

Perbaikan Kualitas Gambar untuk Deteksi Plat Nomor Kendaraan dengan Metode *Super Resolution GANs*

Sugeng^{*1}, Nugraha Widyanto²

Program Studi Sistem Komputer, Fakultas Ilmu dan Teknik Komputer, Universitas Komputer Indonesia
Jl. Dipati Ukur no 112-114, Bandung 40132, Jawa Barat, Indonesia
Email: ¹sugeng@email.unikom.ac.id, ²nwidyanto9.nw9@gmail.com

Abstract. *Optimizing Vehicle License Plate Detection through Super Resolution GANs for Enhanced Image Quality.* Research on deep learning that can enhance image resolution can be applied in various fields. One of its implementations is in vehicle license plate detection. Using Deep Learning SRGAN technology, which can improve image resolution, simplifies the object recognition process. In this study, the model is trained with 1,070 images, including 535 low-resolution and 535 high-resolution images. The model is then tested with 10 low-resolution images. The results show that the model can increase image resolution by up to $2\times$ from the input images. The evaluation of the model yields an average PSNR value of 20,1587 dB for the input images and 21,1831 dB for the model's output. The average SSIM value is 0.5215 for the input images and 0.6331 for the model's output.

Keywords: deep learning, machine learning, license plate, image resolution, SRGANs

Abstrak. Penelitian tentang pembelajaran mendalam yang dapat meningkatkan resolusi gambar dapat diterapkan di berbagai bidang. Salah satu implementasinya adalah dalam deteksi plat nomor kendaraan. Dengan menggunakan teknologi Deep Learning SRGAN yang mampu meningkatkan resolusi gambar, membuat proses pengenalan objek menjadi lebih mudah. Dalam studi ini, model dilatih dengan 1.070 gambar, termasuk 535 gambar beresolusi rendah dan 535 gambar beresolusi tinggi. Model kemudian diuji dengan 10 gambar beresolusi rendah. Hasilnya menunjukkan bahwa model dapat meningkatkan resolusi gambar hingga $2x$ dari gambar masukan. Evaluasi model menghasilkan nilai PSNR rata-rata sebesar 20,1587 dB untuk input image dan 21,1831 dB untuk output model. Nilai SSIM rata-rata adalah 0,5215 untuk input image dan 0,6331 untuk output model.

Kata Kunci: deep learning, machine learning, plat nomor, resolusi gambar, SRGANs

1. Pendahuluan

Makin maraknya pelanggaran lalu lintas yang terjadi di Indonesia dapat meningkatkan tingkat kecelakaan lalu lintas di Indonesia. Menurut data dari Badan Pusat Statistik (BPS) dan Kantor Kepolisian Republik Indonesia (Polri), jumlah kecelakaan lalu lintas yang terjadi dari tahun 2016 sampai 2021, yaitu sebanyak 640.270 kasus kecelakaan lalu lintas, di mana pada tahun 2019 terjadi kecelakaan lalu lintas tertinggi, yaitu sebanyak 116.411 kasus kecelakaan lalu lintas yang terjadi di Indonesia. Selain itu, untuk kasus pelanggaran lalu lintas yang terjadi dari Januari 2021 sampai Oktober 2021, sudah tercatat bukti pelanggaran (tilang) sebanyak 1,77 juta. Dari jumlah tersebut, sebanyak 793.821 tilang atau 44,89% merupakan pelanggaran ringan, 746.153 tilang atau 42,22% merupakan pelanggaran berat, dan sebanyak 227.819 tilang atau 12,89% merupakan pelanggaran sedang [1].

Untuk mengurangi tingkat pelanggaran lalu lintas, Polri menerapkan sistem tilang elektronik atau *Electronic Traffic Law Enforcement* (ETLE). Tilang elektronik tersebut diterapkan oleh Polri karena memiliki kelebihan dibandingkan dengan tilang manual. Salah satu kelebihan ETLE daripada tilang manual adalah ETLE lebih fleksibel. Dengan diberlakukannya ETLE ini diharapkan dapat mengurangi tingkat kecelakaan lalu lintas yang disebabkan karena pelanggaran lalu lintas [2]. Bentuk ETLE *mobile device* dibagi menjadi tiga, yaitu ETLE *mobile*

on board, ETLE mobile handheld, serta ETLE mobile Apps [3].

