

PERANCANGAN DAN IMPLEMENTASI IMAGE ENHANCEMENT PLAT NOMOR KENDARAAN DENGAN MEMBANDINGKAN METODE SRCNN DAN VDSR

Razzaq Alfalaq
Electrical Engineering Faculty
Telkom University
Bandung, Indonesia
ralfalaq@student.telkomuniversity.ac.id

Irma Safitri
Electrical Engineering Faculty
Telkom University
Bandung, Indonesia
irmasafitri@telkomuniversity.ac.id

Syamsul Rizal
Electrical Engineering Faculty
Telkom University
Bandung, Indonesia
syamsul@telkomuniversity.ac.id

Abstrak — Kendaraan adalah alat transportasi yang paling banyak digunakan di seluruh Indonesia. Pada plat nomor kendaraan di Indonesia terdiri dari huruf dan angka, dengan setiap daerah memiliki kode karakter plat nomor kendaraan masing-masing. Tugas Akhir ini dirancang sistem yang bisa membaca plat kendaraan khususnya kendaraan bermotor dengan menggunakan metode *Super Resolution Convolutional Neural Network* (SRCNN) dapat meningkatkan akurasi pengenalan plat nomor kendaraan dan *Very Deep Super-Resolution* (VDSR) untuk mengeksplorasi peningkatan kinerja SR dengan peningkatan kedalaman jaringan. Dataset yang digunakan bersumber dari diskominfo kota Malang. Hasil akhir yang telah didapatkan pada metode SRCNN dan VDSR dengan menggunakan *optimizer adam* dan *activator relu* untuk layer *convolution*, metode VDSR mendapatkan nilai PSNR 39.756 dB dan MSE 0.001, dan metode SRCNN mendapatkan nilai PSNR 37.329 dB dan MSE 0.001. Dari hasil tersebut dapat disimpulkan VDSR melakukan rekonstruksi gambar super resolusi dengan baik.

Kata kunci : *Image enhancement, Super Resolution Convolutional Neural Network, Very Deep Super Resolution*

I. PENDAHULUAN

Rambu lalu lintas adalah salah satu dari perlengkapan jalan yang berisi lambang, huruf, angka, kalimat dan atau gabungan diantaranya yang berfungsi sebagai pemberi peringatan, larangan, perintah dan petunjuk kepada para pengguna jalan (Undang-undang Republik Indonesia, 2009). Saat ini banyak pengendara yang masih belum memahami apa arti dari rambu-rambu lalu lintas yang dilihatnya sehingga banyak yang melakukan pelanggaran baik secara sengaja maupun tidak disengaja. Menurut data pada badan pusat statistik, pada tahun 2020, jumlah kendaraan di kota Bandung provinsi Jawa Barat mencapai 1,089,966

kendaraan. Sebuah kendaraan akan mempunyai tanda pengenal berupa (TNKB) Tanda Nomor Kendaraan Bermotor. TNKB terdiri dari dua baris, baris pertama terdiri dari huruf yang menunjukkan kode wilayah, selanjutnya diikuti nomor dan kode area yang menunjukkan kabupaten domisili pemilik kendaraan. Baris kedua menunjukkan bulan serta tahun masa berlaku TNKB [1]. Studi kasus ini diambil untuk mengimplementasikan dua hal yang tentang pendeteksian lokasi dari sebuah plat dalam kendaraan dan setelah lokasi plat tersebut ditemukan maka sebuah sistem harus dapat membaca plat tersebut secara benar. Diketahui bahwa metode yang diimplementasikan pada penelitian deteksi pelat nomor kendaraan adalah metode dari *image processing* dan *deep learning*. Penelitian ini menggunakan metode *image processing*.

Pengambilan citra dilakukan dengan meletakkan kamera di berbagai tempat. Penelitian ini menggunakan kamera CCTV yang terpasang di setiap sudut tiang lampu lalu lintas. Pada penelitian sebelumnya yang dilakukan oleh Hasan Imaduddin, Muhammad Khoiril, Muhammad Ilham Perdana, dan Indra Adji Sulistijono, mengusulkan penggunaan *Convolutional Neural Network* (CNN) dengan hasil yang cukup baik dengan persentase keberhasilan deteksi plat nomor sebesar 68% [2]. Penelitian ini menggunakan metode *Super Resolution Convolutional Neural Network* (SRCNN) yang diterapkan dalam meningkatkan akurasi deteksi kendaraan dari citra resolusi tinggi. Namun, SRCNN belum banyak digunakan untuk melakukan rekonstruksi citra plat nomor khususnya untuk tujuan peningkatan akurasi pengenalan karakter [3]. Pada umumnya, citra beresolusi tinggi memiliki kerapatan piksel yang lebih padat, maka citra dengan resolusi tinggi memiliki detail yang lebih baik di bandingkan dengan citra resolusi rendah [4]. Namun pada metode SRCNN masih belum bisa menghasilkan citra dengan tepi yang jelas dan tekstur yang baik [5]. Penelitian ini menggunakan metode *very*

