

RESEARCH ARTICLE

## Analisis Penggunaan Super Image Resolution Dengan Menggunakan EDSR dan WDSR Pada Sel Manusia

Farhan Sulthan Rifqi, Irma Safitri\* and Nur Ibrahim

Fakultas Teknik Elektro, Universitas Telkom, Bandung, 40257, Jawa Barat, Indonesia

\*Corresponding author: [irmasaf@telkomuniversity.ac.id](mailto:irmasaf@telkomuniversity.ac.id)

Received on 21 April 2024; accepted on 23 May 2024

### Abstrak

Teknologi digital berkembang secara cepat dan masif. Salah satunya pada proses pengamatan sel pada manusia. Teknologi tingkat tinggi yang digunakan untuk proses tersebut adalah menggunakan PET Scan. Namun teknologi tersebut masih memiliki kekurangan, yaitu buruknya citra yang dihasilkan. Penelitian ini berfungsi untuk memperbaiki permasalahan tersebut. Dengan menjadikan output dari PET Scan sebagai data masukan (dataset) ke dalam sebuah model jaringan super-resolution, yaitu model Enhanced Deep Residual Networks for Single Image Super-Resolution (EDSR) dan Wide Activation for Efficient and Accurate Image Super-Resolution (WDSR). Tipe dataset yang digunakan adalah PET Y-90. Model kemudian ditraining untuk melihat seberapa baik model bekerja pada dataset. Proses training dilakukan dengan steps sebanyak 300.000 kali dan batch size 16, serta Scalling dari kedua model adalah 4. Hasil dari proses training akan dianalisis untuk melihat efektifitas perbaikan citra yang dihasilkan model. Dengan membandingkan PSNR dan SSIM yang dihasilkan dapat melihat kualitas citra yang dihasilkan oleh kedua model. Hasil PSNR dari EDSR dan WDSR masing-masing sebesar ... dB dan ... dB, serta SSIM sebesar ... dan ... . Setelah dataset di training, citra dengan kualitas rendah dari dataset dapat diubah menjadi citra dengan kualitas Super Resolution.

**Key words:** EDSR,WDSR,Super-Resolution,Deep Learning.

### Pendahuluan

Sel adalah penyusun yang paling penting pada tubuh mahluk hidup. Untuk mempelajari tubuh manusia, dibutuhkan pengetahuan akan sel terlebih dahulu. Penyakit pada manusia berasal dari gangguan dan penyimpangan dari perilaku sel itu sendiri. Pada tahun 1930, mikroskop elektron membuat resolusi citra pada sel lebih besar 500 kali lipat, membuatnya lebih mudah untuk menemukan dan membedakan struktur pada sel [1]. Namun pengamatan sel tersebut memerlukan waktu yang lama serta biaya yang cukup tinggi [2]. Hal tersebut dapat mengakibatkan kerusakan pada sel dan akan mempersulit proses pengamatan.

Salah satu teknologi maju yang digunakan untuk pengambilan citra adalah PET. PET atau *Positron Emission Tomography* adalah pemeriksaan noninvasif yang menghasilkan gambaran fungsi metabolisme molekuler dari tubuh pasien dengan hasil berupa tiga dimensi dengan menggunakan sebuah senyawa radioaktif yang sudah berstandar medis. Namun PET masih memiliki banyak kekurangan, karena penggunaan senyawa radioaktif selain membutuhkan biaya yang cukup tinggi juga dapat membahayakan pasien. Terlepas dari permasalahan tersebut, output yang dihasilkan oleh PET umumnya memiliki kualitas citra yang rendah, serta untuk memperoleh hasil tersebut dibutuhkan waktu yang cukup lama.

Permasalahan tersebut dapat diselesaikan dengan sebuah metode yang dapat mengubah kualitas citra rendah menjadi kualitas sangat tinggi. Dengan menggunakan salah satu cabang dari *artificial intelligence (AI)* yaitu *deep learning (DL)*, permasalahan tersebut dapat diatasi, karena citra yang didapat dapat dikonversi menjadi gambar dengan resolusi super atau *Super Resolution (SR)*. Hal tersebut dapat membuat proses observasi menjadi lebih mudah dan akan mengurangi waktu dan biaya yang dibutuhkan proses observasi data PET.

