

Super Resolution* pada Citra Udara menggunakan *Convolutional Neural Network

MUHAMMAD EFAN ABDULFATTAH, LEDYA NOVAMIZANTI, SYAMSUL RIZAL

Fakultas Teknik Elektro, Telkom University, Indonesia
Email: muhammadefan@student.telkomuniversity.ac.id

Received 28 Juni 2020 | *Revised* 16 Juli 2020 | *Accepted* 24 Juli 2020

ABSTRAK

Bencana di Indonesia didominasi oleh bencana hidrometeorologi yang mengakibatkan kerusakan dalam skala besar. Melalui pemetaan, penanganan yang menyeluruh dapat dilakukan guna membantu analisa dan penindakan selanjutnya. Unmanned Aerial Vehicle (UAV) dapat digunakan sebagai alat bantu pemetaan dari udara. Namun, karena faktor kamera maupun perangkat pengolah citra yang tidak memenuhi spesifikasi, hasilnya menjadi kurang informatif. Penelitian ini mengusulkan Super Resolution pada citra udara berbasis Convolutional Neural Network (CNN) dengan model DCSCN. Model terdiri atas Feature Extraction Network untuk mengekstraksi ciri citra, dan Reconstruction Network untuk merekonstruksi citra. Performa DCSCN dibandingkan dengan Super Resolution CNN (SRCNN). Eksperimen dilakukan pada dataset Set5 dengan nilai scale factor 2, 3 dan 4. Secara berurutan SRCNN menghasilkan nilai PSNR dan SSIM sebesar 36.66 dB / 0.9542, 32.75 dB / 0.9090 dan 30.49 dB / 0.8628. Performa DCSCN meningkat menjadi 37.614dB / 0.9588, 33.86 dB / 0.9225 dan 31.48 dB / 0.8851.

Kata kunci: citra udara, deep learning, super resolution

ABSTRACT

Disasters in Indonesia are dominated by hydrometeorological disasters, which cause large-scale damage. Through mapping, comprehensive handling can be done to help the analysis and subsequent action. Unmanned Aerial Vehicle (UAV) can be used as an aerial mapping tool. However, due to the camera and image processing devices that do not meet specifications, the results are less informative. This research proposes Super Resolution on aerial imagery based on Convolutional Neural Network (CNN) with the DCSCN model. The model consists of Feature Extraction Network for extracting image features and Reconstruction Network for reconstructing images. DCSCN's performance is compared to CNN Super Resolution (SRCNN). Experiments were carried out on the Set5 dataset with scale factor values 2, 3, and 4. The SRCNN sequentially produced PSNR and SSIM values of 36.66dB / 0.9542, 32.75dB / 0.9090 and 30.49dB / 0.8628. DCSCN's performance increased to 37,614dB / 0.9588, 33.86dB / 0.9225 and 31.48dB / 0.8851.

Keywords: aerial imagery, deep learning, super resolution

1. PENDAHULUAN

Secara geografis, Negara Kesatuan Republik Indonesia termasuk dalam kategori iklim tropis dengan perubahan cuaca yang terjadi di setiap tahunnya. Kondisi tersebut menjadikan Indonesia rentan terhadap ancaman bencana hidrometeorologi, seperti: angin puting beliung, kebakaran hutan, banjir, dan tanah longsor. Badan Nasional Penanggulangan Bencana (BNPB) menyatakan bahwa pada tahun 2019, bencana hidrometeorologi masih mendominasi dengan prediksi sebesar 95% dari total bencana yang disebabkan oleh kerusakan pada Daerah Aliran Sungai (DAS) **(Welle, 2019)**. Untuk mengefektifkan proses identifikasi, diperlukan pemetaan terhadap area yang terkena dampak bencana. Salah satu cara yang dapat dilakukan dengan bantuan *Unmanned Aerial Vehicle* (UAV) atau pesawat tanpa awak. UAV mampu terbang dengan kendali *remote control* maupun terbang secara *autonomous* **(Shahmoradi, 2020)**. Namun, pada suatu kondisi terdapat kemungkinan adanya permasalahan pada hasil pemetaan atau fotogrametri. Hal ini karena keterbatasan spesifikasi kamera maupun perangkat pengolahan citra yang digunakan. Akibatnya, informasi yang dapat dipahami oleh manusia secara visual menjadi kurang detail. Oleh karena itu, diusulkanlah metode *Super Resolution* untuk memperjelas tampilan citra **(Dong, dkk, 2015)(Tong, dkk, 2017)**.

Sistem *Super Resolution* yang dibuat mampu merekonstruksi ukuran citra menjadi lebih besar. Sehingga, mata manusia dapat mencerna detail informasi pada citra tersebut dengan lebih baik. Model yang digunakan adalah *Deep CNN with Skip Connection and Network In Network* (DCSCN), yang terdiri atas *Feature Extraction Network* dengan fitur *Skip Connection* pada *hidden layer* untuk mengekstraksi ciri *local* dan ciri *global* dari citra masukan. *Reconstruction Network* dengan fitur *Network In Network* (NIN) atau parallel CNN **(Lin, dkk, 2014)** berfungsi untuk merekonstruksi citra berdasarkan pada ciri yang didapatkan dari *Feature Extraction Network*. *Skip connection* digunakan pada awal model untuk memuat hasil *pre-processing* menggunakan interpolasi *bicubic* **(Fadnavis, 2014)** berdasarkan pada nilai *scale factor* tertentu. Hasil *pre-processing* tersebut nantinya digabungkan dengan hasil dari *Reconstruction Network*, sehingga diperoleh citra rekonstruksi **(Yamanaka, dkk, 2017)**. Chao Dong, et al mengusulkan model *Super Resolution CNN* (SRCNN). Model tersebut terdiri atas struktur *Patch Extraction and Representation, Non-Linear Mapping* dan *Reconstruction* **(Dong, dkk, 2015)**. Dalam naskah ini, kami mengusulkan *Super Resolution* yang diterapkan pada citra udara menggunakan model DCSCN yang di latih menggunakan dataset BSD200 dan 100 citra udara milik penulis, sehingga total *dataset* latih berisi 300 citra. *Dataset* baru tersebut dinamakan dengan Aero_bsd300 yang pada tahapan prosesnya diaugmentasi hingga delapan kali.

2. METODOLOGI

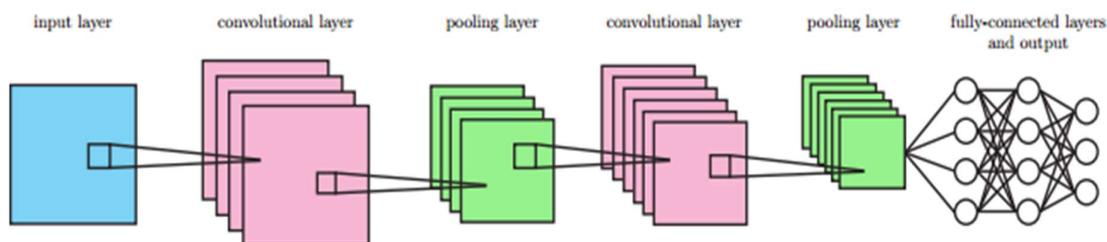
2.1 Super Resolution

Super Resolution merupakan contoh dari penerapan pengolahan citra digital yang ditujukan untuk merekonstruksi citra dengan resolusi rendah dan detail minim menjadi citra resolusi tinggi dengan detail yang lebih kentara. Ukuran citra hasil rekonstruksi bergantung pada nilai *scale factor* yang digunakan. Melalui *Super Resolution*, diharapkan informasi yang terdapat pada citra dapat dikenali secara lebih baik oleh mata manusia **(Dong, dkk, 2015) (Tong, dkk, 2017) (Yamanaka, dkk, 2017) (Ahn, dkk, 2019) (Sun, dkk, 2019)**.

