

Raindrop Removal On A Single Image Using The Generative Adversarial Network

Raindrop Removal Pada Citra Tunggal Menggunakan Generative Adversarial Network

Muhammad Rizal Muttaqin¹, Oddy Virgantara Putra², Lukman Effendi³
{ mrizalmuttaqin@mhs.unida.gontor.ac.id¹, oddy@unida.gontor.ac.id², lukman@unida.gontor.ac.id³ }

Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Darussalam Gontor¹²³

Abstract. *The presence of raindrops attached to the window glass or vehicle glass reduces visibility of the actual scene. The area covered by raindrops forms a round image and reflects light from the actual scene, this image is called Raindrop. In some cases, the camera's focus is blocked by Raindrop will result in a blurry image. The problem faced is that there is no actual landscape image, so to overcome this this research tries to adapt the research from Rui Qian and MaybeShewill-CV which uses the Generative Adversarial Network architecture, by adding the Raindrop and Groundtruth datasets from observations at Darussalam Gontor University. The purpose of this study is to remove raindrops from a single image. This is important to research because it provides updates and optimizes the results of previous research. This study shows the accuracy of PSNR 21.37 and SSIM 0.7561. The model managed to remove Raindrops from the image, but still couldn't match the Groundtruth image. Inability to handle raindrops due to lack of time to run a large number of epochs to produce PSNR values above 40 db and SSIM above 0.9. PSNR and SSIM values can continue to increase along with the addition of the dataset as well as the number of epoch training models carried out.*

Keywords – Raindrop; Generative Adversarial Network; Single Image

Abstrak. *Adanya tetesan air hujan yang menempel pada kaca jendela ataupun kaca kendaraan mengurangi penglihatan terhadap pemandangan sebenarnya. Daerah yang tertutupi tetesan air hujan membentuk citra berbentuk bulat dan memantulkan cahaya dari pemandangan sebenarnya, citra ini disebut dengan Raindrop. Dalam beberapa kejadian, fokus kamera yang terhalangi oleh Raindrop akan menghasilkan gambar dengan tampilan yang blurry. Permasalahan yang dihadapi adalah tidak adanya gambar pemandangan yang sebenarnya, sehingga untuk mengatasi hal tersebut penelitian ini mencoba mengadaptasi penelitian dari Rui Qian dan MaybeShewill-CV yang menggunakan arsitektur Generative Adversarial Network, dengan menambahkan dataset Raindrop dan Groundtruth hasil observasi di Universitas Darussalam Gontor. Tujuan penelitian ini adalah menghilangkan Raindrop dari citra tunggal. Hal ini penting untuk diteliti karena untuk memberikan pembaharuan dan mengoptimalkan hasil penelitian sebelumnya. Penelitian ini menunjukkan tingkat akurasi PSNR 21.37 dan SSIM 0.7561. Model berhasil menghilangkan Raindrop dari gambar, namun masih belum bisa menyamai gambar Groundtruth. Kurang mampunya dalam menangani Raindrop karena kurangnya waktu untuk menjalankan jumlah epoch yang banyak demi menghasilkan nilai PSNR diatas 40 db dan SSIM diatas 0.9. Nilai PSNR dan SSIM dapat terus bertambah seiring penambahan dataset juga jumlah epoch training model yang dilakukan.*

Kata Kunci – Tetesan Air Hujan; Generative Adversarial Network; Citra Tunggal

I. PENDAHULUAN

Tetes air hujan yang menempel pada permukaan kaca jendela, kaca kendaraan atau lensa kamera dapat mengurangi visibilitas pemandangan sebenarnya. Hal tersebut disebabkan karena daerah kaca yang terkena tetesan air hujan menghasilkan citra yang berbeda dengan daerah kaca tanpa tetesan air hujan. Wilayah tetesan air hujan pada hasil pengambilan gambar dibentuk oleh sinar cahaya yang dipantulkan dari pemandangan dibelakangnya, lalu membentuk sebuah citra yang disebut *Raindrop*. Dalam beberapa kejadian, fokus kamera yang terhalangi oleh *Raindrop* menghasilkan gambar dengan tampilan yang *blurry*.