Akan tetapi, penerapan ETLE ini masih belum sempurna. Seperti yang terjadi di Kota Solo, di mana kemampuan kameranya yang rendah sehingga operator ruang CCTV hanya menghasilkan rekaman saja dan hasil tangkapan layarnya masih *blur*. Hal tersebut mengakibatkan plat nomor yang disorot menjadi tidak jelas [4]. Selain itu, jika kemampuan kameranya rendah, maka hasil tangkapan layar akan menjadi *blur* saat mendeteksi objek yang bergerak, seperti mobil atau motor yang sedang melaju cepat [5]. *Noise* saat pengambilan citra membuat pengenalan plat nomor kendaraan menjadi kurang akurat [6]. Oleh karena itu, untuk meningkatkan akurasi pada sistem ETLE dibutuhkan gambar yang lebih jelas. Dengan menggunakan *Super-Resolution Generative Adversarial Network* (SRGAN) akan membuat resolusi gambar yang dihasilkan oleh kamera dapat diperbesar (*upscale*) dan tidak buram (*blur*). Hasil keluaran gambar yang telah ditingkatkan resolusinya dapat digunakan dalam sistem deteksi dan pengenalan plat nomor kendaraan.

2. Tinjauan Pustaka

Pada bagian kedua penelitian ini membahas terkait tinjauan pustaka dalam penelitian terkait SRGAN dalam mendeteksi plat nomor kendaraan. Penelitian tentang pendeteksian posisi plat nomor kendaraan menggunakan metode transformasi *hough* dan *hit or miss*. Penelitian ini mengembangkan sistem ini dalam GUI Matlab dengan tahapan pengolahan citra seperti binerisasi, deteksi tepi, dan *resizing*. Evaluasi sistem dilakukan dengan mengukur nilai *recall* dan *precision*, yang menunjukkan keberhasilan pendeteksian sebesar 76%, 72%, dan 48% untuk nilai *threshold* 0,75, 0,8, dan 0,85 secara berturut-turut. Hasilnya menunjukkan bahwa *recall* rata-rata adalah 54%, 50%, dan 40%, sementara *precision* rata-rata adalah 14%, 14%, dan 12% untuk nilai *threshold* yang sama [6].

Penelitian berjudul “Pendeteksian Plat Nomor Kendaraan Menggunakan Algoritma You Only Look Once V3 dan Tesseract”. Mereka mengembangkan sistem yang dapat mendeteksi dan mengenali karakter plat nomor kendaraan dengan menggunakan algoritma *You Only Look Once* V3 untuk deteksi objek dan *Tesseract Optical Character Recognition* untuk deteksi teks dalam gambar. Hasilnya menunjukkan bahwa sistem ini mampu menampilkan deteksi objek langsung di layar laptop dan mengenali karakter teks secara *real-time* dengan merekam objek melalui webcam [7][8]. Dalam penelitian ini fokus utama adalah membuat integrasi antara algoritma perbaikan citra dengan sistem deteksi dan pengenalan plat nomor kendaraan untuk dapat meningkatkan kemampuan sistem pengenalan plat nomor kendaraan.


2.1. Deep Learning

Deep learning merupakan sub bidang dari *machine learning* yang algoritmanya terinspirasi oleh struktur dan fungsi otak manusia yang disebut Jaringan Saraf Tiruan (JST) [9]. Sebagai sebuah teknologi, *deep learning* bekerja menggunakan berbagai algoritma dengan kegunaan dan keunggulan yang berbeda-beda, sehingga pemilihannya perlu disesuaikan dengan kebutuhan [10]. Dua arsitektur yang umum digunakan adalah *Convolutional Neural Network* (CNN), yang efektif untuk mendeteksi dan mengenali objek pada data citra (gambar) [11], serta *Recurrent Neural Network* (RNN) yang dirancang secara khusus untuk memproses data berurutan (*sequential*) [12]. Pendekatan lainnya adalah *Generative Adversarial Networks* (GAN), sebuah kelas algoritma *self-supervised learning* yang mengimplementasikan dua jaringan saraf—sebuah model *generator* untuk menghasilkan data baru dan sebuah model *discriminator* untuk membedakan data asli dari data palsu. Kedua model ini dilatih secara bersamaan dalam kerangka *zero-sum game* yang bersifat adversarial hingga model *generator* mampu menghasilkan data baru yang sangat realistis, sehingga dapat “menipu” *discriminator* [13].