2.2 Convolutional Neural Network

CNN termasuk dalam algoritma *Deep Learning* yang bekerja secara *feed-forward*. Pada umumnya, CNN diaplikasikan untuk bidang *Computer Vision*, misalnya: deteksi objek, klasifikasi objek dan lain-lain **(Suyanto, 2018)(Heaton, 2015)**. CNN memiliki beberapa

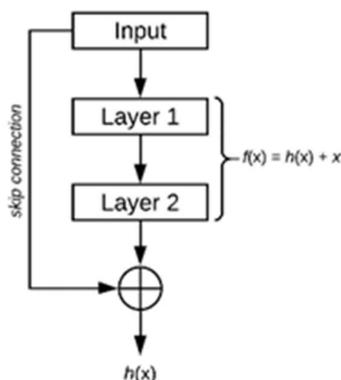
macam *layer*, yaitu: *input layer*, *output layer*, serta *hidden layer* yang terdiri dari *convolutional layer*, *pooling layer* dan *fully-connected layer*. Setiap *layer* tersebut terdiri atas *array* tiga dimensi, yaitu: lebar, tinggi, dan kedalaman. Lebar dan tinggi merupakan ukuran matriks, sedangkan kedalaman mengacu pada jumlah kanal warna citra atau dalam bagian yang lain dapat mewakili jumlah *filter*. Jumlah *hidden layer* pada CNN bergantung pada arsitektur yang digunakan. Contoh arsitektur yang marak digunakan adalah VGGNet (Simonyan, dkk, 2015), GoogleNet dan ResNet (Sewak, dkk, 2018). Gambar 1 merupakan lapisan-lapisan yang terdapat pada CNN (Stenroos, 2017).



Gambar 1. Lapisan-lapisan pada CNN

2.3 Residual Block

Residual Block merupakan suatu kumpulan fungsi yang didalamnya terdapat fitur *Skip Connection* pada arsitektur *Residual Network* (ResNet). Adanya fitur tersebut, ResNet telah membuktikan efektivitasnya setelah menjadi juara pada kompetisi ILSVRC 2015. *Skip connection* dianggap mampu mengatasi permasalahan galat pelatihan dan evaluasi yang tinggi karena *underfitting* yang disebabkan oleh *vanishing gradient* pada model dengan lapisan yang sangat dalam (Géron, dkk, 2017) (Tong, dkk, 2017) (Sewak, dkk, 2018). Gambar 2 merupakan contoh representasi dari *residual block* (Géron, 2017).



Gambar 2. Contoh *Residual Block*

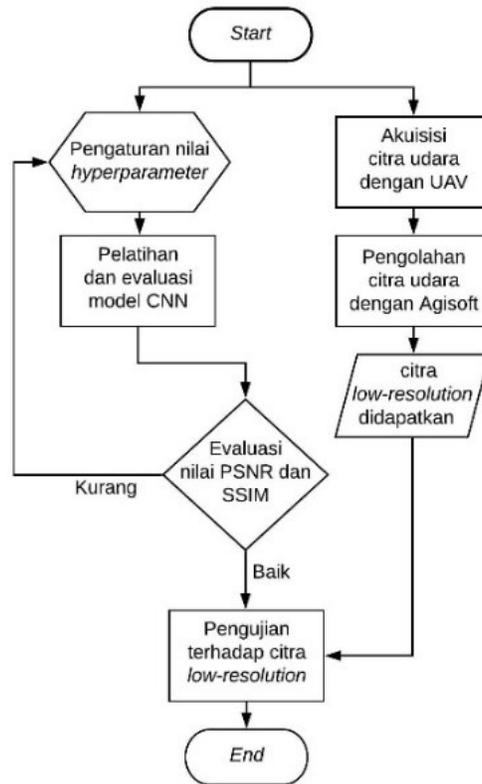
2.4 Network In Network

Network in Network (NIN) merupakan suatu struktur jaringan dalam CNN yang dapat digunakan untuk meningkatkan non-linearitas pada citra yang hendak diekstraksi cirinya. NIN bekerja seperti lapisan konvolusional yang setelahnya diaplikasikan fungsi aktivasi ReLU untuk mendapatkan nilai *weight* yang non-linear. Dalam struktur NIN terdapat *kernel*/konvolusi 1×1 yang disusun sebanyak beberapa bagian (Lin, dkk, 2014).

2.5 Rancangan Sistem

Bagian ini memaparkan sistematika untuk mendapatkan citra rekonstruksi dengan resolusi tinggi dari citra resolusi rendah yang diambil dari udara. Tahapannya diawali dengan membuat *dataset* latih dan *dataset* evaluasi. Lalu, tahap *pre-processing* yang dibarengi dengan tahap

pelatihan model yang telah dirancang. Kemudian dilakukan tahap evaluasi model hasil pelatihan dengan beberapa sampel citra dari *dataset* evaluasi. Setelah didapatkan model yang sesuai dengan skenario, model dapat diujikan. Pengujian dilakukan pada citra resolusi rendah untuk merekonstruksi citra tersebut menjadi citra dengan ukuran tertentu sesuai dengan nilai *scale factor* yang digunakan. Gambar 3 merupakan representasi dari skenario pelatihan.



Gambar 3. Skenario Penelitian

2.6 Pengumpulan *Dataset*

Pada penelitian ini, sampel citra dibagi menjadi dua jenis *dataset*, yaitu: *dataset* latih dan *dataset* evaluasi. *Dataset* latih berisi 100 sampel citra udara milik penulis yang diambil melalui UAV, dan 200 sampel citra dari *dataset* BSD200 yang dapat diakses pada laman <https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds>. Total terdapat 300 sampel citra pada *dataset* latih yang dinamakan Aero_bsd300. Sedangkan, pada *dataset* evaluasi terdiri dari 10 sampel citra udara milik penulis, dinamakan *dataset* Aero10. Selain itu, penelitian ini juga memanfaatkan *dataset* Set5 yang berisi 5 sampel citra yang dapat diakses pada laman <https://www.kaggle.com/ll01dm/set-5-14-super-resolution-dataset>. *Dataset* Set5 ini digunakan sebagai bahan evaluasi antara model yang diusulkan dengan metode rekonstruksi citra lainnya.