deep super-resolution (VDSR) menggunakan *Deep CNN* dengan memperkenalkan jaringan residual untuk melatih arsitektur jaringan yang jauh lebih dalam. *VDSR* mempelajari sisa antara resolusi rendah dan gambar resolusi tinggi sebagai lawan dari pemetaan langsung. Memungkinkan jaringan menjadi jauh lebih dalam, dan tetap memperthankan tingkat konvergensi yang sesuai [6].

II. KAJIAN TEORI

A. Spesifikasi Plat Nomor Kendaraan

Plat nomor kendaraan merupakan salah satu bentuk identitas kendaraan, dan setiap negara memiliki spesifikasi yang berbeda. Di Indonesia sendiri memiliki bentuk fisik berupa lembaran plat aluminium dan memiliki susunan huruf dan angka. Roda dua memiliki ukuran plat dengan tinggi 275 milimeter dan tinggi 110 milimeter lebarnya, sedangkan kendaraan roda empat atau lebih tingginya 430 milimeter dan lebar 135 milimeter [7]. Kumpulan data yang akan digunakan adalah mobil pribadi (plat hitam).

B. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan jenis jaringan saraf dalam mempelajari hierarki fitur kompleks dengan konvolusi, aktivasi non-linear, dan lapisan penyatuan. *CNN* dirancang untuk pengenalan dan klasifikasi gambar. Kelebihannya yaitu bahwa input jaringan akan menjadi jelas ketika input dan gambar multidimensi dapat langsung masuk ke dalam jaringan, sehingga dapat menghindari pengalihan fitur yang kompleks dan rekonstruksi data.




Figure 1. Arsitektur CNN

C. Super Resolution Convolutional Neural Network

Metode ini merupakan kombinasi dari citra *Convolutional Neural Network (CNN)* dan integrasi metode super resolution umum. Tujuan utama adalah untuk secara efektif menyederhanakan dan mengurangi jumlah parameter yang terlibat dalam neural network [18]. *Super resolution* terbagi dalam tiga tahap, yaitu: ekstraksi dan ekstraksi khusus blok gambar, pemanfaatan sifat jaringan konvolusional untuk mengekstrak fitur dari blok gambar, pemetaan non-linear, dan rekonstruksi [19]. Metode ini dibentuk oleh 3 lapisan CNN, yaitu ekstraksi ciri citra dan representasi, pemetaan non-linear, dan rekonstruksi dari citra beresolusi tinggi.




Figure 2 Proses SRCNN [20]

D. Very Deep Super Resolution

Very Deep Super Resolution (VDSR) terdiri dari 20 layer VGG-Net. Metode ini mampu meningkatkan akurasi secara signifikan dibandingkan metode sebelumnya dan mencapai kinerja yang unggul. Dengan menggunakan arsitektur yang lebih dalam, *VDSR* memanfaatkan pemahaman bahwa pemetaan piksel ke piksel langsung, yang telah digunakan di masa lalu saat melakukan super resolusi, terlalu kompleks dan mengakibatkan tingkat konvergensi yang lambat [6]. *VDSR* bertujuan untuk mengeksplorasi peningkatan kinerja *Super Resolution* dengan meningkatkan kedalaman jaringan.

Model terakhirnya ditunjukkan pada Gambar menggunakan 20 lapisan dengan filter kecil untuk mendapatkan bidang reseptif yang lebih besar. Dengan tujuan mencapai performa yang lebih baik dan meningkatkan kecepatan, *VDSR* didasarkan pada fakta bahwa gambar *Low Resolution (LR)* dan gambar *High Resolution (HR)* berbagi informasi yang sama untuk sebagian besar. Sisa antara gambar *HR* dipelajari menggunakan learning rate yang sangat tinggi, menggabungkan gambar *LR* untuk menghasilkan gambar *HR* [21].