2.2. Super-Resolution GAN(SRGAN)

Super-Resolution GAN (SRGAN) menerapkan *deep network* yang dikombinasikan dengan *adversary network* untuk menghasilkan gambar dengan resolusi yang lebih tinggi. Selama proses *training*, gambar resolusi tinggi atau *high resolution* (HR) di-*downsampling* ke gambar

resolusi rendah *low resolution* (LR). Generator GAN meng-*upsampling* gambar LR ke gambar *super-resolution* (SR). Diskriminator digunakan untuk membedakan gambar HR dan *backpropagate loss* GAN untuk melatih diskriminator dan generator [14] seperti yang ditampilkan pada Gambar 1.



Gambar 1. Proses Training SRGAN

Pada Gambar 1, metode SRGAN digunakan untuk meningkatkan resolusi citra dari rendah ke tinggi (*super-resolution*) melalui dua arsitektur jaringan utama, yaitu jaringan generator dan jaringan diskriminator. Jaringan generator, yang mengadopsi koneksi loncat (*skip connection*) mirip ResNet, memiliki *residual block* sebagai komponen intinya. Setiap *block* terdiri dari dua lapisan konvolusional dengan kernel 3×3 dan 64 *feature maps*, yang diikuti oleh *batch normalization* dan fungsi aktivasi *Parametric ReLU* (PReLU). Untuk proses *upsampling*, generator menggunakan dua lapisan *sub-pixel convolutional*.

Sementara itu, jaringan diskriminator bertugas untuk membedakan antara citra *high-resolution* (HR) asli dengan citra hasil *super-resolution* (SR) dari generator. Arsitekturnya terdiri dari delapan lapisan konvolusional dengan kernel 3×3 , di mana jumlah filter meningkat secara bertahap dari 64 hingga 512. Jaringan ini menggunakan fungsi aktivasi *Leaky ReLU* ($\alpha=0.2$) dan *strided convolution* untuk mereduksi resolusi sebagai pengganti *max-pooling*. Pada bagian akhir, arsitektur ini diakhiri dengan dua *dense layer* dan sebuah fungsi aktivasi *sigmoid* untuk menghasilkan probabilitas klasifikasi [15].

2.3. Loss Function pada SRGAN

Fungsi kerugian (*loss function*) merupakan komponen krusial untuk mengukur tingkat kesalahan antara prediksi model dan nilai sebenarnya. Pada arsitektur SRGAN, fungsi kerugian yang digunakan adalah kombinasi dari *adversarial loss* dan *perceptual loss*. Secara spesifik, *perceptual loss* (juga dikenal sebagai *content loss*) berfokus pada evaluasi kesamaan fitur visual pada level yang lebih tinggi, bukan sekadar perbedaan piksel. Untuk mencapainya, sebuah jaringan konvolusional yang telah dilatih sebelumnya (*pre-trained*), seperti VGG atau ResNet, dimanfaatkan untuk mengekstraksi representasi fitur dari citra hasil generator dan citra referensi (asli). Nilai *perceptual loss* kemudian dihitung berdasarkan *Mean Squared Error* (MSE) antara fitur-fitur yang diekstraksi dari citra input $F(x)$ dan citra target (y) [16]. *Perceptual loss* didefinisikan dalam Persamaan 1.

$$L(x, y) = \frac{1}{n} \sum_{i=1}^n (F(x)_i - F(y)_i)^2 \quad (1)$$

Di mana:

- x = input
- y = target
- $F(x)$ = hasil ekstraksi input
- $F(y)$ = hasil ekstraksi output