Sebelumnya, beberapa penelitian telah dilakukan untuk mengatasi masalah pendeteksian dan penghilangan *Raindrop* seperti ini. Seperti penelitian milik Martin Roser yang mendeteksi *Raindrop* pada citra yang dihasilkan oleh kamera, tapi tidak menghilangkannya[1]. Lalu beberapa penelitian oleh Atsushi Yamashita yang memanfaatkan hasil citra dari kamera stereo[2] dan video[3], [4], namun penelitian dari Atsushi Yamashita tidak berlaku untuk gambar input tunggal yang diambil oleh kamera biasa.

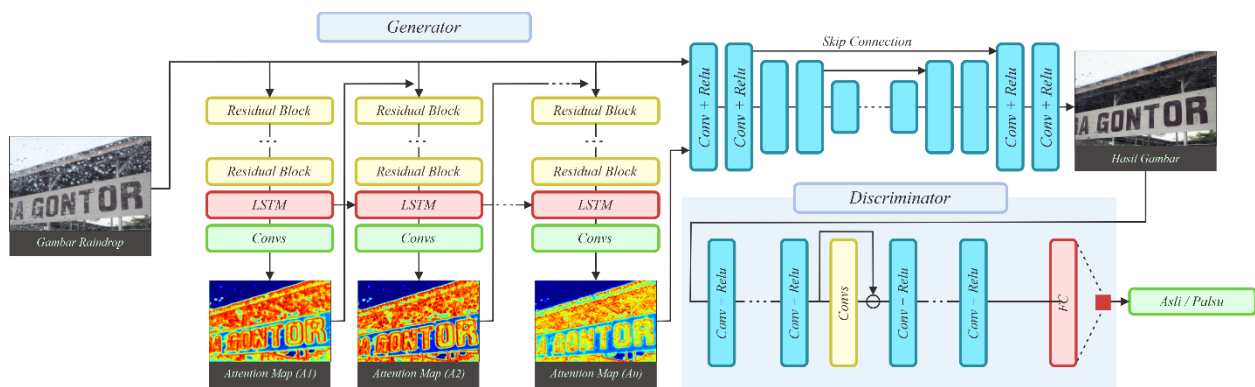
Penelitian kelima dilakukan oleh Eigen untuk mencoba mendeteksi dan menghilangkan *Raindrop* pada citra tunggal melalui metode *Deep Learning*, namun hasilnya hanya dapat menangani tetesan air hujan yang kecil dan

masih menghasilkan *output* yang buram. Hal ini juga membuktikan bahwa metode ini belum bisa menangani *Raindrop* yang besar dan padat dengan baik[5].

Penelitian keenam yang dilakukan oleh Rui Qian mencoba untuk mendeteksi dan menghilangkan *Raindrop*. Penelitian ini menggunakan arsitektur *Generative Adversarial Network* yang memiliki dua jaringan utama yaitu *Generator* dan *Discriminator*. Jaringan *Generator* menghasilkan citra yang dinilai oleh jaringan *Discriminator* untuk memastikan hasil tersebut memiliki tingkat kesesuaian yang tinggi dengan pemandangan sebenarnya[6].



Gambar 1. Dataset *Raindrop* hasil observasi yang didapatkan di Universitas Darussalam Gontor.



Gambar 2. Arsitektur GAN terdiri dari Jaringan Generator dan Jaringan Discriminator.

Penelitian ini mengadaptasi penelitian milik Rui Qian yang telah diperbaharui oleh MaybeShewill-CV dengan menambahkan *dataset Raindrop* dan juga *Groundtruth* dari hasil observasi di Universitas Darussalam Gontor selama 1 bulan, contoh gambar hasil observasi dapat dilihat pada Gambar 1. Gambar 1 menampilkan beberapa gambar yang diambil dengan kondisi pencahayaan yang berbeda. (a) & (b) diambil dengan kamera dan lingkungan yang tidak berada dibawah sinar matahari langsung, (c) & (d) diambil dengan kamera dan lingkungan yang berada dibawah matahari langsung. Tujuan penelitian ini adalah menghilangkan tetesan air hujan dari citra tunggal. Hal ini penting untuk diteliti karena untuk memberikan pembaharuan dan mengoptimalkan hasil penelitian sebelumnya, tentunya menjadi jalan keluar bagi mereka yang ingin mendapatkan hasil citra terbaik walaupun terdapat *Raindrop* didalamnya.