SR merupakan resolusi yang didapat setelah melakukan pemulihan terhadap citra dengan resolusi tinggi atau *high resolution (HR)* [3, 4]. Dengan menggunakan metode dari *machine learning*, yaitu *deep neural network (DNN)* dapat meningkatkan performa dengan signifikan pada pengukuran seberapa baik arsitektur dalam mengolah gambar dengan menunjukkan *peak signal to noise ratio (PSNR)* untuk masalah SR. Akan tetapi, terdapat beberapa masalah dengan metode tersebut sehingga membatasi optimasi arsitektur.

Dengan menggunakan metode *Enhanced Deep Residual Network (EDSR)* dan *Wide Activation for Efficient and Accurate Super Resolution (WDSR)* dapat melakukan peningkatan citra dengan beberapa skala pembesaran atau *scale framework* yang berbeda secara optimal [4]. Sejauh ini belum ada penelitian lebih lanjut mengenai EDSR dan WDSR apabila ada beberapa parameter yang diubah dan dataset

yang diganti, serta belum adanya pengimplementasiannya pada bidang medis.

Pada tugas akhir ini penulis menggunakan salah satu cabang dari AI yaitu DL untuk memulihkan citra HR atau resolusi standar pada data hasil PET menjadi citra dengan resolusi SR. Dengan melatih dataset PET menggunakan model ESDR dan WSDR dapat mendapatkan parameter PSNR dan loss yang digunakan untuk analisis model yang bekerja. Digunakan metode bicubic downsampling untuk performansi konversi data oleh kedua model dengan dataset PET.

### Tinjauan Pustaka

#### Positron Emission Tomography

Positron Emission Tomography atau disingkat PET, merupakan pemeriksaan noninvasif yang menghasilkan gambaran fungsi metabolisme molekuler dari tubuh pasien dengan hasil berupa tiga dimensi dengan menggunakan sebuah senyawa radioaktif yang sudah berstandar medis. PET scan dilakukan dengan menggunakan radiofarmaka yang akan memudahkan dokter dalam mendeteksi aktivitas metabolik pada sel pasien, seperti sel-sel kanker ganas dan sebagainya. Radiofarmaka fludeoksiglukosa merupakan senyawa radioaktif serta telah memenuhi persyaratan farmakologis yang telah ditetapkan baik dalam diagnostik, terapi, maupun penelitian pada dunia medis [5]. Pengolahan citra PET dapat dikombinasikan dengan prosedur lain yaitu Positron Emission Tomography/Magnetic Resonance Imaging atau dikenal sebagai PET/MRI dan Positron Emission Tomography/Computed Tomography atau dikenal sebagai PET/CT.

#### Residual Neural Network

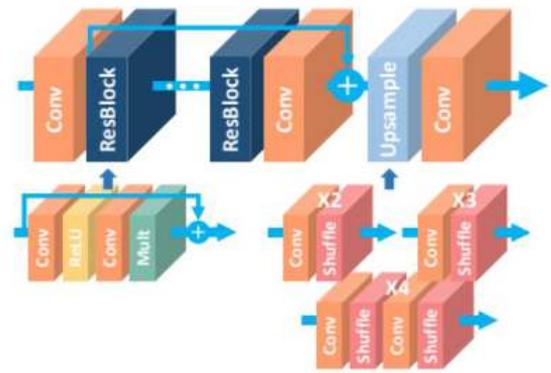
ResNet adalah salah satu bentuk dari Artificial Neural Networks (ANN) yang merekonstruksi sebuah jaringan menyerupai sel piramida dari cerebral cortex karena cara kerja ResNet menyerupai saraf yang saling terkoneksi. Cara kerja ResNet tersebut dilakukan dengan memanfaatkan jalan pintas untuk berpindah dari satu lapisan (layer) ke lapisan lainnya dengan melewati satu lapisan atau beberapa lapisan. Model ResNet yang digunakan umumnya dapat melewati dua atau tiga lapisan yang mengandung fungsi aktivasi nonlinier atau Rectified Linear Unit (ReLU) serta normalisasi batch diantara lapisan tersebut [6]. Normalisasi batch dilakukan agar ANN lebih cepat dan stabil dengan normalisasi input lapisan dengan pemusatan dan penskalaan ulang.