2.7 Akuisisi Citra

Akuisisi citra udara dilakukan menggunakan kamera yang dipasang pada bagian bawah badan UAV, dengan posisi lensa menghadap tepat ke bawah. Tahapan yang harus dilakukan, yaitu:

1. Tahap Perencanaan Misi Pemetaan

Diawali dengan mengatur *waypoint* menggunakan aplikasi Mission Planner (MP) sebagai pemandu arah terbang UAV. Pengaturan *waypoint* dilakukan dengan masuk ke menu *Flight*

Plan, lalu *altitude* diatur pada angka 150m dan luas cakupan diatur dengan menempatkan titik *waypoint* pada peta yang ditampilkan oleh aplikasi MP. *Flight plan* yang berisi *waypoint* telah diatur sedemikian rupa untuk pelaksanaan misi pemetaan di daerah Lapangan TNI Grati-Pasuruan yang direpresentasikan oleh Gambar 4.

2. Tahap *Geo Tagging* Citra Udara

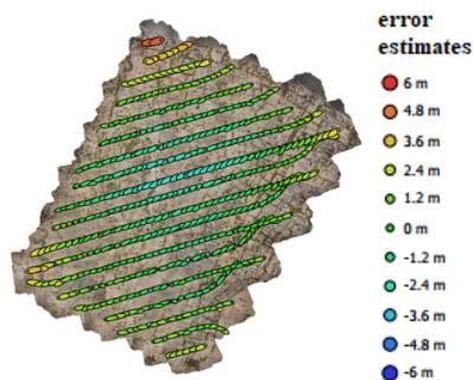
Geo Tagging merupakan tahap menyatukan potongan citra udara dengan titik koordinat ketika citra udara tersebut diambil. Titik koordinat didapatkan dari modul *Global Positioning System* (GPS) yang terintegrasi dengan *Flight Controller* (FC). Untuk mengunduh *data log* titik koordinat dilakukan dengan menghubungkan antara FC dengan laptop. Kemudian, aplikasi MP dibuka dan *data log* dapat diunduh dari opsi yang tersedia pada tampilan menu utama yang bernama *DataFlash Log*. Selanjutnya, pilih opsi *Download DataFlash Log Via Mavlink*, sehingga *file* akan tersimpan pada folder *Document* di laptop. Setelah *data log* didapatkan, maka titik koordinat yang ada di dalamnya digabungkan dengan potongan citra udara dengan cara masuk ke menu *temp* yang dapat diakses menggunakan *hotkey* ctrl+f. Masuk ke menu *Geo ref images*, untuk memasukan *data log* yang telah diunduh pilih *Browse Log*. Opsi *Browse Pictures* untuk memasukan potongan citra udara. Selanjutnya pilih opsi *Pre-process*, dan pilih opsi *GeoTag Images*. Pada tahap ini, potongan citra udara telah disatukan dengan titik koordinat dan disimpan di dalam folder baru yang bernama "*geotagged*". Gambar 5 menunjukkan titik koordinat nyata dalam pengambilan citra udara. Data berupa estimasi galat dalam satuan jarak (m) terhadap titik koordinat pengambilan citra yang diatur melalui *waypoint* di MP.

3. Tahap Pengolahan Citra Udara

Pengolahan menggunakan aplikasi Agisoft Metashape pada semua potongan citra udara yang telah ditanami titik koordinat. Semua citra dipanggil dengan memilih opsi *Add Photos* pada tampilan *Workspace*. Kemudian, menuju *toolbar Workflow* untuk menyatukan potongan citra udara dengan memilih opsi *Align Photos*. Hasil dari pemrosesan kemudian di-*export* dalam format jpg (*.jpg). Citra udara ini digunakan sebagai bahan pengujian pada sistem *Super Resolution* yang sebelumnya dikonversi terlebih dahulu ke format bmp (*.bmp).



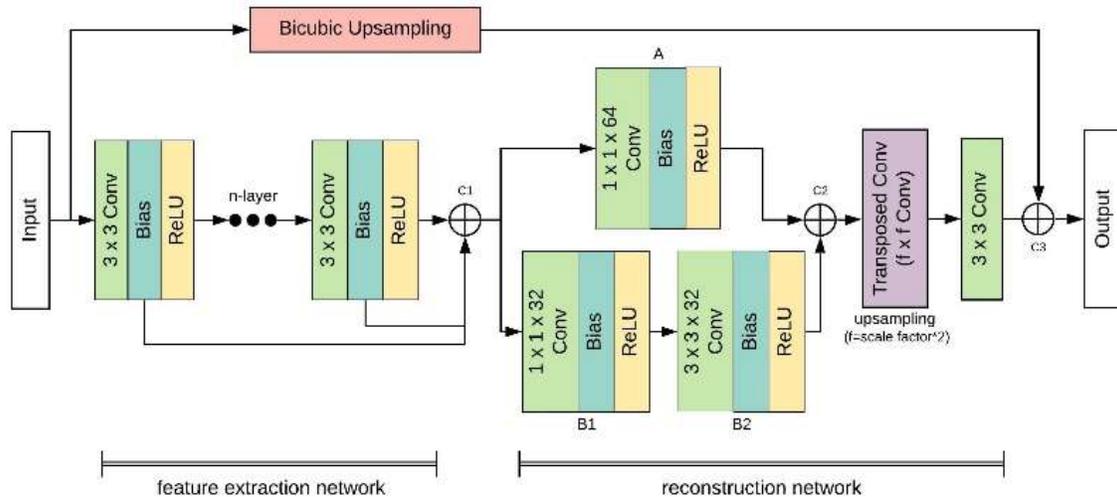
Gambar 4. Waypoint Misi Pemetaan



Gambar 5. Titik Koordinat Pengambilan Citra

2.9 *Super Resolution*

Sistematika untuk mendapatkan citra rekonstruksi dengan model DCSCN direpresentasikan oleh Gambar 6. Secara keseluruhan, sistematika yang dijalankan untuk mendapatkan citra rekonstruksi dengan resolusi tinggi dibagi menjadi dua tahap, yaitu: tahap pelatihan dan evaluasi, serta tahap pengujian.



Gambar 6. Blok Desain Sistem

2.9.1 Tahap Pelatihan dan Evaluasi

Sistem *Super Resolution* yang dibuat dilatih dan dievaluasi menggunakan *dataset* yang berisi sampel citra *Red-Green-Blue* (RGB) dengan format *.bmp. Arsitektur yang dirancang, terdiri dari: *feature extraction network* dan *reconstruction network*. Proses yang terjadi pada masing-masing jaringan, yaitu:

1. Feature Extraction Network

Tahap pertama, yaitu *pre-processing* untuk mendapatkan citra resolusi rendah. Tahap ini dilakukan terhadap *dataset* evaluasi melalui proses *down-sampling* lalu *up-sampling* menggunakan interpolasi *bicubic* dengan nilai *scale factor* tertentu. Hasilnya dilampatkan ke titik *concatenate* ketiga, yang dinamakan dengan *skip connection*. Kemudian, sampel citra dari *dataset* latih mulai dimasukkan ke lapisan masukan sebelum ke lapisan tersembunyi. Di dalam lapisan tersembunyi, terdapat proses konvolusi antara citra masukan dengan sejumlah *filter* yang berukuran 3×3 , dan rentang nilainya telah diatur berdasarkan pada He *Initializer* (Patel, dkk, 2018). Hasil dari konvolusi kemudian diseleksi oleh fungsi aktivasi *Rectified Linear Unit* (ReLU) (Wibawa, 2016), lalu ditampung pada *weight kernel* baru. Pada proses selanjutnya, *weight kernel* tersebut ada yang dikonvolusikan lagi dengan *filter* berdasarkan pada He *initializer*, serta ada yang dilampatkan menuju titik *concatenation* pertama. Proses tersebut terjadi di setiap *layer* yang diterapkan pada arsitektur. Tujuan dari *weight kernel* baru yang diteruskan ke setiap lapisan tersembunyi adalah untuk mengekstraksi ciri *local* dari setiap citra masukan. Sedangkan *skip connection* yang ada di setiap *layer* berguna untuk mengirimkan hasil ekstraksi ciri *global* dari setiap sampel citra masukan, dan dikirim menuju titik *concatenation* pertama.