Adversarial loss merupakan konsep fundamental dalam *Generative Adversarial Networks* (GAN) yang mendorong interaksi kompetitif antara dua komponen utamanya, yaitu Generator (G) dan Diskriminator (D). Proses ini bekerja secara adversarial, di mana G dilatih untuk menghasilkan data yang tidak dapat dibedakan dari data asli, sementara D dilatih untuk makin akurat dalam membedakan antara data nyata dan data palsu. Nilai *loss* ini dihitung

berdasarkan probabilitas keluaran D yang berkisar antara 0 hingga 1 dalam mengklasifikasikan sebuah data. Tujuan akhirnya adalah untuk melatih G hingga mampu menghasilkan data yang sangat realistis sehingga "menipu" D dan membuatnya kesulitan untuk membedakannya dari data asli. *Adversarial loss* didefinisikan dalam Persamaan 2.

$$\text{Min}_G \text{Max}_D V(D, G) = E_x[\log D(x)] + E_z[\log(1 - D(G(z)))] \quad (2)$$

Di mana:

G = generator

D = discriminator

$D(x)$ = discriminator menganggap data asli (x)

$G(z)$ = data palsu (z) yang dihasilkan generator

2.4. Evaluasi Model SRGAN

PSNR (*Peak Signal-to-Noise Ratio*) adalah ukuran kuantitatif yang digunakan untuk mengukur sejauh mana gambar hasil perbaikan mendekati gambar asli dengan memperhitungkan perbedaan antara sinyal gambar dan tingkat derau (*noise*) dalam gambar tersebut. PSNR diukur dalam satuan desibel (dB) dan diperoleh dengan menghitung perbandingan antara nilai maksimal sinyal gambar asli dengan rata-rata kuadrat perbedaan antara piksel gambar asli dan piksel gambar hasil perbaikan [17]. Nilai ideal dari PSNR yaitu sekitar 30 dB (desibel), namun ada juga yang di bawah 30 db (tergantung gambar *inputnya*). Makin tinggi nilai PSNR, maka makin tinggi tingkat kemiripan antara gambar asli dengan gambar hasil dari generator model (gambar buatan). Rumus matematis PSNR dinyatakan pada Persamaan 3.

$$\text{PSNR}(I_1, I_2) = 10 \log_{10} \left(\frac{R^2}{\text{MSE}(I_1, I_2)} \right) \quad (3)$$

Di mana:

I_1 = citra asli atau referensi (*ground truth*)

I_2 = citra yang telah direstorasi

R = rentang nilai piksel dalam citra

Sementara untuk metode MSE dapat ditulis dengan Persamaan 4.

$$\text{MSE}(I_1, I_2) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N [I_1(i, j) - I_2(i, j)]^2 \quad (4)$$


Structural Similarity Index (SSIM) adalah metrik yang lebih kompleks daripada PSNR dan lebih mencerminkan persepsi visual manusia terhadap gambar. SSIM memperhitungkan tiga aspek utama: perbandingan kontras, perbandingan struktur, dan perbandingan kecerahan antara gambar asli dan hasil perbaikan [17].

3. Metodologi Penelitian

Metode yang digunakan dalam perancangan sistem perbaikan kualitas gambar dalam deteksi plat nomor kendaraan yaitu menggunakan metode *deep learning super resolution GAN*. Proses perbaikan kualitas gambar dimulai dengan menyiapkan *dataset*, dilanjutkan dengan proses augmentasi *dataset*. Setelah *dataset* siap maka akan dilanjutkan dengan membagi data menjadi *data training* dan *data test*, kemudian dilakukan proses *training* sekaligus dilakukan proses evaluasi. Model yang telah dievaluasi dapat digunakan untuk tahap akhir, yaitu proses testing model menggunakan gambar baru yang memiliki resolusi rendah.

Pada proses perbaikan citra dilakukan dengan metode *deep learning* menggunakan model SRGAN (*Super-Resolution Generative Adversarial Network*). SRGAN adalah metode *deep*

learning untuk meningkatkan kualitas gambar resolusi rendah menjadi resolusi tinggi. Terdiri dari dua jaringan, yaitu G yang menghasilkan gambar tajam, dan D yang membedakan antara gambar hasil buatan dan gambar asli. Keduanya dilatih secara bersamaan dalam sistem adversarial. Evaluasi dilakukan menggunakan metrik PSNR, SSIM, dan LPIPS; SRGAN dikatakan baik jika menghasilkan nilai PSNR > 28 dB, SSIM > 0,9, dan LPIPS < 0,15, serta secara visual mampu menghasilkan gambar yang tajam, jelas, dan mendekati aslinya. Alur proses penelitian seperti terlihat pada Gambar 2.