II. METODE

Hingga saat ini, implementasi arsitektur GAN telah digunakan dalam berbagai tujuan, contohnya untuk membuat prediksi wajah manusia pada masa tua yang merupakan penelitian dari Yunfan[8]. Bersama dengan teman-temannya, Yunfan mencoba untuk menambahkan perpaduan antara metode GAN dan perhatian visual untuk bisa memproses suatu gambar wajah manusia menjadi lebih tua, akan tetapi tidak keluar dari fitur asli wajah tersebut. Lalu contoh lainnya dari Zhang[9] yang menggunakan GAN untuk meningkatkan hasil gambar dari mikroskop yang memiliki resolusi kecil menjadi lebih besar dan lebih jelas dari sebelumnya. Perbedaan diantara mereka adalah penggunaan tambahan metode untuk menghasilkan output yang diinginkan.


Penelitian disini menggunakan laptop dengan spesifikasi *processor* Intel Core i5 8300H 2.30 Ghz, *random access memory* berukuran 16 GB, penyimpanan data SSD dengan ukuran 222 GB dan *graphics processing unit* NVIDIA GTX 1050 dengan ukuran memory 4 GB.

Masalah utama yang dihadapi jika ingin menghilangkan *Raindrop* dari citra tunggal adalah tidak adanya informasi citra sebenarnya yang tertutupi oleh *Raindrop*. Untuk mengatasi masalah informasi yang tidak diberikan tersebut, penelitian ini menggunakan arsitektur GAN yang memiliki dua bagian utama yaitu jaringan *Generator* dan jaringan *Discriminator* seperti yang ditampilkan pada Gambar 2. Dengan adanya *input* gambar yang tergradasi oleh *Raindrop*,

jaringan *Generator* berusaha menghasilkan citra senyawa mungkin dan bebas dari gangguan *Raindrop*. Model dilatih menggunakan *dataset* yang terdiri dari data gambar *Groundtruth* (gambar pemandangan tanpa gangguan) dan *Raindrop* (gambar dengan adanya gangguan tetesan air hujan), lalu jaringan *Discriminator* memvalidasi gambar yang dihasilkan jaringan *Generator* sebelumnya dan memberikan informasi apakah gambar tersebut sudah terlihat nyata atau belum.



Gambar 3. Citra *Raindrop* yang seakan-akan memiliki citra tersendiri.



Gambar 4. Hasil *Attention Map* yang dihasilkan oleh jaringan *Generator*

Pada dasarnya *Raindrop* terlihat transparan. Namun, karena bentuk dan indeks biasanya, piksel di daerah *Raindrop* ini tidak hanya dipengaruhi oleh satu titik saja akan tetapi mencangkup seluruh lingkungan yang ada[4]. Hal tersebut membuat *Raindrop* seakan-akan memiliki citra tersendiri yang berbeda dari lingkungan latar belakangnya. Selain itu, kamera juga berfokus kepada pemandangan dibelakangnya, sehingga citra dalam wilayah *Raindrop* sebagian besar menjadi kabur. Beberapa bagian *Raindrop*, terutama daerah pinggiran dan daerah transparan menyampaikan beberapa informasi tentang gambaran latar belakang sebenarnya. Gambar 3 menunjukkan contoh dari citra *Raindrop*, (a) adalah salah satu data gambar *Raindrop* dari *dataset* dan (b) adalah gambar yang menunjukkan bahwa citra *Raindrop* seperti menghasilkan citra tersendiri dari latar belakang sebenarnya.

Jaringan *Generator*


Jaringan *Generator* terdiri dari dua sub-jaringan yaitu jaringan *Attentive-Recurrent* dan *Contextual Autoencoder*. Tujuan dari jaringan *Attentive-Recurrent* adalah menemukan daerah *Raindrop* pada gambar *input*. Daerah *Raindrop* yang dimaksud adalah daerah *Raindrop* dan struktur disekitar *Raindrop* yang diperlukan oleh jaringan *Contextual Autoencoder* sehingga nantinya dapat menghasilkan restorasi citra yang lebih baik. Jaringan *Discriminator* berfokus kepada penilaian hasil gambar setelahnya.