2. Reconstruction Network

Setelah *weight kernel* yang berisi data ciri didapatkan, tahap pelatihan dilanjutkan dengan *reconstruction network* untuk merekonstruksi citra. Pada jaringan ini, dilakukan proses konvolusi dan seleksi oleh ReLU, seperti halnya pada proses di *feature extraction network*. Namun, di bagian ini menggunakan konfigurasi seperti *Network in Network* (NiN). Sehingga, terdapat dua cabang, yaitu: cabang A berisi satu proses konvolusi dengan 64 *filter* berukuran 1×1 lalu seleksi oleh ReLU, dan cabang B berisi dua proses konvolusi lalu seleksi oleh ReLU. Proses B1 menggunakan 32 *filter* berukuran 1×1 , dan proses B2 menggunakan 32 *filter* berukuran 3×3 . Hasil dari setiap cabang tersebut kemudian mengalir ke titik *concatenation* kedua untuk digabungkan. Setelahnya, nilai *weight kernel* yang terbaru diarahkan menuju titik

concatenation ketiga untuk ditambahkan dengan citra hasil interpolasi *bicubic*, sehingga diperoleh citra hasil rekonstruksi. Seluruh proses tersebut dilakukan secara iteratif sebanyak jumlah *epoch*, dan keluaran yang didapatkan dari tahap pertama ini adalah nilai parameter PSNR dan SSIM yang dijadikan sebagai bahan untuk mengevaluasi model yang telah dilatih. Nilai *learning rate* yang ditetapkan berpengaruh pada nilai *weight kernel*. Dengan diterapkannya *decay* pada *learning rate*, maka model yang dirancang mampu mencapai titik konvergensi dengan lebih cepat dan simpangan saat osilasi terjadi menjadi lebih pendek.

2.9.2 Tahap Pengujian

Tahapan pengujian dilakukan setelah tahap evaluasi model pada masing-masing *scale factor* selesai dilakukan. Nilai *weight* yang telah didapatkan dari tahap pelatihan digunakan untuk tahap pengujian. Keluaran dari tahap ini adalah hasil rekonstruksi citra udara untuk dievaluasi secara visual. Fotogrametri yang digunakan sebagai bahan pengujian di cuplik dengan ukuran tertentu dan dinamakan dengan *image_20*.

2.10 Performa Sistem

2.10.1 Peak Signal-to-Noise Ratio

Peak Signal-to-Noise Ratio (PSNR) merupakan nilai parameter dalam pengolahan citra yang menyatakan besarnya galat pada citra dengan satuan dB. *Mean Square Error* (MSE) merupakan nilai parameter yang menyatakan galat rata-rata hasil perbandingan antara citra asli dengan citra hasil rekonstruksi. Persamaan 1 dan 2 merupakan perhitungan untuk mendapatkan nilai PSNR dan *Mean Square Error* (MSE) (Nurfitri, dkk, 2016).

$$\text{PSNR} = 10 \log_{10} \frac{s^2}{\text{MSE}} \quad (1)$$

$$\text{MSE} = \frac{1}{N} \sum_{i=0}^N (y_i - \hat{y}_i)^2 \quad (2)$$

dengan s adalah nilai intensitas maksimum dari ukuran bit citra yang diolah. Pada tulisan ini, citra menggunakan layer RGB, sehingga nilai s adalah 255. N merupakan ukuran resolusi citra, y adalah nilai intensitas pada tiap piksel citra asli, serta \hat{y} merupakan nilai intensitas pada citra hasil rekonstruksi (Budiman, dkk, 2015).

2.10.2 Structural Similarity Index Measurement

Structural Similarity Index Measurement (SSIM) merupakan nilai parameter yang menyatakan tingkat kemiripan antara citra asli dengan citra hasil rekonstruksi. Parameter ini digunakan pada tahap evaluasi model DCSCN untuk menentukan model dengan pengaturan mana yang mampu merekonstruksi citra dengan lebih baik. Rentang nilai SSIM dibatasi dari 0 hingga 1. Semakin besar nilai SSIM maka tingkat kemiripan semakin tinggi (Nurfitri, dkk, 2016).

3. HASIL DAN PEMBAHASAN

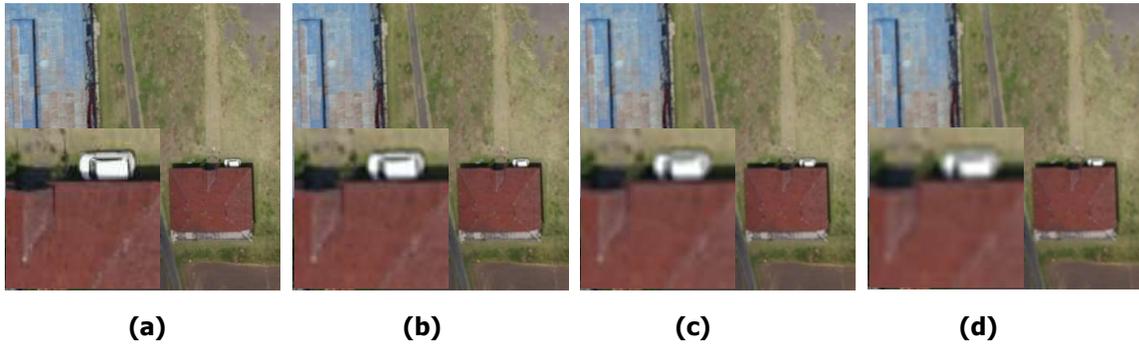
Bab ini memaparkan hasil penelitian yang diperoleh dari setiap skenario yang dijalankan, disertai dengan analisis evaluasi hasil yang diperoleh. Tahap evaluasi sistem *Super Resolution* dilakukan berdasarkan pada parameter PSNR dan SSIM. Tahap evaluasi dilakukan dalam beberapa tahap sesuai dengan skenario yang telah dibuat, guna menentukan pengaturan yang paling baik dalam efisiensi waktu komputasi, serta nilai parameter PSNR dan SSIM yang lebih tinggi. Setiap skenario yang dijalankan, dievaluasi berdasarkan pada nilai *scale factor*. Hal ini ditujukan agar mendapatkan citra hasil rekonstruksi yang terbaik pada masing-masing nilai *scale factor*. Nilai *scale factor* yang diujikan, yaitu: 2, 3, dan 4.

3.1 Tahap *Pre-Processing*

Pada tahap *pre-processing*, citra masukan akan direduksi ukurannya berdasarkan pada nilai *scale factor* tertentu, kemudian dikembalikan ke ukuran semula menggunakan interpolasi *bicubic* guna mendapatkan citra resolusi rendah. Tabel 1 merupakan hasil evaluasi dari tahap *pre-processing*. Citra *ground-truth* dan hasil dari tahap ini direpresentasikan oleh Gambar 7. Citra tersebut merupakan salah satu sampel dari *dataset* Aero10.