Gambar 2. Alur Proses Penelitian

3.1. Dataset

Dataset yang digunakan untuk merancang model *deep learning* ini adalah *dataset* berupa gambar asli yang diambil dari hasil foto menggunakan kamera dan hasil pengumpulan gambar plat nomor kendaraan yang bersumber dari Kaggle. Jumlah gambar dari *dataset* gambar asli yaitu 535 gambar. Gambar asli dari *dataset* tersebut akan dijadikan sebagai materi untuk proses *training* pada model *deep learning*. Akan tetapi, *dataset* tersebut harus diolah terlebih dahulu agar menjadi data yang dapat digunakan dalam proses *training*. Oleh karena itu, penulis melakukan *synthetic dataset* yang bertujuan untuk membuat *dataset* yang dapat digunakan untuk proses *training*. Pada *synthetic dataset*, penulis melakukan penyesuaian ukuran resolusi gambar sehingga *dataset* memiliki dua jenis gambar yaitu LR (*Low Resolution*) dan HR (*High Resolution*). Kemudian, dari *dataset* tersebut dibagi menjadi dua bagian, yaitu *data train* dan *data validation*.

3.2. Data Augmentasi

Melakukan *data augmentation* (augmentasi data) dalam konteks *self-supervised learning*, khususnya pada tugas rekonstruksi gambar, merupakan pendekatan strategis yang bertujuan untuk meningkatkan kemampuan model dalam mengeneralisasi informasi dari data yang belum pernah dilihat sebelumnya. Dalam skenario *self-supervised learning*, sistem diinstruksikan untuk memprediksi sebagian informasi dari data *input* tanpa memerlukan anotasi label yang eksplisit sehingga dapat menjadi tantangan bagi model dalam mengartikan variasi kompleks yang terdapat dalam data. Ilustrasi pada Gambar 2 menggambarkan proses augmentasi data yang dilakukan oleh penulis.




Gambar 3. Hasil Data Augmentation

Pada Gambar 3, augmentasi gambar yang dilakukan yaitu membuat data tersebut menjadi dua bagian, yaitu data yang memiliki resolusi tinggi dengan *resize* gambar tersebut. Untuk gambar yang beresolusi kecil, maka diberi *size* 128×128 . Sedangkan untuk data gambar yang beresolusi tinggi, maka diberi *size* 256×256 . Gambar tersebut akan dibuat *blur* dengan menggunakan *Gaussian Blur* dengan kernel 3×3 terlebih dahulu sebelum menjadi data latih.

3.3. Proses Training

Pada saat *training*, model yang dibuat akan dilatih dengan jumlah *epoch* sebanyak 100 dengan *learning rate* sebesar 0,0003 dan *batch_size* = 16. Gambar hasil prediksi saat proses *training* pada *epoch* ke-1 dapat dilihat pada Gambar 4. Proses *training* pada model SRGAN tidak menunjukkan *training loss* dan *validation*, pada model SRGAN *training* dapat dievaluasi dengan matrik PSNR dan SSIM.


Selain itu, juga dapat dilihat dari hasil visual seperti pada Gambar 4 yang menunjukkan proses *epoch* mulai *epoch* 1 sampai dengan *epoch* 100. Hasil evaluasi PSNR dan SSIM seperti pada Tabel 1. Setelah dilatih dengan *epoch* sebanyak 100, maka akan terlihat pada Gambar 5. Kemudian setelah proses *training* selesai, dilakukan sebuah pengujian dengan menggunakan gambar acak untuk memprediksi hasil dari SRGANs, maka hasilnya seperti Gambar 6.



Gambar 4. Hasil Training Model SRGAN dengan Epoch ke-1



Gambar 5. Hasil Training Model SRGAN dengan Epoch ke-100



Gambar 6. Hasil Prediksi Model SRGAN

4. Hasil dan Pembahasan

Hasil dan pembahasan terkait penelitian ini dibahas berdasarkan pengujian yang dilakukan. Pengujian dilakukan dengan memberikan data gambar beresolusi rendah untuk ditingkatkan kualitasnya. Setelah ditingkatkan maka gambar beresolusi tinggi dapat digunakan dalam proses deteksi dan pengenalan karakter plat nomor kendaraan.