Figure 3 Arsitektur VDSR [22]

E. Epoch

Epoch adalah satu putaran lengkap dari seluruh dataset pelatihan yang digunakan untuk melatih model dalam pembelajaran mesin. Dalam konteks jaringan saraf, epoch berarti satu kali iterasi di mana seluruh data pelatihan melewati jaringan saraf, menyebabkan penyesuaian bobot-bobot (weights) agar sesuai dengan data. [23] Epoch menandakan satu siklus algoritma machine learning di mana model "belajar" dari seluruh set data pelatihan yang ingin diproses. Dalam prakteknya, penggunaan mini-batch memungkinkan proses pembelajaran dari sebagian data pada setiap epoch, bukan seluruh dataset sekaligus. Dengan demikian, mesin tidak belajar dari keseluruhan data secara simultan, tetapi dari sejumlah batch data yang telah ditentukan sebelumnya.

F. Optimizer

Optimizer merupakan algoritma untuk memperbarui *weight* dan *bias* pada proses pembelajaran yang bertujuan untuk meminimalisir *loss function* dengan caramenyamakan *output* yang diinginkan dengan *output* yang diprediksi [24]. Pada penelitian ini, ada tiga *optimizer* yang akan digunakan dalam proses pengujian yaitu *Adaptive Moment (Adam)*, *Stochastic Gradient Descent (SGD)*, dan *Root Mean Square (RMSprop)*.

III. METODE

A. Desain Sistem

dirancang sistem untuk *Super Resolution Convolutional Neural Network (SRCNN)* dan *Very Deep Super Resolution (VDSR)*. Dengan hasil output peningkatan kualitas gambar dari gambar yang beresolusi rendah ke gambar yang beresolusi tinggi. Dengan membandingkan hasil PSNR dan SSIM




Figure 4. Diagram alir SRCNN dan VDSR

dua percobaan tersebut maka akan didapatkan perbandingan hasil manakah yang memiliki kualitas gambar yang lebih baik. Secara umum desain rancangan sistem SRCNN dan VDSR dapat dilihat gambar.

1. Dataset, merupakan proses mendapatkan gambar citra kendaraan
2. Data Preparation yaitu tahap membantu memastikan bahwa data akurat, konsisten, dan sesuai untuk analisis atau pemodelan
3. Testing Dataset merupakan bagian terpisah dari Kumpulan data yang digunakan untuk mengevaluasi performa model pembelajaran mesin setelah model tersebut dilatih pada Kumpulan data,
4. Training Dataset merupakan bagian dari kumpulan data yang lebih besar yang digunakan untuk melatih model pembelajaran mesin,
5. Image Recontruction bertujuan untuk memulihkan gambar atau meningkatkan kualitas berdasarkan data parsial, terdegradasi, atau beresolusi lebih rendah
6. Super Resolution Image bertujuan untuk menghasilkan gambar dengan resolusi lebih tinggi dari satu atau lebih pengamatan dengan resolusi lebih rendah pada pemandangan atau objek yang sama.

B. SRCNN

Metode ini merupakan penggabungan dari citra *super resolution Convolutional Neural Network (CNN)* dan integrasi dari metode *super resolution* umum agar secara efektif dapat mensederhanakan dan mengurangi parameter yang ada di *neural network* [17]. *SRCNN* menggunakan interpolasi tiga gambar ganda preprocessing, perbesaran gambar resolusi rendah ke ukuran target seperti (X3, X4) tiga lapisan konvolusi, lapisan pertama menggunakan cek konvolusi 9 x 9 ekstrasi ciri citra, lapisan kedua menggunakan konvolusi bagian depan 1 x luntuk mengekstrak karakteristik parameter nonlinear,lapisan ketiga menggunakan pemeriksaan konvolusi 5 x 5 setelah

memetakan karakteristik rekonstruksi, untuk menghasilkan gambar resolusi tinggi [4].

Super resolution dibagi dalam tiga tahap, yaitu: extraction dan extraction khusus blok gambar, menggunakan sifat jaringan konvolusional untuk fitur ekstrak dari blok gambar, non-linier mapping, dan reconstruction [18]. Metode ini dibentuk 3 lapisan *CNN* yaitu ekstrasi ciri citra dan representasi, *non linear mapping*, dan rekontruksi dari citra beresolusi tinggi.




Figure 5. Struktur SRCNN

hanya berisi tiga lapisan, dan setiap lapisan memiliki lapisan konvolusi dengan fungsi aktivasi. Gambar input jaringan adalah gambar interpolasi bikubik dari gambar beresolusi rendah, dengan ukuran yang sama dengan gambar HR keluaran. Lapisan pertama terutama mengekstrak tambalan dan representasi gambar beresolusi rendah. Lapisan kedua memetakan representasi n-1dimensi (vector fitur) dari beberapa tambalan menjadi n-2dimensi, membuat pemetaan non-linear. Jumlah tambalan untuk setiap operasi pemetaan bergantung pada ukuran kernel dari lapisan konvolusi kedua. Kemudian lapisan terakhir terwujud rekontruksi gambar beresolusi tinggi.

