gambar 7. Kegagalan pengisian citra manusia



Gambar 8. Kegagalan pengisian citra hewan

IV. KESIMPULAN

Bagian Penelitian yang dilakukan untuk melakukan restorasi citra dengan metode *image completion* berbasis deep learning telah berhasil memperoleh hasil yang baik berdasarkan uji visual yang dilakukan kepada responden. Dengan menggunakan jaringan penyelesaian dan diskriminator, model yang digunakan mampu menghasilkan pengisian celah citra yang realistis. Dibandingkan dengan metode umum berbasis tambalan citra, model ini dapat mengisi bagian citra menggunakan bagian baru yang tidak pernah digunakan dalam citra. Limitasi dari model yang dikembangkan saat ini terkait dengan arsitektur yang digunakan sehingga untuk ukuran celah yang terlalu besar akan mengurangi kualitas pengisian yang dilakukan pada citra sehingga menyebabkan gambar tidak terlengkapi dengan sempurna. Penelitian di masa depan dapat dilakukan untuk mengembangkan arsitektur yang digunakan dengan ukuran layer jaringan yang lebih besar untuk mengatasi limitasi ini.

UCAPAN TERIMA KASIH

Peneliti mengucapkan terima kasih kepada LPPM Universitas Atma Jaya Makassar yang telah memberikan dukungan dana untuk terlaksananya penelitian ini melalui hibah penelitian dosen LPPM UAJM

REFERENCES

[1] P. Chyan and N. T. Saptadi, "Pemulihan Citra Berbasis Metode Markov Random Field," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 2, p. 218, Apr. 2022.

[2] P. Chyan, "PENERAPAN IMAGE ENHANCEMENT ALGORITHM UNTUK MENINGKATKAN KUALITAS CITRA TAK BERGERAK," *Inf. dan Teknol. Ilm.*, vol. 4, no. 3, May 2017.

[3] P. Chyan, "Rancang Bangun Mesin Pencari Citra Dengan Pendekatan Temu Balik Berbasis Konten," *TEMATIKA*, vol. 3, no. 2, 2015.

[4] J. Bin Huang, S. B. Kang, N. Ahuja, and J. Kopf, "Image completion using planar structure guidance," *ACM Trans. Graph.*, vol. 33, no. 4, 2014.

[5] G. Chican and M. Tamaazousti, "Constrained PatchMatch for image completion," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8887, pp. 560–568, 2014.

[6] J. Sun, L. Yuan, J. Jia, and H. Y. Shum, "Image completion with structure propagation," *ACM Trans. Graph.*, vol. 24, no. 3, pp. 861–868, Jul. 2005.

[7] C. Zheng, T. J. Cham, J. Cai, and D. Phung, "Bridging Global Context Interactions for High-Fidelity Image completion," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2022-June, pp. 11502–11512, 2022.

[8] S. Iizuka, E. Simo-Serra, and H. Ishikawa, "Globally and locally consistent image completion," *ACM Trans. Graph.*, vol. 36, no. 4, 2017.

[9] Q. Li, L. Hu, Q. Shang, Y. Wang, L. Jiang, and W. Long, "Research Progress in the Field of Image completion," *Proc. - 2021 3rd Int. Conf. Artif. Intell. Adv. Manuf. AIAM 2021*, pp. 398–402, 2021.

[10] P. Aditya Laksana, "Restorasi Pada Citra Digital Menggunakan Pendekatan Exemplar Based Inpainting," Oct. 2014.

[11] A. H. Hasugian and I. Zufria, "Perancangan Sistem Restorasi Citra Dengan Metode Image Inpainting," *Algorit. J. ILMU Komput. DAN Inform.*, vol. 2, no. 2, p. 31, Jan. 2019.

[12] M. Failzal and A. Rao, "RECOGNITION of STRESS USING FACE IMAGE and FACIAL LANDMARKS," *Int. Adv. Res. J. Sci. Eng. Technol.*, vol. 8, no. 5, pp. 792–797, 2021.

[13] P. Chyan, "Image Enhancement Based On Bee Colony Algorithm," *J. Eng. Appl. Sci.*, vol. 14, no. 1, pp. 43–49, 2019.

[14] J. Yang, R. Xu, Z. Qi, and Y. Shi, "Visual Anomaly Detection for Images: A Systematic Survey," *Procedia Comput. Sci.*, vol. 199, pp. 471–478, 2021.

[15] P. Chyan, "Sistem Temu Balik Citra Menggunakan Ekstraksi Fitur Citra Dengan Klasifikasi Region Untuk Identifikasi Objek," *TEMATIKA*, vol. 2, no. 2, pp. 63–72, 2014.

[16] N. Akimoto, S. Kasai, M. Hayashi, and Y. Aoki, "360-Degree Image completion by Two-Stage Conditional Gans," *Proc. - Int. Conf. Image Process. ICIP*, vol. 2019-September, pp. 4704–4708, Sep. 2019.

[17] Q. Chen, G. Li, Q. Xiao, L. Xie, and M. Xiao, "Image completion via transformation and structural constraints," *Eurasip J. Image Video Process.*, vol. 2020, no. 1, pp. 1–18, Dec. 2020.

[18] L. Theis, A. Van Den Oord, and M. Bethge, "A note on the evaluation of generative models," *4th Int. Conf. Learn. Represent. ICLR 2016 - Conf. Track Proc.*, 2016.

[19] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, Jun. 2017.

[20] P. Isola, J. Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-image translation with conditional adversarial networks," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-January, pp. 5967–5976, Nov. 2017.

[21] H. W. Ng and S. Winkler, "A data-driven approach to cleaning large face datasets," *2014 IEEE Int. Conf. Image Process. ICIP 2014*, pp. 343–347, 2014.