#### Residual Block

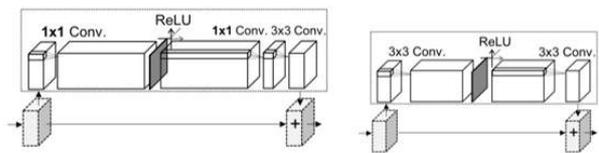
Residual Block mengolah informasi dengan melewati koneksi dari satu layer menuju layer fungsi aktivasi kemudian dilanjutkan prosesnya ke layer berikutnya yang lebih dalam [7, 8, 9]. Pada proses kerja residual block, jika sebelumnya terdapat nilai  $x$  kemudian melakukan komputasi dari layer ke layer fungsi aktivasi, kemudian ke layer selanjutnya yang lebih dalam untuk menghasilkan nilai  $f(x)$ . Jika hal tersebut dilakukan secara terus menerus maka dimensi input akan mengecil. Proses residual block dilakukan dengan shortcut di mana alih-alih melakukan proses secara linear, Residual Block melakukan pemotongan untuk mempercepat pemrosesan ke layer yang lebih dalam. Maka activation map tidak akan mengecil karena proses pemotongan [6, 10].

#### Convolution Layer

Salah satu cara untuk menaikkan scale dari citra LR adalah dengan mengkonvolusikan dengan penambahan pecahan 1. Operasi konvolusi dilakukan pada layer khusus untuk proses tersebut. Operasi tersebut dapat diimplementasikan dengan interpolasi, perforate, atau un-pooling dari ruang citra LR ke HR yang diikuti dengan mengkonvolusi dengan penambahan satu di ruang HR.



Gambar 1. Gambaran Arsitektur EDSR



Gambar 2. Blok Residual yang Terdapat Pada WDSR-B (kiri) dan WDSR-A (kanan)

#### Loss

Loss mereferensikan perbedaan antara gambar asli dengan gambar yang dihasilkan oleh algoritma dari arsitektur image processing yang digunakan. Loss didapatkan dari beberapa faktor, seperti; noise, kompresi algoritma, dan artifacts yang dihasilkan oleh algoritma arsitektur itu sendiri. Artifacts merupakan fitur yang muncul pada gambar yang dihasilkan yang tidak terdapat pada gambar asli. Ada beberapa fungsi loss yang digunakan untuk mengukur seberapa banyak loss dari sebuah gambar yang diproses, namun yang paling umum digunakan adalah Mean Squared Error (MSE). Fungsi loss lainnya adalah Mean Absolute Error (MAE), menghitung PSNR dengan pixel loss dan perceptual loss, dan SSIM. Pemilihan loss dipilih tergantung dengan pengaplikasian fungsi loss.

#### EDSR

EDSR merupakan sebuah model untuk SR yang menggunakan arsitektur tingkat tinggi, jika dilihat pada Gambar 1 [9]. EDSR memiliki blok residual yang berbeda dari ResNet seperti yang dijelaskan pada Gambar 2.1. Dengan menghapus sejumlah lapisan normalisasi yang membatasi fleksibilitas jangkauan dari jaringan dengan menormalisasikan beberapa fitur aktivasi, penggunaan memori Graphics Processing Unit (GPU) dapat dikurangi.

#### WDSR

WDSR merupakan pengembangan dari model EDSR. WDSR adalah pengembangan dari EDSR dengan melakukan perubahan lebih lanjut dari jumlah kanal pada jalur identitas mapping serta meningkatkan jumlahnya pada tiap blok residual tanpa penambahan parameter [8]. Pada Gambar 2 terdapat dua desain blok residual yaitu WDSR-A serta WDSR-B secara berurutan. WDSR-A merupakan blok residual dengan aktivasi melebar sedangkan WDSR-B merupakan aktivasi yang lebih melebar. Jika dibandingkan dengan blok residual EDSR, WDSR-A memiliki jalur mapping identitas yang lebih tipis dengan kanal yang lebih lebar (2x sampai 4x) sebelum tiap blok residual diaktifkan [11].



Gambar 3. Penggambaran Desain Sistem

Table 1. Perbedaan Variabel Pada Model

Opsi	SRRN	VDSR	EDSR	WDSR
Scale	4	4	4	4
Blok	16	16	16	32
Residual				
Filter	64	64	64	32
Parameter	1,5 juta	1,5 juta	1,52 juta	0,62 juta
Batch Normalization	Ya	Weight Normalization	-	Weight Normalization
Penskalaan Residual	-	-	0,1	-
Fungsi Loss	L2	L1	L1	L1

## Metodologi Penelitian

Tugas akhir ini dibuat untuk mengimplementasikan antara bidang medis dengan teknologi *deep learning* dengan proses gambar. Pengimplementasian tersebut yaitu dengan menggunakan model *EDSR* dan *WDSR* yang sudah ada dengan menggunakan *bicubic downsampling* untuk menurunkan kualitas citra untuk proses *training*. Pada Gambar 3, skema sistem untuk memperoleh hasil berupa citra gambar beresolusi super terbagi menjadi tiga proses, yaitu: *data preparation*, *training*, dan *testing*.