Input	Bicubic interpolation of LR images
Number of layers	3
Residual unit	No
Parameters of 1 st layer	9 × 9 × 1 × 64
Parameters of 2 nd layer	5 × 5 × 64 × 32
Parameters of 3 rd layer	5 × 5 × 32 × 1
Learning rate	1 × 10 ⁻⁴

Figure 6 Parameter SRCNN

C. VDSR




Figure 7 Struktur VDSR

Very Deep Super-Resolution (VDSR) terdiri dari 20 layer VGG-Net. Metode ini mampu meningkatkan akurasi yang signifikan dibandingkan metode sebelumnya dan mencapai kinerja yang unggul. Bahwa jaringan yang lebih dalam memberikan kinerja lebih besar, arsitektur ini memanfaatkan bahwa saat melakukan super resolusi, pemetaan piksel ke piksel langsung yang telah digunakan di masa lalu terlalu kompleks dan mengakibatkan tingkat konvergensi yang lambat [6].

VDSR bertujuan untuk mengeksplorasi peningkatan kinerja SR dengan peningkatan kedalaman jaringan. Model terakhirnya ditunjukkan pada Gambar menggunakan 20 layer dengan filter kecil untuk mendapatkan bidang reseptif yang lebih besar. Sisa antara gambar HR dan LR yang dipelajari menggunakan learning rate yang sangat tinggi, menggabungkan gambar LR untuk menghasilkan gambar HR [19].

Input	Bicubic interpolation of LR images
Number of layers	20
Residual unit	Yes
Parameter of 1 st layer	3 x 3 x 1 x 12
Parameter of 2 nd – 19 th layer	3 x 3 x 12 x 12
Parameter of 20 th layer	3 x 3 x 12 x 1
Learning rate	1 x 10 ⁻³

Figure 8 Parameter VDSR

IV. HASIL DAN ANALISIS

A. Pengujian Sistem

Pengujian sistem dilakukan untuk mendapatkan performansi sistem yang telah dirancang. Adapun tujuan dari pengujian ini adalah sebagai berikut:

1. Mengetahui performa SRCNN dan VDSR dengan modifikasi *code* pada SRCNN dan VDSR.
2. Mendapatkan model sistem terbaik untuk modifikasi SRCNN dan VDSR.
3. Menganalisis hasil perbaikan citra menggunakan metode modifikasi pada *code* SRCNN dan VDSR yang.

B. Parameter

Parameter yang digunakan pada tugas akhir ini meliputi yaitu MSE, PSNR, dan SSIM

1. Mean Square Error (MSE)

Merupakan kuadrat rata-rata nilai *error* antara citra asli dengan citra yang telah dimodifikasi, MSE dapat dipresentasikan dengan persamaan berikut ini:

$$MSE = \frac{1}{N} \sum_{i=1}^N ||X(i) - X_{SR}(i)||_2$$

Dimana:

$X(i)$ = adalah *observed values*

X_{SR} = adalah *predicted values*

N = adalah *number of data points*

2. Peak Signal to Noise Ration (PSNR)

Adalah perbandingan antara nilai maksimum dari sinyal yang telah diukur disbanding dengan besarnya *noise* pada sinyal tersebut, PSNR dapat direpresentasikan dengan persamaan berikut ini:

$$PSNR = 10 \log_{10} \frac{L^2}{MSE}$$

Dimana:

L^2 = adalah piksel maksimum dari citra

MSE = adalah rata-rata nilai *error* antara citra asli dengan citra modifikasi

3. Structural Similiarty Index Metrics (SSIM)

Adalah kualitas *metric* yang digunakan untuk mengukur sejauh mana kemiripan antara dua buah citra yaitu citra asli dan citra yang telah dimodifikasi dengan memperhatikan tiga factor yaitu *loss of correlation*, *luminance distortion* dan *contrast distortion*, SSIM dapat direpresentasikan dengan persamaan berikut:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

Dimana:

$\mu_x, \mu_y, \sigma_x, \sigma_y$ dan σ_{xy} = adalah *local means*, *standart deviations*, dan *cross covariance* untuk citra x, y

Jika $\alpha = \beta = \gamma = 1$ maka C_1, C_2 merupakan indeks *default* untuk *exponents* nya.