Model *Attention Map* diterapkan untuk melokalisasi daerah *Raindrop* dalam gambar masukan. *Attention Map* membedakan gambar *Groundtruth* dengan gambar *Raindrop* dari *dataset* yang disediakan untuk pelatihan. Dalam satu *Attentive-Recurrent* terdiri dari 6 *Residual Block*, *Long Short-Term Memory (LSTM)* dan juga *Convolutional Layer* yang nantinya akan menghasilkan 2D *Attention Map*. Setiap langkah pelatihan terdiri dari 4 *Attentive-Recurrent* yang membantu menghasilkan fitur dari gambar *input* dan *mask* dari *Attentive-Recurrent* sebelumnya.

Attention Map merupakan peta non-biner dan mewakili peningkatan *attention* dari daerah non-*Raindrop* hingga daerah rintik hujan dan nilainya bervariasi. *Attention Map* mempelajari matriks yang berkisar dari 0 hingga 1 yang diwakilkan dengan intensitas warna dari biru hingga merah, semakin besar nilainya, maka semakin berwarna merah daerah *Raindrop* yang akan ditampilkan, seperti yang ditunjukkan pada Gambar 4. Adanya beberapa bagian gambar yang bukan *Raindrop* juga ikut terdeteksi karena daerah tersebut juga membutuhkan perhatian. Daerah transparan dari

Raindrop sebenarnya bervariasi (beberapa bagian tidak sepenuhnya menutupi latar belakang dan yang lainnya menyampaikan beberapa informasi atau gambaran latar belakang).

Untuk bagian kedua dari jaringan *Generator* adalah *Contextual Autoencoder*, jaringan ini mengambil gambar *Raindrop* dan *Attention Map* sebagai masukannya. Perbandingan *multi-scale* ditambahkan untuk memaksimalkan informasi yang didapatkan. Perbandingan tersebut membandingkan perbedaan antara keluaran dari *Convolutional Layer* dengan *Groundtruth* yang telah diturunkan skalanya.



Gambar 5. Sampel dataset gambar *Raindrop* dan *Groundtruth*

Tujuan dari *Contextual Autoencoder* adalah menghasilkan gambar yang bebas dari *Raindrop*. Masukan dari *Contextual Autoencoder* adalah gabungan gambar *Raindrop* awal dan hasil akhir *Attention Map* dari jaringan *Attentive-Recurrent*. *Contextual Autoencoder* memiliki 16 blok *Conv-ReLU* (*Rectified Linear Unit*) dan juga *Skip Connection* yang telah ditambahkan untuk mencegah blurnya gambar.

Jaringan Discriminator

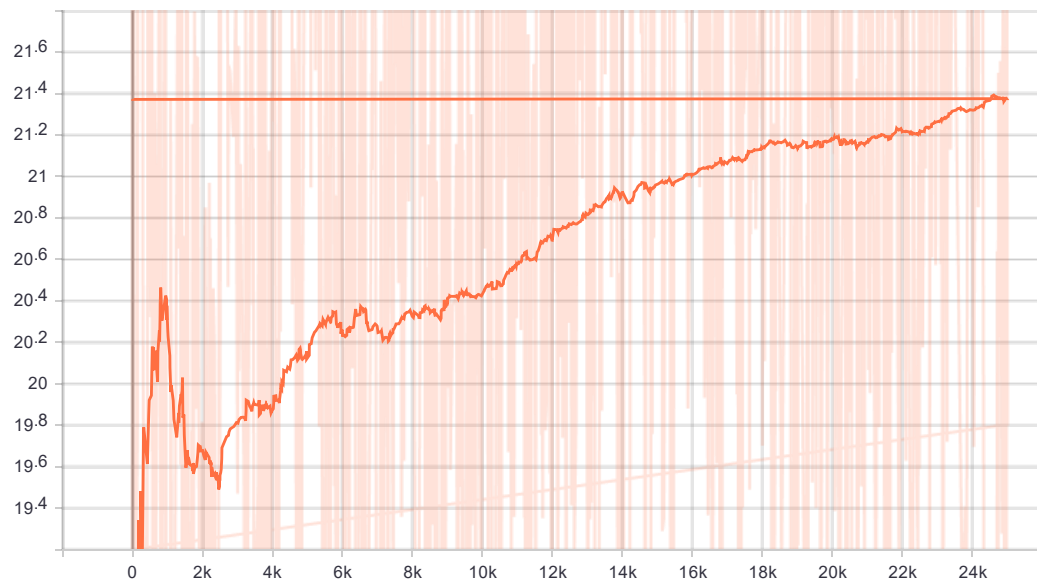
Attention Map yang telah dihasilkan oleh jaringan *Attentive-Recurrent* digunakan untuk membedakan gambar palsu dan gambar asli. Jaringan *Discriminator* berisi 9 *Stage Convolution Layer* dengan *kernel* (5, 5). Pada *Stage* ke 7, hasil *Attention Map* yang didapatkan dari *Stage* ke 6 dikalikan dengan hasil dari *Convolution Layer* pada *Stage* ke 6. Dimensi yang dihasilkan dari 9 *Stage Convolution Layer* adalah 1024 *Fully Connected Layer*, lalu disatukan dengan fungsi aktivasi *Sigmoid Activation*.