### Data Preparation

*Data preparation* merupakan proses untuk menyiapkan data berupa kumpulan gambar beresolusi rendah karena gambar yang akan digunakan pada saat proses *training* dan *testing* adalah gambar beresolusi rendah. Karena *dataset* yang digunakan berisi kumpulan data dengan citra berkualitas tinggi, maka data harus diturunkan kualitasnya. *Dataset* yang digunakan merupakan *dataset PET* yaitu kumpulan *dataset* dari hasil pemeriksaan citra sel-sel yang telah discan. *Dataset* yang digunakan adalah *PET Y-90*, yaitu kumpulan gambar dalam bentuk array berformat *Excel* yang kemudian akan diubah menjadi bentuk gambar dan dikumpulkan menjadi *dataset*.

### Training

Proses *training* adalah proses yang digunakan untuk mendapatkan hasil citra *LR* berupa *validated*, *predicted* citra *HR*. Hasil output yang didapatkan merupakan *PSNR* dan *loss*. Hasil akan didapatkan dari *dataset* yang telah di-*training* dengan banyak *steps* dan hasil yang paling optimal akan didapatkan setelah *steps* 300.000 dilakukan. Perbandingan hasil dari output tersebut dapat terlihat sesuai dengan *steps* yang telah ditentukan. Hasil dari *steps* yang dilakukan saat melakukan *training* akan menghasilkan output berupa nilai *loss* serta *accuracy* pada setiap *steps* yang berhasil melakukan *looping* saat *training*.

Proses *training* dilakukan pada setiap model dengan mengganti parameter berupa penambahan atau pengurangan blok pada setiap proses *training*. Blok yang digunakan masing-masing berjumlah 8, 16, 32, dan 64 Blok. Hasil *training* tersebut akan berupa *PSNR*, *loss*, *training time* dan *SSIM*.

### Testing

*Testing* dilakukan untuk mengonversi gambar beresolusi rendah menjadi resolusi super atau *SR*. Dengan parameter yang dihasilkan berupa *SSIM* untuk melihat seberapa mirip gambar yang sudah diproses dengan gambar asli. Kemudian parameter yang dihasilkan oleh kedua model akan dibandingkan, yaitu antara *EDSR* dan *WDSR*. Dari parameter yang didapat tersebut, maka dapat dilihat metode mana yang menghasilkan kualitas gambar lebih baik.

### Parameter Peningkatan Kualitas Gambar

1. *PSNR*

$$PSNR = 10 \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (1)$$

$MAX_I$  adalah nilai maksimum yang valid pada *pixel*, yaitu pada rentang 0-255. *MSE* adalah *mean squared error*.

2. *Loss* Perseptual

$$\mathcal{L}_{content}(I_{HR}, I_{SR}; \phi, l) = \frac{1}{H_l W_l C_l} \|\phi_l(I_{HR}) - \phi_l(I_{SR})\|_2^2 \quad (2)$$

$\phi_l(I)$  adalah *fitur map* dari lapisan ke- $l$ ,  $H_l$ ,  $W_l$ , dan  $C_l$  masing-masing secara berurutan merupakan tinggi, lebar, dan jumlah kanal dari *fitur map*.

3. *MSE*

$$MSE = \frac{\sum (y_1 - \hat{y}_2)^2}{N} \quad (3)$$

$I_{HR}$  dan  $\hat{I}_{SR}$  masing-masing merupakan nilai *pixel* dari gambar asli dan nilai *pixel* dari gambar yang diproses.  $N$  adalah jumlah *pixel* dari gambar.

4. *SSIM*

$$SSIM(x, y) = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (4)$$

$\mu_x$ ,  $\mu_y$ ,  $\sigma_x$ , dan  $\sigma_y$  masing-masing mewakili rata-rata serta standar deviasi dari kedua gambar asli serta referensi gambar itu sendiri, sementara  $C_1$  dan  $C_2$  merupakan konstanta.