C. Tahap pengujian Sistem

Dataset yang telah didapatkan akan dimasukan kedalam Google *drive*. Pengujian dilakukan untuk melihat kinerja dari sistem modifikasi SRCNN dan VDSR:

1. Tahap dan *preprocessing*

Dataset yang telah di *upload* ke dalam *drive* dibagi menjadi dua macam data yaitu *test* dan *training* persentase perbandingan nya adalah 80% untuk *training* dan 20% *test*.

2. Tahap evaluasi

Setelah dataset yang telah dibagi maka selanjutnya masuk ke tahap evaluasi sistem, pada tahap ini dataset yang telah dibagi kemudian dirubah untuk data masukan dengan mengganti *shape* menjadi (32,32,1). Setelah sesuai maka data akan di *split* menuju proses *training* dan *testing*.

3. Tahap *training*

Pada tahap ini data masukan akan dilatih sesuai dengan metode SRCNN dan VDSR,

4. Tahap *testing* dan rekonstruksi citra

Setelah melewati tahap *training* maka data akan memasuki tahap *testing* dan rekonstruksi sehingga akan muncul prediksi citra yang telah kita latih untuk dibandingkan dengan citra *distorted low* dan citra asli.

5. Tahap pengujian

Tahap terakhir dalam pengujian sistem adalah melihat beberapa parameter kinerja model modifikasi sehingga didapatkan tingkat performansi sistem seperti PSNR dan SSIM.

D. Analisis Sistem

Setelah mendapatkan model modifikasi maka selanjutnya adalah analisis sistem dengan cara membandingkan tingkat kinerja *activator* ReLU, pengaruh *optimizer* terhadap sistem dan juga membandingkan dua dataset yang akan diuji pada empat model yang telah dimodifikasi. Pengujian model dimodifikasi ini meliputi beberapa pengujian yaitu sebagai berikut:

1. Menganalisis *optimizer* terhadap model asli SRCNN dan VDSR untuk mencari *optimizer* terbaik yang layak digunakan untuk kedua model modifikasi. Pengujian ini akan memilih dari dua *optimizer* yang sering digunakan diantaranya *optimizer* adam, dan SGD. Dari kedua *optimizer* tersebut akan dipilih satu *optimizer* terbaik yang nantinya akan dipakai untuk dilihat nilai parameter PSNR.
2. Menganalisis *dataset* terhadap kedua model modifikasi untuk melihat performansi modengan variasi iterasi (*epoch*) 50 pada setiap yang telah diuji pengujian ini melibatkan dua macam *dataset* yang telah diuji ke dalam sistem model modifikasi yang meliputi beberapa *dataset* yaitu *set 5*, dan *set 14* untuk nantinya dilihat nilai parameter PSNR, dan SSIM.
3. Menganalisis *accuracy* dan *loss* terhadap kedua model modifikasi untuk melihat performansi berdasarkan variasi *epoch* berturut-turut sebesar 50, 100, dan 150 pada setiap *dataset*.
4. Menganalisis waktu komputasi sistem yang diuji terhadap kedua model modifikasi berdasarkan variasi *epoch* berturut-turut sebesar 50, 100, dan 150 pada setiap *dataset*.

D. Pengujian Optimizer Pada SRCNN dan VDSR

Pengujian dilakukan dengan menggunakan 190 data yang dibagi dengan persentase 80% untuk data latih dan 20% untuk data tes sehingga masing – masing mendapatkan 152 data untuk dilatih dan 38 untuk dites. *Scenario* pada pengujian ini adalah dengan melakukan pergantian *optimizer* pada model SRCNN dan VDSR yang akan diproses dengan *epoch* 50 dan *patience* 5, diujikan pada tiga *optimizer* ini kemudian dilihat perbandingan nya berdasarkan nilai MSE dan PSNR.




Figure 9 Pengujian *optimizer* Adam, SGD, RMSprop parameter PSNR pada metode SRCNN dan VDSR

Nilai terbaik untuk parameter PSNR dari 3 *optimizer* diatas dimiliki oleh metode VDSR *optimizer* Adam dengan nilai PSNR 30,192 dB




Figure 10 Pengujian *optimizer* Adam, SGD, RMSprop parameter MSE pada metode SRCNN dan VDSR

Nilai terbaik untuk parameter MSE dari 3 *optimizer* diatas dimiliki oleh metode SRCNN *optimizer* Adam, SGD, dan RMSprop dengan nilai 0,001, dan metode VDSR dengan *optimizer* SGD dengan nilai 0,001.