Dataset


Untuk pelatihan model dalam penelitian ini, *dataset* yang digunakan berjumlah 1509 pasang gambar *Groundtruth* dan *Raindrop*, *dataset* tersebut merupakan gabungan dari penelitian Rui Qian dan hasil observasi di Universitas Darussalam Gontor. Pengumpulan *dataset* dari observasi di Universitas Darussalam Gontor dilakukan pada pukul 06.00 WIB hingga 09.00 WIB. Mengingat data yang dibutuhkan adalah pasangan gambar yang berisikan *Groundtruth* dan *Raindrop*, maka setiap tempat pengambilan gambar, kamera tidak boleh berubah arah, ini dilakukan agar mendapatkan pemandangan yang sama antara *Raindrop* dan *Groundtruth*. Pengambilan gambar *Raindrop* dilakukan terlebih dahulu, setelah itu dilanjutkan dengan pengambilan gambar *Groundtruth* dengan jangka waktu tidak lebih dari 10 detik pada tempat yang sama. Perubahan latar belakang mempengaruhi tingkat akurasi dari metode ini. Gambar 5 akan menunjukkan beberapa hasil dari pengambilan gambar. Dari Gambar 5, nomor 1a, 2a, 3a, dan 4a adalah data *Raindrop*, sedangkan 1b, 2b, 3b dan 4b adalah data *Groundtruth*.

Cara mendapatkan data *Raindrop* adalah menggunakan mika bening berukuran 21 x 29.7 cm dan disemprotkan air melalui *Water Spray*. Mika bening diletakkan depan kamera dengan jarak 10 - 20 centimeter, ini dilakukan untuk mendapatkan gambar yang jelas dan mendapatkan variasi *Raindrop* pada gambar. Tinggi kamera yang dipasang pada Tripod dengan permukaan tanah adalah 1 meter. Kamera yang digunakan adalah SONY A6000 yang memiliki resolusi kamera 24.3MP. Gambar yang dihasilkan memiliki resolusi sebesar 6000 x 4000 *megapixel* menggunakan lensa manual MEIKE dengan *focal length* 35 mm, *aperture* 1.7 sampai dengan 22 dan *filter* berdiameter 49 mm. Kamera dipasang diatas tripod agar mengurangi getaran dan perpindahan posisi untuk pengambilan kedua jenis data. Objek pemandangan yang diambil adalah gedung dan jalan, disini tidak mengambil objek manusia dan pepohonan yang lebar karena mudah menimbulkan perbedaan bayangan dan posisi antara data *Groundtruth* dan data *Raindrop*.

III. HASIL DAN PEMBAHASAN



(a)



(b)

Gambar 8. Visualisasi nilai yang didapatkan dari proses pelatihan

Pelatihan yang dilakukan oleh Rui Qian pada bulan Juni 2018 menggunakan *dataset* sebanyak 1.119 pasang gambar *Raindrop* dan *Groundtruth*. Dengan jumlah *dataset* tersebut, Rui Qian berhasil mendapatkan hasil nilai 31.57 untuk PSNR dan 0.9023 untuk SSIM. Namun, Rui Qian tidak mencantumkan versi *library*, berapa jumlah *epoch* dan juga *Learning Rate* yang digunakan pada penelitiannya. Tak lama berselang pada bulan yang sama, MaybeShewill-CV di akun *Github*-nya mencoba untuk mengimplementasikan penelitian *Attentive Generative Adversarial Network for Raindrop Removal from A Single Image* beserta *dataset* milik Rui Qian. MaybeShewill-CV menggunakan Python 3.5, CUDA 9.0, CUDNN 7.0 dan *Graphic Card* GTX 1070. MaybeShewill-CV mencantumkan *Learning Rate* 0.0002 dan juga versi *library* yang digunakan untuk memudahkan peningkatan performa model dalam penelitian kedepannya. Tabel 1 menampilkan versi *library* yang digunakan oleh MaybeShewill-CV.