Tabel 1. Hasil Evaluasi Tahap *Pre-processing*

Citra	<i>Scale Factor</i>	PSNR	SSIM
image_20	2	36.460	0.9414
	3	33.401	0.8864
	4	31.893	0.8514



Gambar 7. Image_20 (a) *Ground-Truth*, (b) *Scale Factor* Dua (c) *Scale Factor* Tiga (d) *Scale Factor* Empat

3.2 Evaluasi Augmentasi *Dataset*

Pada skenario pertama, dilakukan evaluasi terhadap jumlah sampel citra pada masing-masing *dataset* latih, yaitu: *dataset* awal maupun *dataset* hasil augmentasi. Inisialisasi parameter *global* ditunjukkan pada Tabel 2.

Tabel 2. Parameter *Global* pada Skenario Pertama

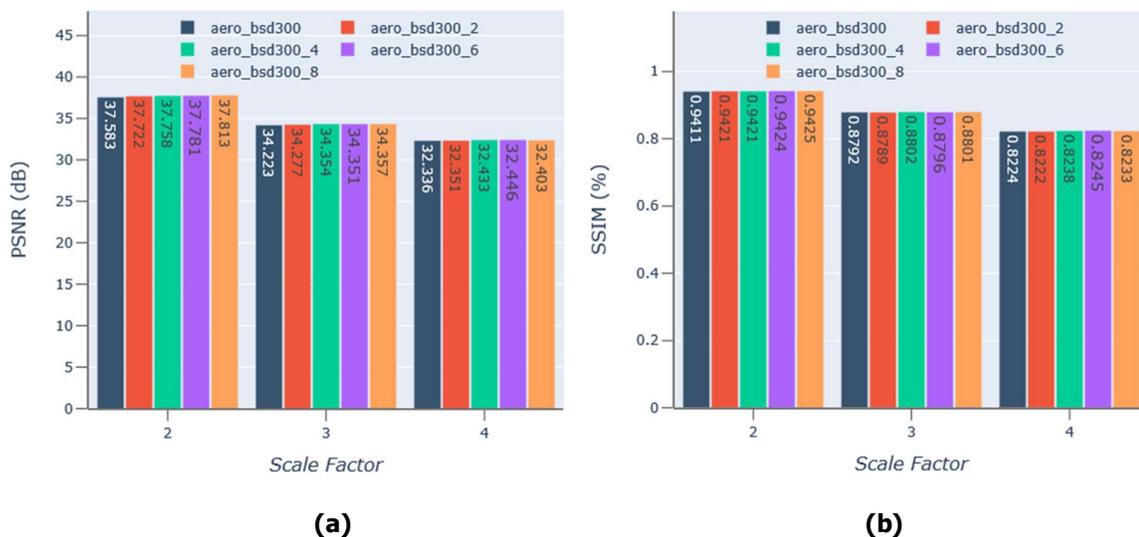
Parameter	Nilai
Jumlah <i>layer</i>	7
Jumlah <i>epoch</i>	150
Jumlah <i>filter</i> ekstraksi ciri awal	192
Jumlah <i>filter</i> ekstraksi ciri akhir	48
Peubah <i>decay filter</i> tiap <i>layer</i>	1.5
<i>Learning rate</i> awal	0.002
<i>Learning rate</i> akhir	0.0005
Peubah <i>decay learning rate</i> tiap 50 <i>epoch</i>	0.5

Rincian *dataset* yang dilakukan pada skenario pertama, yaitu:

1. *Dataset* Aero_bsd300 yang berisi 300 sampel citra.
2. *Dataset* Aero_bsd300_2 dengan augmentasi secara *horizontal*, maka didapatkan 600 sampel citra.
3. *Dataset* Aero_bsd300_4 dengan augmentasi secara *horizontal*, *vertical* dan *vertical-horizontal*, maka didapatkan 1200 sampel citra.

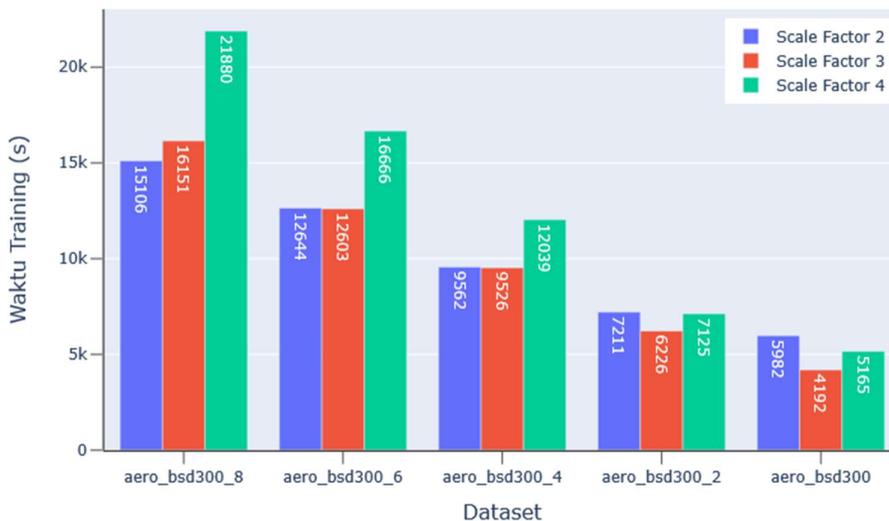
4. *Dataset* Aero_bsd300_6 dengan augmentasi secara *horizontal, vertical, vertical-horizontal, single clock-wise rotation* dan *double clock-wise rotation*, maka didapatkan 1800 sampel citra.
5. *Dataset* Aero_bsd300_8 dengan augmentasi secara *horizontal, vertical, vertical-horizontal, single clock-wise rotation, double clock-wise rotation, single clock-wise rotation-vertical* dan *double clock-wise rotation-vertical*, maka didapatkan 2400 sampel citra.

Data perbandingan berdasarkan *scale factor* disajikan pada Gambar 8.



Gambar 8. Hasil Evaluasi Nilai *Scale Factor* terhadap Performa (a) PSNR (b) SSIM

Berdasarkan Gambar 8, diperoleh bahwa *dataset* Aero_bsd300_6 dan Aero_bsd300_8 mendapatkan nilai tertinggi pada parameter PSNR dan SSIM, dengan selisih di antara keduanya tidak terlampaui jauh. Namun, terdapat perbedaan yang mencolok terhadap konsumsi waktu yang dibutuhkan pada tahap pelatihan, seperti yang ditunjukkan oleh Gambar 9. *Dataset* Aero_bsd300_6 dipilih untuk diterapkan pada skenario berikutnya, karena dinilai lebih efisien dalam waktu komputasi.



Gambar 9. Hasil Evaluasi Waktu *Training* terhadap *Dataset* Latih

3.3 Evaluasi Jumlah Layer

Pada skenario kedua, parameter yang dievaluasi merupakan jumlah *layer* pada *feature extraction network*. Pengujian dilakukan pada *dataset* Aero_bsd300_6 dan nilai *scale factor* 4. Tabel 4 merupakan inialisasi parameter *global* pada skenario kedua.