E. Pengujian Variasi Dataset pada Modifikasi SRCNN dan VDSR

Pengujian dilakukan dengan menggunakan dataset Set14 dengan keseluruhan data yaitu 950 gambar, yaitu gambar 760 untuk data *training* dan 95 gambar untuk *validation test*. Pengujian menggunakan sebanyak 950 gambar yang dibagi persentase 80% untuk data latih dan 20% untuk data tes. *Scenario* pada pengujian ini akan akan memakai *optimizer* adam dan *activator full* relu yang telah diuji performansi pada pengujian sebelumnya, pada pengujian ini diuji pada tingkat pengulangan *epoch* 50 pengujian ini akan dilakukan pada kedua model yaitu SRCNN dan VDSR. Parameter yang akan ditinjau dari pengujian kali ini yaitu MSE, PSNR, dan SSIM selanjutnya akan dilakukan perbandingan parameter tersebut terhadap model tersebut pada *dataset* Set5.

Pengujian dilakukan dengan *scenario* SRCNN dan VDSR yaitu dengan melatih *dataset* dengan *epoch* 50 dan melakukan *testing* sehingga dapat diambil hasil dari nilai parameter yang ditinjau yaitu MSE, PSNR, dan SSIM.

SRCNN	Set14						
	Layer	96.bmp	97.bmp	98.bmp	99.bmp	100.bmp	101.bmp
MSE	3	0,001	0,006	0,001	0,001	0,001	0,004
PSNR	3	25,51	29,85	27,65	26,27	27,22	31,97
SSIM	3	0,874	0,925	0,922	0,903	0,873	0,951
VDSR	Set14						
	Layer	96.bmp	97.bmp	98.bmp	99.bmp	100.bmp	101.bmp
MSE	19	0,002	0,005	0,002	0,007	0,003	0,001
PSNR	19	32,41	28,54	35,15	29,48	33,55	34,75
SSIM	19	0,985	0,912	0,993	0,971	0,979	0,983

Figure 11 Pengujian Dataset

Dapat dilihat dari table 4.2 dari hasil pengujian didapatkan pada training dengan dataset Set14 terdapat 950 gambar training yang dibagi menjadi 760 untuk training dan 95 untuk validation test. Proses pengujian dataset menggunakan Set14 mendapatkan hasil yang baik jika ditinjau dari model SRCNN, dan dapat dilihat dari nilai rata-rata PSNR model VDSR dapat mengungguli SRCNN saat testing menggunakan citra 98.bmp dan 101.bmp dengan nilai PSNR berturut – turut sebesar 35,15 dB dan 34,75 dB, meskipun tidak mengungguli SRCNN.

F. Perbandingan Citra Hasil Simulasi Testing Dataset

Perbandingan hasil simulasi akan dibandingkan dari model SRCNN dan VDSR dengan menggunakan parameter yang sama yaitu menggunakan *optimizer* adam, menggunakan *activator* relu dengan variasi epoch 50 dan menggunakan enam *dataset* yang berbeda dimana *dataset* masing-masing menyimpan gambar dalam jumlah dan format yang berbeda – beda. Parameter tersebut nantinya akan diuji pada modifikasi untuk melihat hasil perbaikan citra yang telah melalui tahap *training* dan *testing* menggunakan *dataset* Set14.

1. 96.bmp




Figure 12 Perbandingan 96.bmp

Dapat dilihat gambar pengujian gambar pada kedua scenario masih terlihat noise pada bagian yang disorot, namun jika dilihat dengan jelas VDSR lebih baik dengan nilai MSE 0,002 dan PSNR 32,41 dB walaupun tipis perbedaan dengan SRCNN dengan nilai MSE 0,001 dan PSNR 25,51 dB.

2. 97.bmp



Figure 13 Perbandingan 97.bmp

Dapat dilihat gambar pengujian gambar pada kedua scenario masih terlihat *noise* pada bagian yang disorot, namun jika dilihat dengan jelas VDSR lebih baik dengan nilai MSE 0,005 dan PSNR 28,54 dB walaupun tipis perbedaan dengan SRCNN dengan nilai MSE 0,006 dan PSNR 29,85 dB.

3. 98.bmp



Figure 14 Perbandingan 98.bmp

Dapat dilihat gambar pengujian gambar pada kedua scenario masih terlihat *noise* pada bagian yang disorot, namun jika dilihat dengan jelas VDSR lebih baik dengan nilai MSE 0,002 dan PSNR 35,15 dB walaupun tipis perbedaan dengan SRCNN dengan nilai MSE 0,001 dan PSNR 27,65 dB.