4.1. Pengujian Peningkatan Kualitas Gambar Plat Nomor Kendaraan

Pada tahap pengujian ini, penulis mencoba untuk menggunakan data dari luar berupa data gambar kendaraan beserta plat nomor kendaraan dengan kondisi *blur*. Setiap gambar akan diuji dengan model yang sudah dibuat, setelah itu akan dievaluasi dengan menggunakan beberapa *metrics* seperti PSNR, dan SSIM. Hasil pengujian terhadap gambar lainnya dapat dilihat pada Gambar 6.



Gambar 7. Hasil Pengujian dengan Gambar Resolusi Rendah: (a) Gambar Masukan (b) Hasil Perbaikan Kualitas Gambar

Pada Gambar 7 terlihat bahwa model SRGANs yang sudah dilatih dapat meningkatkan kualitas gambar sebelumnya meskipun belum sempurna dikarenakan model SRGAN yang dibuat hanya dapat meningkatkan resolusi gambar sebesar dua kali dari gambar masukan. Gambar hasil proses SRGANs tersebut memiliki hasil evaluasi *metrics* seperti pada Tabel 1.

Tabel 1. Hasil Evaluasi Model SRGAN

Model	PSNR	SSIM
Bicubic	19,7056	0,5376
Model Peneliti	20,8019	0,6535

Pada Tabel 1 terlihat bahwa model yang dibuat memiliki nilai evaluasi menggunakan beberapa *metrics* seperti PSNR dan SSIM, yang mana nilai evaluasi tersebut didapatkan dari percobaan yang telah dilakukan, yaitu dari perhitungan antara gambar asli dengan gambar yang di-*generate* oleh model SRGAN. Terlihat bahwa terdapat peningkatan nilai PSNR dan SSIM dari data *input* setelah dilakukan *generate* pada gambar.

Untuk pengujian gambar lainnya, penulis menggunakan gambar kendaraan beserta plat nomor kendaraan, di mana terdapat 10 gambar *low resolution* yang akan dijadikan *input* dan 10 gambar *high resolution* yang merupakan gambar asli. Gambar *high resolution* tersebut akan dijadikan sebagai acuan untuk menentukan nilai PSNR dari *input* dan hasil model seperti yang terlihat pada Tabel 2.

Tabel 2. Perbandingan Nilai PSNR Gambar Masukan dengan Hasil Model

Gambar	Input (Bicubic)	Model
1	19,7056	20,8019
2	20,1907	21,2043
3	20,2487	21,4789
4	20,4965	21,3697
5	19,8079	20,1734
6	21,6732	22,3667
7	19,5054	21,8632
8	20,1072	21,6893
9	19,6055	19,9958
10	20,2467	20,8879
Rata-rata	20,1587	21,1831

Pada Tabel 2 terlihat bahwa nilai PSNR dari setiap gambar yang diuji memiliki nilai yang berbeda, di mana gambar *input* pada dasarnya memiliki nilai PSNR di bawah gambar hasil peningkatan oleh model. Rata-rata nilai PSNR dari gambar *input* adalah 20,1587 dB, sedangkan rata-rata nilai PSNR dari gambar hasil model yang dibuat adalah 21,1831 dB. Dari nilai rata-rata PSNR tersebut dapat dikatakan bahwa gambar hasil dari model yang dibuat lebih jelas daripada gambar *input*nya.

Selain pengujian untuk menentukan nilai PSNR, penulis juga melakukan pengujian terhadap nilai SSIM dari 10 gambar yang sama saat pengujian menentukan nilai PSNR sebelumnya. Hasil dari pengujian nilai SSIM dapat dilihat pada Tabel 3.