Tabel 4. Parameter Global pada Skenario Kedua

Parameter	Nilai
Jumlah <i>epoch</i>	90
Jumlah <i>filter</i> ekstraksi ciri awal	192
Jumlah <i>filter</i> ekstraksi ciri akhir	48
Peubah <i>decay filter</i> tiap <i>layer</i>	1.5
<i>Learning rate</i> awal	0.002
<i>Learning rate</i> akhir	0.0005
Peubah <i>decay learning rate</i> tiap 50 <i>epoch</i>	0.5

Tahap evaluasi dilakukan dengan lima macam jumlah *layer* yang berbeda. Oleh karena itu, terdapat perbedaan pada distribusi jumlah *filter* di setiap *layer*, yaitu:

1. Pada model dengan lima buah *layer*, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 192, 134, 101, 73 dan 48.
2. Pada model dengan enam buah *layer*, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 192, 142, 113, 89, 67 dan 48.
3. Pada model dengan tujuh buah *layer*, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 192, 148, 122, 101, 82, 64 dan 48.
4. Pada model dengan delapan buah *layer*, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 192, 152, 129, 110, 92, 76, 62 dan 48.
5. Pada model dengan sembilan buah *layer*, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 192, 156, 134, 117, 101, 86, 73, 60 dan 48.

Tabel 5. Pengaruh Jumlah Layer terhadap Performa

Jumlah Layer	PSNR (dB)	SSIM
5	32.372	0.8234
6	32.41	0.8238
7	32.42	0.8238
8	32.442	0.8244
9	32.461	0.8246

Tabel 5 merupakan hasil eksperimen dari tahap evaluasi pertama hingga kelima. Semakin banyak jumlah *layer*, maka nilai parameter PSNR dan SSIM menjadi relatif lebih tinggi. Hal ini dikarenakan semakin banyak fitur atau ciri *local* maupun *global* yang diekstraksi oleh model dari citra latih, maka hasil rekonstruksi *Super Resolution* meningkat dari segi visual maupun nilai PSNR dan SSIM. Oleh karena itu, model dengan 9 *layer* dipilih untuk diterapkan pada skenario berikutnya.

3.4 Evaluasi Jumlah Filter

Pada skenario ketiga, parameter yang dievaluasi merupakan jumlah *filter* awal pada *feature extraction network*. Berdasarkan hasil pengujian tahap sebelumnya, maka pada tahap evaluasi ini dilakukan dengan *dataset* Aero_bsd300_6, dan 9 *layer*. Selain itu, nilai *scale factor* 4, dan iterasi sebanyak 90 *epoch*. Tabel 6 merupakan nilai asumsi parameter *global* pada skenario ketiga.

Tabel 6. Parameter *Global* pada Skenario Ketiga

Parameter	Nilai
Jumlah <i>filter</i> ekstraksi ciri akhir	48
Peubah <i>decay filter</i> tiap <i>layer</i>	1.5
<i>Learning rate</i> awal	0.002
<i>Learning rate</i> akhir	0.0005
Peubah <i>decay learning rate</i> tiap 50 <i>epoch</i>	0.5

Tahap evaluasi dilakukan dengan tiga macam jumlah *filter* yang berbeda. Sehingga, terdapat perbedaan pada distribusi jumlah *filter* pada masing-masing *layer* di *feature extraction network*. Rincian distribusi jumlah *filter*, sebagai berikut:

1. Pada model dengan 96 buah *filter* awal, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 96, 84, 76, 71, 65, 60, 56, 52 dan 48 buah.
2. Pada model dengan 144 buah *filter* awal, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 144, 120, 105, 94, 83, 73, 64, 56 dan 48 buah.
3. Pada model dengan 192 buah *filter* awal, distribusi jumlah *filter* berurutan dari *layer* pertama hingga *layer* terakhir, yaitu: 192, 156, 134, 117, 101, 86, 73, 60 dan 48 buah.

Tabel 7. Pengaruh Jumlah *Filter* terhadap Performa

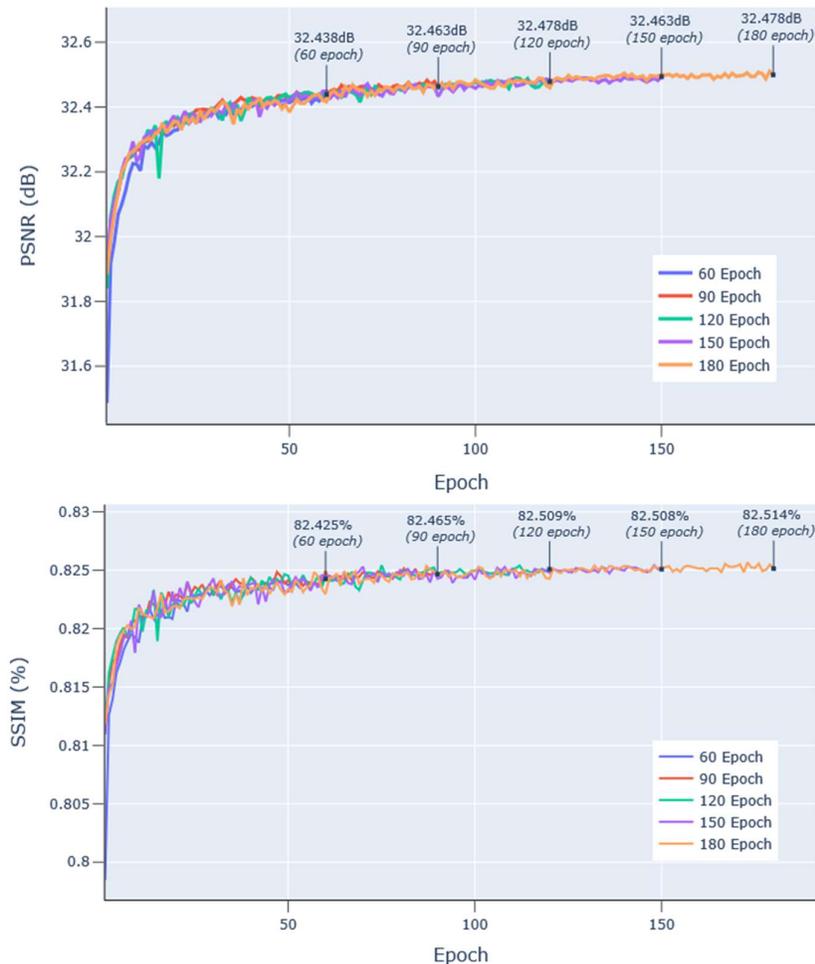
Jumlah <i>Filter</i>	PSNR (dB)	SSIM
96	32.442	0.8241
144	32.449	0.8247
192	32.461	0.8246

Tabel 7 merupakan hasil pengujian dari pengaruh jumlah *filter* terhadap Performa sistem. Berdasarkan hasil dari seluruh evaluasi, diperoleh bahwa semakin banyak jumlah *filter*, maka nilai parameter PSNR dan SSIM menjadi relatif lebih tinggi. Hal ini dikarenakan semakin banyaknya fitur atau ciri yang diekstraksi oleh model dari citra latih, maka hasil rekonstruksi *Super Resolution* pun meningkat. Penurunan nilai SSIM terjadi pada model dengan 192 *filter*. Hal tersebut dikarenakan adanya osilasi pada nilai gradien saat proses menuju titik konvergensi. Jumlah *epoch* yang sedikit menyebabkan nilai bobot yang didapatkan berhenti di titik tersebut. Oleh karena itu, berdasarkan pada nilai PSNR yang didapatkan, model dengan 192 buah *filter* dipilih untuk diterapkan pada skenario berikutnya.