4. 99.bmp



Figure 15 Perbandingan 99.bmp

Dapat dilihat gambar pengujian gambar pada kedua scenario masih terlihat *noise* pada bagian yang disorot, namun jika dilihat dengan jelas SRCNN lebih baik dengan nilai MSE 0,001 dan PSNR 26,27 dB walaupun tipis perbedaan dengan VDSR dengan nilai MSE 0,007 dan PSNR 29,48 dB.

5. 100.bmp




Figure 16 Perbandingan 100.bmp

Dapat dilihat gambar pengujian gambar pada kedua scenario masih terlihat *noise* pada bagian yang disorot, namn jika dilihat dengan jelas VDSR lebih baik dengan nilai MSE 0,003 dan PSNR 33,55 dB walupun tipis perbedaan dengan SRCNN dengan nilai MSE 0,001 dan PSNR 27,22 dB.

6. 101.bmp



Figure 17 Perbandingan 101.bmp

Dapat dilihat gambar pengujian gambar pada kedua scenario masih terlihat *noise* pada bagian yang disorot, namn jika dilihat dengan jelas VDSR lebih baik dengan nilai MSE 0,001 dan PSNR 34,75 dB walupun tipis perbedaan dengan SRCNN dengan nilai MSE 0,004 dan PSNR 31,97 dB.

G. Pengujian Loss

Pengujian *loss* pada tugas akhir kali ini menggunakan *library mean squared error* untuk mendapatkan nilai *loss* pada setiap model yang telah dilakukan pengujian, berikut merupakan nilai *loss* pada setiap model:

SRCNN	Loss	
	Set5	Set14
EPOCH 50	0,007	0,018
EPOCH 100	0,012	0,016
EPOCH 150	0,012	0,005
VDSR	Loss	
	Set5	Set14
EPOCH 50	0,047	0,055
EPOCH 100	0,031	0,017
EPOCH 150	0,016	0,005

Figure 18 Paraneter Loss

Pada gambar dapat dilihat pengujian *loss* yang telah diuji pada setiap metode dengan kelipatan *epoch* 50 dan dengan menggunakan dua *dataset* yang berbeda didapatkan hasil nilai *loss* terendah pada SRCNN *epoch* 150 dengan mendapatkan hasil 0,005 sedangkan untuk nilai *loss* tertinggi didapatkan oleh VDSR *epoch* 50 sebesar 0,055, pengaruh *loss* pada setiap metode menentukan nilai parameter MSE dan PSNR semakin kecil nilai *loss*-nya makanya nilai semakin baik.

H. Pengujian Waktu Komputasi

Pada pengujian akan dilihat seberapa lama sistem memproses dataset dengan variasi *epoch* yang berbeda – beda, sistem akan diuji menggunakan dataset sekunder hasil argumentasi pada variasi *epoch* 50, 100, dan 150 yang ditinjau dengan satu detik. Pengujian juga melihat pengaruh kedalaman layer.

SRCNN	Waktu komputasi (detik)		
	Layer	Set5	Set14
EPOCH 50	3	113,25	152,481
EPOCH 100	3	141,7	176,271
EPOCH 150	3	173,213	188,912
VDSR	Waktu komputasi (detik)		
	Layer	Set5	Set14
EPOCH 50	19	201,3	223,4
EPOCH 100	19	212,6	212,8
EPOCH 150	19	271,781	26,7

Figure 19 Waktu Komputasi Sistem

Dapat dilihat dari gambar pengaruh kedalaman *layer* dan *dataset* yang dipakai sangat mempengaruhi waktu komputasi semakin banyak *layer* yang dipakai oleh model modifikasi berpengaruh pada melambatnya proses komputansi, sedangkan jika ditinjau dari *dataset* yang dipakai waktu komputansi sistem tidak terlalu beda jauh. Selanjutnya variasi *epoch* sangat berpengaruh pada waktu komputansi semakin variasinya besar proses komputansi yang dihasilkan juga semakin lama.

V. KESIMPULAN

Dari hasil analisis, dan hasil pengujian pada penelitian ini maka dapat diambil kesimpulan sebagai berikut:

1. SRCNN dan VDSR menunjukkan peningkatan detail citra secara signifikan, untuk evaluasi kinerja kedua metode menunjukkan mampu meningkatkan resolusi citra renda dengan baik.
2. Berdasarkan hasil dari pengujian *optimizer* dengan nilai terbaik yang dapat dimiliki oleh metode VDSR *optimizer* Adam dengan nilai PSNR 30,192, dan untuk nilai MSE *optimizer* Adam, SGD, dan RMSprop