Tabel 3. Perbandingan Nilai SSIM Gambar Masukan dengan Hasil Model

Gambar	Input (Bicubic)	Model
1	0,5376	0,6535
2	0,4357	0,5667
3	0,6739	0,7634
4	0,4837	0,5903
5	0,5046	0,6172
6	0,4906	0,6017
7	0,5782	0,6841
8	0,5203	0,6492
9	0,4751	0,5677
10	0,5156	0,6371
Rata-rata	0,5215	0,6331

Pada Tabel 3 terlihat bahwa nilai SSIM dari setiap gambar yang diuji memiliki nilai yang berbeda, di mana gambar *input* pada dasarnya memiliki nilai SSIM di bawah gambar hasil peningkatan oleh model. Rata-rata nilai SSIM dari gambar *input* adalah 0,5215, sedangkan rata-rata nilai SSIM dari gambar hasil model yang dibuat adalah 0,6331. Dari nilai rata-rata SSIM tersebut dapat dikatakan bahwa gambar hasil dari model yang dibuat lebih mirip dengan gambar aslinya, sedangkan gambar *input* berada di bawah gambar hasil model yang sudah dibuat.

4.2. Integrasi Model dan Pengujian Pengenalan Plat Nomor Kendaraan

Setelah proses pengujian model peningkatan kualitas gambar, proses selanjutnya adalah melakukan integrasi pada sistem deteksi dan pengenalan plat nomor kendaraan. Pengujian dilakukan untuk melihat apakah plat nomor kendaraan dapat terdeteksi atau tidak setelah proses peningkatan kualitas gambar. Hasil pengenalan plat nomor seperti terlihat pada Gambar 8.



Gambar 8. Hasil Deteksi dan Pengenalan Plat Nomor: (a) Gambar Masukan, (b) Gambar Hasil Model, dan (c) Gambar Asli

Pada Gambar 8 terlihat bahwa Gambar (a) adalah gambar awal yang merupakan data gambar terdegradasi sebelum dilakukan perbaikan kualitas gambar dengan model SRGAN. Setelah dilakukan proses deteksi dan pengenalan, hasilnya karakter tidak dapat dikenali dengan jelas. Gambar 8(b) adalah Gambar yang sudah dilakukan proses peningkatan kualitas gambar dengan model yang SRGAN. Hasilnya Gambar 8(b) dapat mengenali karakter plat nomor dengan benar. Sementara pada gambar 8(c) adalah gambar asli dari plat nomor yang tidak terdegradasi dan hasilnya seluruh karakter dapat dikenali dengan baik.

5. Kesimpulan dan Saran

Berdasarkan hasil pengujian, penulis menyimpulkan bahwa model yang dibuat dapat melakukan peningkatan resolusi gambar. Selain itu, pada pengujian pendeteksi plat nomor kendaraan terdapat perbedaan akurasi antara gambar *input* dengan gambar yang sudah diperbaiki dengan model. Model yang telah dibuat dapat meningkatkan resolusi gambar sebesar 2 kali dari gambar *input*. Hasil evaluasi menggunakan *metrics* PSNR berdasarkan perhitungan pada Tabel 2 yang membandingkan gambar *input* dan hasil model maka nilai rata-rata gambar *input* 20,1587 dB dan nilai rata-rata model yaitu sebesar 21,1831 dB yang membuktikan bahwa gambar hasil model lebih jelas daripada gambar *input*. Sedangkan untuk *metrics* SSIM Tabel 3, gambar *input* memiliki nilai rata-rata sebesar 0,5215 dan nilai model yaitu sebesar 0,6331. Hasil ini membuktikan bahwa gambar hasil keluaran model lebih mirip dengan gambar aslinya. Dari hasil evaluasi tersebut dapat dinyatakan bahwa model sudah dapat meningkatkan resolusi gambar sehingga berpengaruh terhadap tingkat akurasi dari pengenalan plat nomor kendaraan.