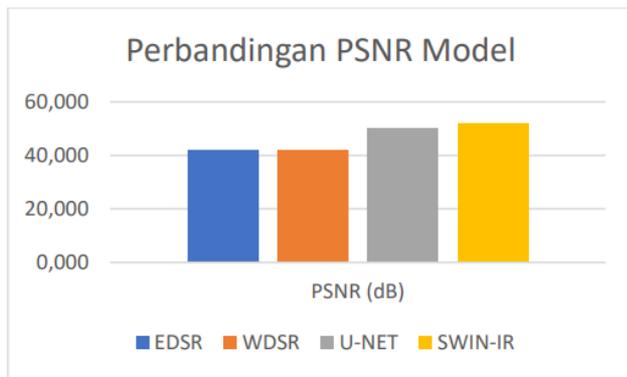
## Hasil dan Pembahasan

Penelitian dilakukan dengan menggunakan algoritma dari resolusi super *EDSR* dan *WDSR* menggunakan bahasa pemrograman *Python*. *WDSR* yang digunakan adalah *WDSR* tipe *B*. Dua metode tersebut kemudian akan dibandingkan mana yang lebih baik dari hasil *PSNR* dan *SSIM*. Model *EDSR* dan *WDSR* yang telah dibuat kemudian diatur nilai *hyperparameter*-nya, kemudian dilatih dan diuji dengan *dataset PET Y-90*. Kedua model dilatih sebanyak 300.000 *steps* untuk mendapatkan nilai *PSNR* dan *SSIM*. Proses *steps* dilakukan dengan tiap 1000 *steps* yang terjadi maka *steps* tersebut telah mengolah sebanyak 16 gambar resolusi rendah dengan output berupa *PSNR*, *SSIM*, serta *loss*.

Kemudian pada riset selanjutnya, dilakukan percobaan dengan menaikkan atau menurunkan jumlah *residual block* yang digunakan. Jumlah *residual block* yang digunakan masing-masing diubah menjadi 8, 16, 32, dan 64 blok. Pergantian blok tersebut akan mempengaruhi *PSNR*, *loss*, *SSIM*, dan waktu *training dataset* yang paling optimal dari kedua model.

**Table 2.** Perbandingan Hasil PSNR EDSR dan WDSR-B.

STEPS	EDSR	WDSR
1000	33,8360	33,5100
5000	36,8623	38,7406
10.000	39,8036	40,1678
50.000	41,3903	41,5869
100.000	41,1452	41,8874
150.000	41,6455	41,8850
200.000	41,6296	41,9063
250.000	41,6798	41,9018
300.000	41,6564	41,8473
PSNR Akhir	41,9240	42,1731
SSIM	0,9765	0,9774



**Gambar 4.** Perbandingan dengan Model Lain

**Hasil Perbandingan EDSR dan WDSR**

Terlihat pada Tabel 2, model *WDSR-B* terbukti mampu menyaingi hasil dari metode *EDSR* dengan perbedaan nilai *PSNR* dan *SSIM* yang tipis, yaitu dengan nilai *PSNR* pada *EDSR* dan *WDSR-B* masing-masing sebesar 43,35 dan 43,20, serta *SSIM* pada *EDSR* dan *WDSR-B* masing-masing sebesar 0,98 pada *dataset Y-90*.

**Perbandingan dengan Model Lain**

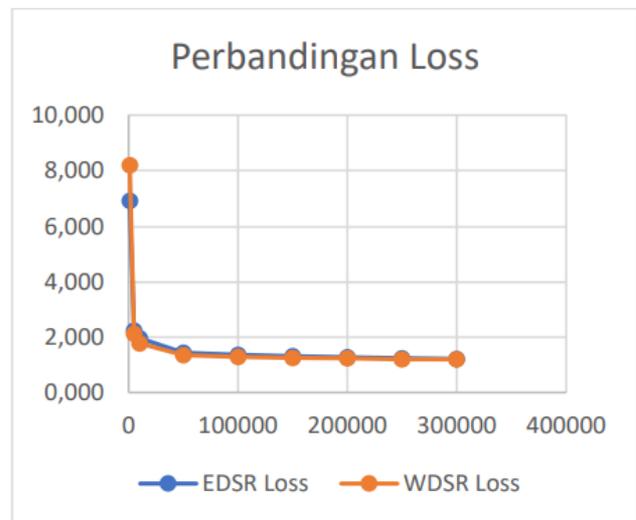
Pada Gambar 4 di atas terlihat nilai *PSNR* yang dihasilkan dengan skala 4x menggunakan *dataset Y-90* untuk model *EDSR* dan *WDSR-B* memiliki nilai *PSNR* yang lebih rendah dibandingkan model lain. Pada kedua model lain, terlihat *PSNR* yang dihasilkan sedikit lebih unggul jika dibandingkan dengan *EDSR* dan *WDSR* dengan *dataset* yang sama. Hasil *PSNR* kedua model lain, yaitu *U-Net* dan *SwinIR*, dengan *dataset PET-VDG* diambil dari jurnal referensi [12]. Perlu diketahui, model lain tersebut dilatih dengan *dataset PET VDG* yang berjumlah 800 gambar, sedangkan model *EDSR* dan *WDSR* dilatih dengan *dataset PET Y-90* yang berjumlah 120 gambar.