Tabel 1. Versi *library* yang digunakan oleh MaybeShewill-CV

No.	Nama Library	Versi
1	opencv_python	3.4.1.15
2	tensorflow	1.15.4
3	glog	0.3.1
4	numpy	1.15.4
5	scikit_image	0.14.1
6	easydict	1.9
7	matplotlib	3.0.2

Tabel 2. Daftar Nilai PSNR dan SSIM dari beberapa jumlah epoch yang dilakukan

No.	Epoch	Val_SSIM	Val_PSNR
1	25000	0.7561	21.37
2	20000	0.7494	21.18
3	15000	0.5612	20.96
4	10000	0.5459	17.34
5	5000	0.5236	16.91



Gambar 9. Perbandingan hasil model dengan Raindrop dan Groundtruth sebenarnya

Pada Gambar 9, ditunjukkan (a) adalah citra *Groundtruth*, (b) adalah citra *Raindrop* dan (c) adalah citra yang berhasil dihasilkan oleh model pada penelitian ini. Dapat dilihat bahwa pada gambar (c), sebagian *Raindrop* berhasil terdeteksi dan dihilangkan, namun masih belum bisa dikatakan sempurna karena masih adanya *Raindrop* lain dan daerah *Raindrop* yang masih belum bisa ditangani oleh model.

Model kali ini mengadaptasi model dari MaybeShewill-CV dengan menjalankan 25000 kali *epochs* (langkah pengulangan training data), proses pelatihan menghabiskan waktu 5 x 24 jam dengan *Learning Rate* sebesar 0,0002. Proses pelatihan juga menghasilkan beberapa model dari jumlah *epochs* yang ditentukan yaitu 5000 kali, 10000 kali, 15000 kali, 20000 kali dan 25000 kali, ini dilakukan untuk mencari perbandingan nilai dari model dan kedepannya dapat diketahui berapa *epochs* yang harus digunakan untuk bisa menghasilkan nilai yang baik. Pada Gambar 8, (a) memvisualisasikan peningkatan nilai PSNR dan (b) memvisualisasikan peningkatan nilai SSIM.

Pengujian model yang telah dihasilkan bertujuan untuk mengetahui nilai SSIM (*Structural Similarity Image Metric*) dan PSNR (*Peak Signal to Noise Ratio*) dari dua citra, yaitu gambar hasil arsitektur GAN dan *Groundtruth* dengan latar belakang yang sama. Nilai SSIM merupakan ukuran perbedaan persepsi antara dua gambar yang serupa, namun tidak dapat menilai mana dari keduanya yang lebih baik, akan tetapi mana yang asli[7]. Untuk PSNR biasanya diukur dalam satuan decibel (db), PSNR digunakan untuk mengetahui perbandingan kualitas citra *Groundtruth* dan citra hasil arsitektur GAN[8]. Tabel 2 menunjukkan nilai SSIM dan PSNR yang dihasilkan dari beberapa jumlah *epochs* yang dijalankan.

Menurut Meirista Wulandari, jangkauan nilai SSIM berkisar antara 0 sampai dengan 1, nilai 0 memiliki arti bahwa kedua citra tidak memiliki korelasi atau kesamaan, nilai 1 artinya kedua citra sama persis[9]. Untuk PSNR dalam artikel yang ditulis oleh Achmad Solichin, kedua citra memiliki kualitas yang relatif rendah jika nilai PSNR berada dibawah 30 dan berkualitas tinggi jika nilai yang didapatkan adalah 40 atau lebih tinggi lagi[10]. Penelitian ini

menunjukkan tingkat akurasi PSNR 21.37 dan SSIM 0.7561. Untuk mendapatkan nilai yang lebih maksimal, dibutuhkan waktu lebih lama untuk mengumpulkan *dataset* juga menjalankan jumlah *epoch* yang banyak.