3.5 Evaluasi Jumlah *Epoch*

Pada skenario keempat, parameter yang dievaluasi merupakan jumlah *epoch* yang digunakan pada tahap pelatihan model. Hal ini berpengaruh terhadap jumlah iterasi yang dibutuhkan oleh *learning rate* untuk melakukan transisi. Tahap evaluasi ini dilakukan dengan *dataset* Aero_bsd300_6, sembilan *layer* dan 192 *filter* awal pada *feature extraction network*. Hal ini didasarkan pada hasil yang didapatkan dari skenario pengujian sebelumnya, dan nilai *scale factor* 4. Diterapkan pula inisialisasi parameter *global*, seperti yang ditunjukkan pada Tabel 4. Tahap evaluasi dilakukan dengan lima macam jumlah *epoch* yang berbeda, maka terdapat perbedaan pada jumlah *epoch* yang diperlukan untuk melakukan transisi *learning rate*, yaitu:

1. Pada evaluasi pertama menggunakan 60 *epoch*, maka *decay* terjadi setiap 20 *epoch*.
2. Pada evaluasi kedua menggunakan 90 *epoch*, maka *decay* terjadi setiap 30 *epoch*.
3. Pada evaluasi ketiga menggunakan 120 *epoch*, maka *decay* terjadi setiap 40 *epoch*.
4. Pada evaluasi keempat menggunakan 150 *epoch*, maka *decay* terjadi setiap 50 *epoch*.
5. Pada evaluasi kelima menggunakan 180 *epoch*, maka *decay* terjadi setiap 60 *epoch*.

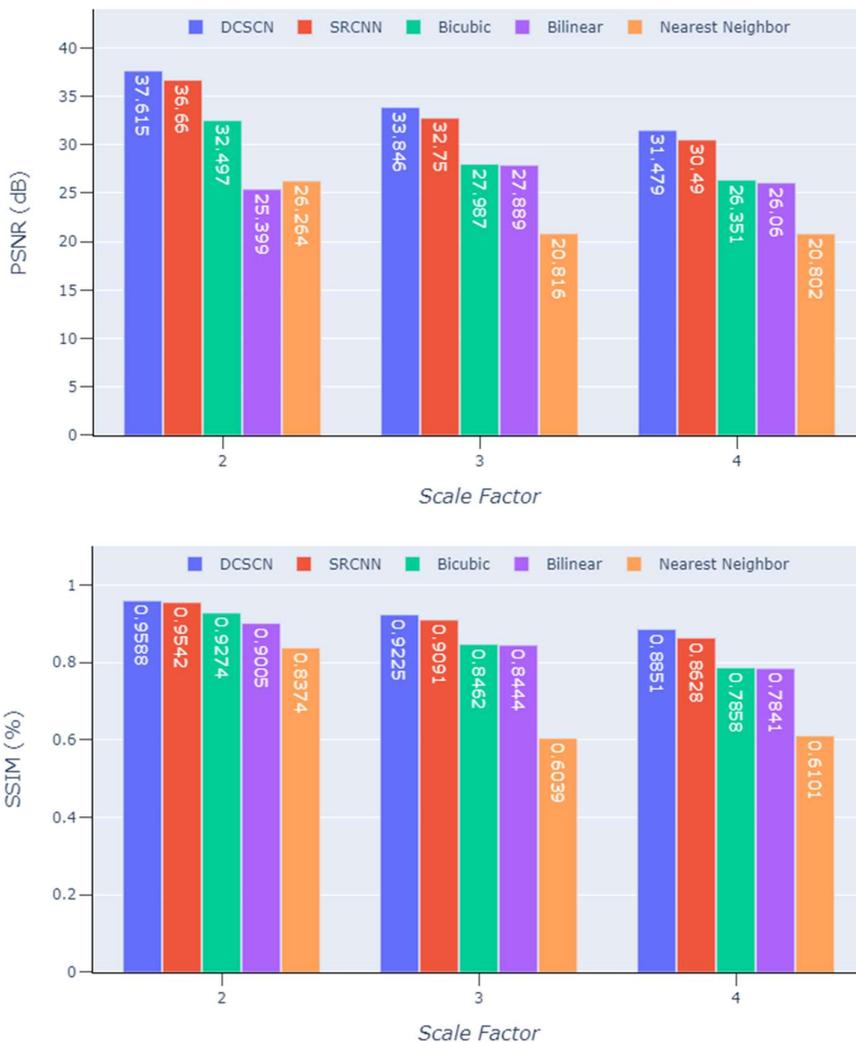


Gambar 10. Pengaruh Jumlah *Epoch* terhadap Performa PSNR (atas) SSIM (bawah)

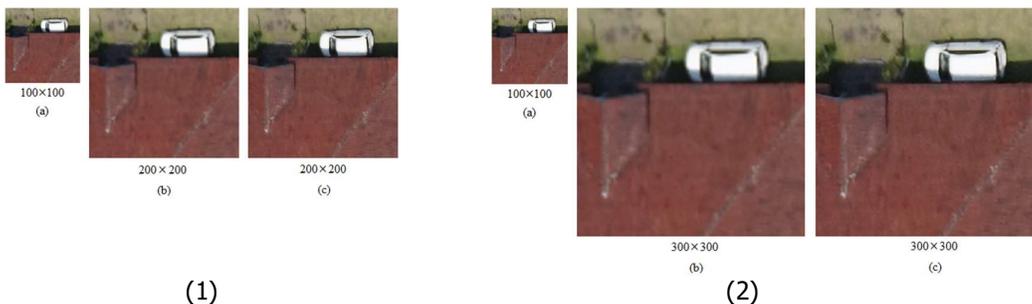
Gambar 10 merupakan hasil pengujian dari pengaruh jumlah epoch terhadap performa sistem. Berdasarkan hasil dari evaluasi pertama hingga kelima, diperoleh bahwa semakin banyak jumlah *epoch*, maka nilai parameter PSNR dan SSIM menjadi relatif lebih tinggi. Merujuk pada Gambar 6 dapat diketahui bahwa terjadi fluktuasi pada nilai PSNR dan SSIM saat tahap pelatihan. Akan tetapi, terdapat tren yang meningkat dan relatif stabil ketika jumlah *epoch* diperbesar. Hal ini disebabkan oleh adanya transisi pada nilai *learning rate*. Berdasarkan Gambar 10, ketika nilai *learning rate* menjadi lebih kecil, fluktuasi yang terjadi cenderung lebih minimal.