Referensi

- [1] R. Pahlevi, "Jumlah Tilang Lalu Lintas Capai 1,77 Juta hingga Oktober 2021," Nov. 09, 2021. [Online]. Available: <https://databoks.katadata.co.id/datapublish/2021/11/09/jumlah-tilang-lalu-lintas-capai-177-juta-hingga-oktober-2021> (accessed: Nov. 15, 2022).
- [2] G. Satria, "Ini Alasan Polisi Gencarkan Tilang Elektronik," Feb. 03, 2021. [Online]. Available: <https://otomotif.kompas.com/read/2021/02/03/102200115/ini-alasan-polisi-gencarkan-tilang-elektronik> (accessed Nov. 15, 2022).
- [3] Korlantas Polri, "Korlantas Polri Luncurkan ETLE di Seluruh Indonesia - Korlantas Polri," Sep. 22, 2022. [Online]. <https://korlantas.polri.go.id/news/korlantas-polri-luncurkan-etle-di-seluruh-indonesia/> (accessed Nov. 15, 2022).
- [4] Arri Widiarto, "Efisienkah Tilang Elektronik di Kota Solo?," Apr. 25, 2022. [Online]. Available: <https://www.ayosemarang.com/netizen/pr-773276650/efisienkah-tilang-elektronik-di-kota-solo> (accessed Jun. 11, 2023).
- [5] Abdul Alim Muhamad, "ETLE Punya Kelemahan di Blank Spot Area," Mar. 30, 2021. [Online]. Available: <https://www.gatra.com/news-507814-hukum-etle-punya-kelemahan-di-blank-spot-area.html> (accessed Jun. 12, 2023).
- [6] Y. Puspito, F. X. Setyawan, and H. Fitriawan, "Deteksi posisi plat nomor kendaraan menggunakan metode transformasi Hough dan hit or miss," *ELECTRICIAN-Jurnal Rekayasa dan Teknologi Elektro*, pp. 118–123, 2018.
- [7] M. Mazlan, E. Ismaredah, H. Simaremare, and O. B. Kharisma, "Desain sistem pendeteksi plat kendaraan untuk pengisian BBM menggunakan metode K-Nearest Neighbor (KNN)," *Journal of Information System Research (JOSH)*, vol. 4, no. 4, pp. 1118–1126, 2023.
- [8] S. Sugeng and E. Syamsuddin, "Perancangan Algoritma Optimasi Pada Pengenalan Karakter Plat Nomor Kendaraan Menggunakan Pengolahan Citra," *Komputika : Jurnal Sistem Komputer*, vol. 9, no. 2, pp. 155–164, Oct. 2020, doi: 10.34010/komputika.v9i2.3682.
- [9] J. Huixian, "The Analysis of Plants Image Recognition Based on Deep Learning and Artificial Neural Network," *IEEE Access*, vol. 8, pp. 68828–68841, 2020, doi: 10.1109/ACCESS.2020.2986946.
- [10] I. Arifin, R. F. Haidi, and M. Dzalhaqi, "Penerapan computer vision menggunakan metode deep learning pada perspektif generasi ulul albab," *Jurnal Teknologi Terpadu*, vol. 7, no. 2, pp. 98–107, 2021, doi: 10.54914/jtt.v7i2.436.
- [11] R. Radikto, D. I. Mulyana, M. A. Rofik, and M. O. Z. Zakaria, "Klasifikasi kendaraan pada jalan raya menggunakan algoritma Convolutional Neural Network (CNN)," *Jurnal Pendidikan Tambusai*, vol. 6, no. 1, pp. 1668–1679, 2022, doi: 10.31004/jptam.v6i1.3179.
- [12] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, vol. 8, no. 1, pp. 53, 2021, doi: 10.1186/s40537-021-00444-8.

- [13] A. Maulana, C. Fatichah, and N. Suciati, "Facial inpainting in unaligned face images using generative adversarial network with feature reconstruction loss", *Jurnal Ilmiah Teknologi Informasi*, vol. 18, no. 2, pp. 171–178, 2022.
- [14] A. R. P. Gondosiswojo and A. G. P. Kusuma, "Low resolution face recognition on CCTV images using a combination of super resolution and face recognition models", *Journal of Theoretical and Applied Information Technology*, vol. 101, pp. 20, 2023.
- [15] C. Ledig *et al.*, "Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network." *arXiv*, 2016. doi: 10.48550/ARXIV.1609.04802.
- [16] P. Liu, Y. Hong, and Y. Liu, "A Novel Multi-Scale Adaptive Convolutional Network for Single Image Super-Resolution," *IEEE Access*, vol. PP, p. 1, Aug. 2019, doi: 10.1109/ACCESS.2019.2908003.
- [17] D. R. I. M. Setiadi, "PSNR vs SSIM: imperceptibility quality assessment for image steganography," *Multimed Tools and Applications*, vol. 80, no. 6, pp. 8423–8444, 2021, doi: 10.1007/s11042-020-10035-z.