IV. KESIMPULAN

Penelitian ini mencoba mengadaptasi penelitian dari Rui Qian yang mendeteksi juga menghilangkan *Raindrop* dari citra tunggal menggunakan arsitektur *Generative Adversarial Network* dipadu dengan *Attention Map*. Model berhasil menghilangkan *Raindrop* dari gambar dengan nilai PSNR 21.37 dan SSIM 0.7561, namun masih belum bisa menyamai gambar *Groundtruth*. Masih kurang mampunya model dalam menangani *Raindrop* dikarenakan kurangnya waktu untuk menjalankan jumlah *epoch* yang banyak. Nilai PSNR dan SSIM dapat terus bertambah seiring penambahan *dataset* juga jumlah *epoch* training model yang dilakukan.

UCAPAN TERIMA KASIH

Saya berterima kasih kepada Allah SWT yang selalu memberikan kesehatan jasmani dan rohani untuk bisa terus menyelesaikan penelitian ini. Dukungan Bapak serta Ibu dirumah dengan do'anya untuk kelancaran proses pendidikan anaknya. Bapak dan Ibu dosen yang tidak lelahnya membimbing dari awal hingga terselesaikannya penelitian ini. Teman-teman angkatan 2018 Universitas Darussalam Gontor, tidak dapat disebutkan namun merekalah pemantik untuk selalu ingat akan penelitian yang harus diselesaikan ini. Dan Program Studi Teknik Informatika Universitas Darussalam Gontor yang memfasilitasi penelitian ini.

REFERENSI

- [1] M. Roser, J. Kurz, and A. Geiger, "Realistic modeling of water droplets for monocular adherent raindrop recognition using Bézier curves," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 6469 LNCS, no. PART 2, pp. 235–244, 2011, doi: 10.1007/978-3-642-22819-3_24.
- [2] A. Yamashita, Y. Tanaka, and T. Kaneko, "Removal of adherent waterdrops from images acquired with stereo camera," *2005 IEEE/RSJ Int. Conf. Intell. Robot. Syst. IROS*, no. 7, pp. 953–958, 2005, doi: 10.1109/IROS.2005.1545103.
- [3] A. Yamashita, I. Fukuchi, and T. Kaneko, "Noises removal from image sequences acquired with moving camera by estimating camera motion from spatio-temporal information," *2009 IEEE/RSJ Int. Conf. Intell. Robot. Syst. IROS 2009*, pp. 3794–3801, 2009, doi: 10.1109/IROS.2009.5354639.
- [4] S. You, R. T. Tan, R. Kawakami, Y. Mukaigawa, and K. Ikeuchi, "Adherent raindrop modeling, detection and removal in video," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 38, no. 9, pp. 1721–1733, 2016, doi: 10.1109/TPAMI.2015.2491937.
- [5] D. Eigen, D. Krishnan, and R. Fergus, "Restoring an image taken through a window covered with dirt or rain," *Proc. IEEE Int. Conf. Comput. Vis.*, pp. 633–640, 2013, doi: 10.1109/ICCV.2013.84.
- [6] R. Qian, R. T. Tan, W. Yang, J. Su, and J. Liu, "Attentive Generative Adversarial Network for Raindrop Removal from A Single Image," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 2482–2491, 2018, doi: 10.1109/CVPR.2018.00263.
- [7] Imates, "SSIM: Structural Similarity Index," www.imatest.com, 2021. .
- [8] A. Cheddad, J. Condell, K. Curran, and P. Mc Kevitt, "Digital image steganography: Survey and analysis of current methods," *Signal Processing*, vol. 90, no. 3, pp. 727–752, 2010, doi: 10.1016/j.sigpro.2009.08.010.
- [9] M. Wulandari, "Pengukuran Ssim Dan Analisis Kinerja Metode Interpolasi Untuk Peningkatan Kualitas Citra Digital," *J. Muara Sains, Teknol. Kedokt. dan Ilmu Kesehat.*, vol. 1, no. 1, pp. 184–195, 2017, doi: 10.24912/jmstkik.v1i1.429.
- [10] A. Solichin, "Mengukur Kualitas Citra Hasil Steganografi," *Mengukur Kualitas Citra Has. Steganografi*, no. April, pp. 1–4, 2015.