3.6 Tahap Pengujian *Super Resolution*

Skenario ini merupakan tahap pengujian sistem *Super Resolution* untuk merekonstruksi citra udara menjadi ukuran yang sesuai dengan *scale factor*, yaitu: 2, 3 dan 4 kali lebih besar dari citra asli. Beberapa parameter pada model CNN yang digunakan, yaitu: *dataset Aero_bsd300_6*, 9 *layer*, 192 *filter* awal pada *feature extraction network*, dan 180 *epoch*. Pengujian ini menggunakan parameter *global* pada Tabel 4. Gambar 11 merupakan hasil citra rekonstruksi untuk berbagai *scale factor* terhadap performa PSNR dan SSIM. Sedangkan Gambar 12 dan Gambar 13 merupakan tampilan hasil pengujian pada cuplikan fotogrametri untuk *scale factor* 2, 3 dan 4.



Gambar 11. Performa PSNR (atas) dan SSIM (bawah) pada Citra Hasil Rekonstruksi



Gambar 12. Hasil Pengujian pada Cuplikan Fotogrametri (1) *scale factor 2*, (2) *Scale Factor 3*, (a) Citra Asli, (b) Interpolasi *bicubic*, (c) *Super Resolution*



**Gambar 13. Hasil Pengujian pada Cuplikan Fotogrametri dengan *Scale Factor* 4
(a) Citra Asli (b) Interpolasi *Bicubic* (c) *Super Resolution***

Berdasarkan hasil evaluasi terhadap *dataset* Aero10, diperoleh bahwa model CNN yang telah dirancang berhasil mengungguli metode rekonstruksi dengan interpolasi *bicubic*. Tahap evaluasi juga dilakukan pada *dataset* Set5 untuk membandingkan antar metode rekonstruksi dengan model DCSCN, model SRCNN, interpolasi *bicubic*, interpolasi *bilinear*, dan interpolasi *nearest neighbor*. Hasil dari tahap evaluasi tersebut dapat diketahui bahwa model DCSCN berhasil mengungguli metode rekonstruksi lainnya. Pada Gambar 12 dan Gambar 13, model DCSCN juga diujikan untuk merekonstruksi citra yang telah di-*downsampling*, dan memberikan kualitas citra yang lebih baik.

4. KESIMPULAN

Penelitian ini menghasilkan sistem *Super Resolution* yang mampu merekonstruksi citra udara dari resolusi rendah menjadi citra udara resolusi tinggi menggunakan model DCSCN. Selain pada citra udara, dilakukan pula evaluasi terhadap nilai parameter PSNR dan SSIM menggunakan *dataset* Set5. Hasil model DCSCN mengungguli SRCNN, dengan nilai yang didapatkan pada *scale factor* 2, 3 dan 4, yaitu: 36.66dB / 0.9542, 32.75dB / 0.9090 dan 30.49dB / 0.8628. Sedangkan, pada penelitian ini didapatkan nilai PSNR dan SSIM sebesar 37.614dB / 0.9588, 33.846dB / 0.9225 dan 31.479dB / 0.8851. Untuk penelitian berikutnya, model *Super Resolution* dapat menggunakan fungsi *optimizer Stochastic Gradient Descent* (SGD). *Optimizer* SGD memiliki tingkat efektivitas yang baik dalam proses *machine learning* untuk melakukan *deep learning*. Fungsi *optimizer* ini bersifat stokastik atau mampu mengukur suatu peristiwa dengan data yang tidak stabil. Kemudian, sistem *Super Resolution* pada citra udara dapat diimplementasikan secara *real-time*. Data video yang ditangkap oleh UAV, selanjutnya dikirimkan secara langsung, dan diproses oleh sistem.

DAFTAR RUJUKAN

- Ahn, H., Chung, B., & Yim, C. (2019). Super-Resolution Convolutional Neural Networks Using Modified and Bilateral ReLU. *International Conference on Electronics, Information, and Communication (ICEIC)*, (pp. 1–4).
- Budiman, G., & Novamizanti, L. (2015). White Space Steganography On Text By Using LZW-Huffman Double Compression, *International Journal of Computer Networks & Communications*, *7*(2), 136A. <https://doi.org/10.5121/ijcnc.2015.7210>.
- Dong, C., Loy, C.C., He, K., & Tang, X. (2016). *Image Super-Resolution Using Deep*

- Convolutional Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(2), 295-307. <https://doi.org/10.1109/TPAMI.2015.2439281>.
- Fadnavis, S. (2014). Image Interpolation Techniques in Digital Image Processing: An Overview. *International Journal of Engineering Research and Applications (IJERA)*, 4(10), 70–73.
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow*. Sebastopol: O'Reilly.
- Heaton, J. (2015). *Artificial Intelligence for Humans, Volume 3: Deep Learning and Neural Networks* (1st ed.; T. Heaton, Ed.). Chesterfield: Heaton Research, Inc.
- Nurfutri, K., & Suyanto, M. (2016). Penilaian Kualitas Pemampatan Citra Pada Aplikasi-Aplikasi Instant Messenger. *Jurnal Ilmiah Multitek Indonesia*, 10(2), 78–90. <https://doi.org/10.24269/mtkind.v10i2.346>.
- Lin, M., Chen, Q., & Shuicheng, Y. (2014). Network In Network. *Neural and Evolutionary Computing*. arXiv:1312.4400
- Patel, P., Nandu, M., & Raut, P. (2018). Initialization of Weights in Neural Networks. *International Journal of Scientific Development and Research (IJS DR)*, 3(11), 73–79.
- Sewak, M., Karim, Md. R., & Pujari, P. (2018). *Practical Convolutional Neural Networks*. Birmingham: Packt Publishing Ltd.
- Shahmoradi, J., Talebi, E., Roghanci, P., & Hassanalian, M. (2020). *A Comprehensive Review of Applications of Drone Technology in the Mining Industry*. *Drones* 2020, 4(34), 1-25. <https://doi.org/10.3390/drones4030034>
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *International Conference on Learning Representations (ICLR)*, (pp. 1–14).
- Sun, Y., Zhang, W., Gu, H., Liu, C., Hong, S., Xu, W., & Gui, G. (2019). Convolutional Neural Network Based Models for Improving Super-Resolution Imaging. *IEEE Access*, 7, 43042–43051. <https://doi.org/10.1109/ACCESS.2019.2908501>.
- Stenroos, O. (2017). *Object Detection from Images Using CNN*. Aalto University.
- Suyanto. (2018). *Machine Learning Tingkat Dasar dan Lanjut*. Penerbit Informatika.
- Tong, T., Li, G., Liu, X., & Gao, Q. (2017). Image Super-Resolution Using Dense Skip Connections. *IEEE International Conference on Computer Vision (ICCV)*, (pp. 4799–4807). <https://doi.org/10.1109/ICCV.2017.514>.

- Welle, D. (2019, September 16). *Bencana Alam di Indonesia Tahun 2019 Diprediksi Terus Terjadi*. Retrieved from <https://www.dw.com/id/bencana-alam-di-indonesia-tahun-2019-diprediksi-terus-terjadi/a-46909297>.
- Wibawa, M. S. (2016). Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan. *Jurnal Sistem Dan Informatika*, *11*(1), 167–174. <https://doi.org/10.13140/RG.2.2.21139.94241>.
- Yamanaka, J., Kuwashima, S., & Kurita, T. (2017). Fast and Accurate Image Super Resolution by Deep CNN with Skip Connection and Network in Network. *24th International Conference of Neural Information Processing (ICONIP)*, (pp. 217–225).