- dengan metode SRCNN dengan nilai 0,001.
3. Berdasarkan hasil penelitian ini memfokuskan pada evaluasi performa kedua metode dengan memperhatikan nilai MSE, PSNR, dan SSIM. Hasil penelitian menunjukkan bahwa kedua metode memiliki pengaruh yang signifikan terhadap peningkatan kualitas citra, namun VDSR menunjukkan performa yang lebih unggul dibandingkan SRCNN dalam hal nilai MSE, PSNR, dan SSIM.
 4. Untuk pengujian *loss* terendah pada SRCNN *epoch* 150 dengan mendapatkan hasil 0,008 sedangkan untuk nilai *loss* tertinggi didapatkan oleh VDSR *epoch* 50 sebesar 0,059. Dapat disimpulkan bahwa VDSR merupakan metode yang lebih baik dalam meningkatkan kualitas citra Super-resolution dibandingkan dengan.
 6. Peningkatan performansi sistem berdampak pada melambatnya komputasi untuk merekonstruksi citra menjadi lebih baik.

REFERENSI

- [1] D. M. R. A. Aris Budianto, "Perbandingan K-Nearest Neighbor (KNN) Dan Support Vector Machine (SVM) Dalam Pengenalan Karakter Plat Kendaraan Bermotor," *Vol 11, No 1 2018*, p. 9, 2018.
- [2] N. H. F. Wawan Setiawan, "Deteksi Objek Plat Nomor Kendaraan Dengan Metode CNN," *Vols. Vol 16, No 1, Juni 2022, 2022*.
- [3] J. W. X. C. YUANTAO CHEN, "Single-Image Super-Resolution Algorithm Based on Structural Self-Similarity and Deformation Block Features," p. 12, 2019.
- [4] H. M. Yan Lv, "Improved SRCNN For Super Resolution Reconstruction," 26 April 2021.
- [5] N. M. Tresna, "Implementasi Metode Generative Adversarial Network Dengan Model Mobilenet," 2020.
- [6] G. D. C. J. J. S. D. Vint, "Evaluation Of Performance Of VDSR Super," p. 5, 2019.
- [7] H. F. Yuda Puspito, "Deteksi Posisi Plat Nomor Kendaraan Menggunakan Metode Transformasi Hough Dan Hit Or Miss," 2018.
- [8] O. D. N. K. T. M. Lazuardi Arsy, "Aplikasi Pengolahan Citra Digital Meat Detection Dengan Metode Segmentasi K-Mean Clustering Berbasis OpenCV Dan Eclipse," *Vol.4, No.2, April 2016*, p. 10, 2016.
- [9] M. R. A. ROMADHONI, "Klasifikasi Mata Glaukoma Dan Mata Normal Menggunakan Metode Support Vector Machine," 2020.
- [10] W. Z. H. G. Yingyi Sun, "Convolutional Neural Network Based Models for Improving," 2019 .
- [11] S. K. T. K. Jin Yamanaka, "Fast and Accurate Image Super Resolution by Deep CNN with Skip Connection and Network in Network," *8 Jul 2017 (v1)*, 2020.
- [12] B. C. C. Y. Hyeongyeom Ahn, "Super-Resolution Convolutional Neural Networks Using Modified and Bilateral ReLU," 2019.
- [13] H. S. J. L. Linwei Yue, "Image Super-Resolution: The Techniques, Applications, And Future," 2016.
- [14] Y. K. J. B. Mengmeng Chen, "Monitoring Early Stage Invasion Of Exotic Spartina Alterniflora Using Deep-Learning Super-Resolution Techniques Based On Multisource High-Resolution Satellite Imagery: A Case Study In The Yellow River Delta, China," 2020.
- [15] T. Nurhikmat, "Implementasi Deep Learning Untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (CNN) Pada Citra Wayang Golek," 2018.
- [16] A. A. Hania, "Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning," 2017.
- [17] C. M. T. Z. Yujie Li, "Underwater Image High Definition Display Using The Multilayer Perceptron And Color," 2019.
- [18] I. W. S. E. Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) Pada Caltech 101," 2016.
- [19] P. W. C. Z. Haopeng Zhang, "A Comparable Study of CNN-Based Single Image Super-Resolution for Space-Based Imaging Sensors," 2019.
- [20] T. Tong, G. Li, X. Liu and G. Qinquan, "Image Super-Resolution Using Dense Skip Connections," *Vols. vol. 2017-October*, pp.4809-4817, 2017.
- [21] D. N. Karyana, U. N. Wisesty and Jondri, "Klasifikasi Emosi Berdasarkan Sinyal EEG Menggunakan Deep Neural Network, *Vols. Vol.3, No.3 December 2016 | Page 5296*, 2016.