**Perbandingan Waktu dan Loss**

Pada Gambar 5 terlihat masing-masing waktu yang dibutuhkan untuk menyelesaikan proses *training* dan *loss* dengan *steps* sebanyak 300.000. Perbedaan lamanya waktu saat proses *training* dilakukan disebabkan oleh perbedaan cara aktivasi algoritma *ANN* dari model *WDSR* yang memiliki cara proses pengaktifan kanal yang dilakukan



**Gambar 5.** Perbandingan Waktu Kedua Model saat Proses Training



**Gambar 6.** Perbandingan Loss Kedua Model saat Proses Training

secara melebar. Hal tersebut yang menjadikan proses *training* pada *WDSR* memakan banyak waktu jika dibandingkan dengan *EDSR*.

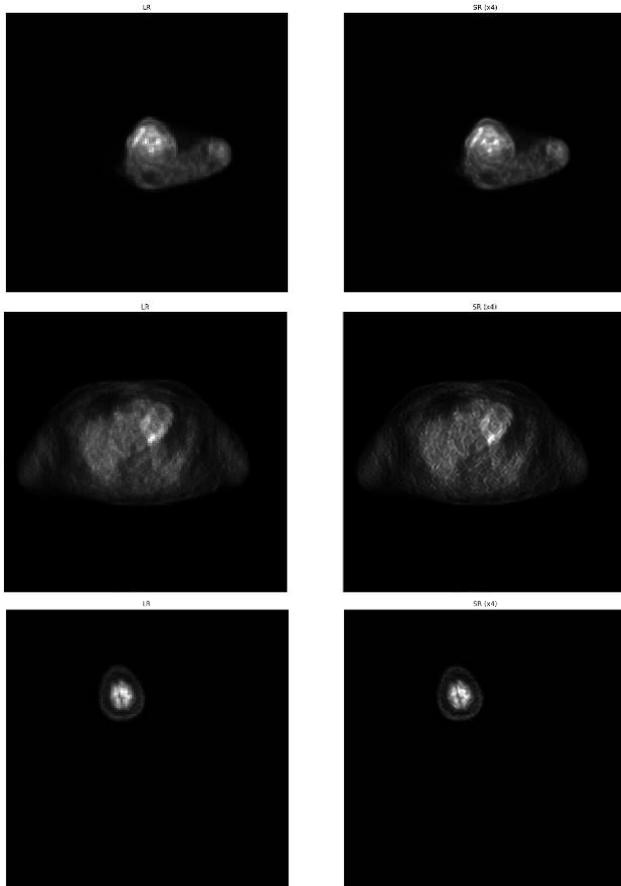
Gambar 6 menjelaskan fungsi *loss* yang digunakan adalah *MSE (Mean Squared Error)*. *Loss* yang dihasilkan saat *step* awal sangat tinggi, namun seiring bertambahnya *steps* *loss* umumnya akan mulai turun dan akan stabil. Fungsi *loss* menggambarkan perbedaan antara gambar yang sedang diolah dengan gambar asli. Grafik yang melandai menunjukkan *error* yang semakin berkurang yang disebabkan oleh algoritma *Residual Neural Network* yang akan meminimalisir *error* yang terjadi pada saat proses *training* yang ditandai dengan semakin landainya grafik, baik dari segi waktu maupun hasil *loss*.

**Pergantian Blok Kedua Model**

Pada Tabel 3 dilakukan beberapa percobaan dengan mengganti banyaknya blok yang digunakan pada model tersebut dengan menggunakan *dataset* yang sama. Dari percobaan tersebut, didapatkan hasil yang

**Table 3.** Pergantian Blok EDSR dan WDSR

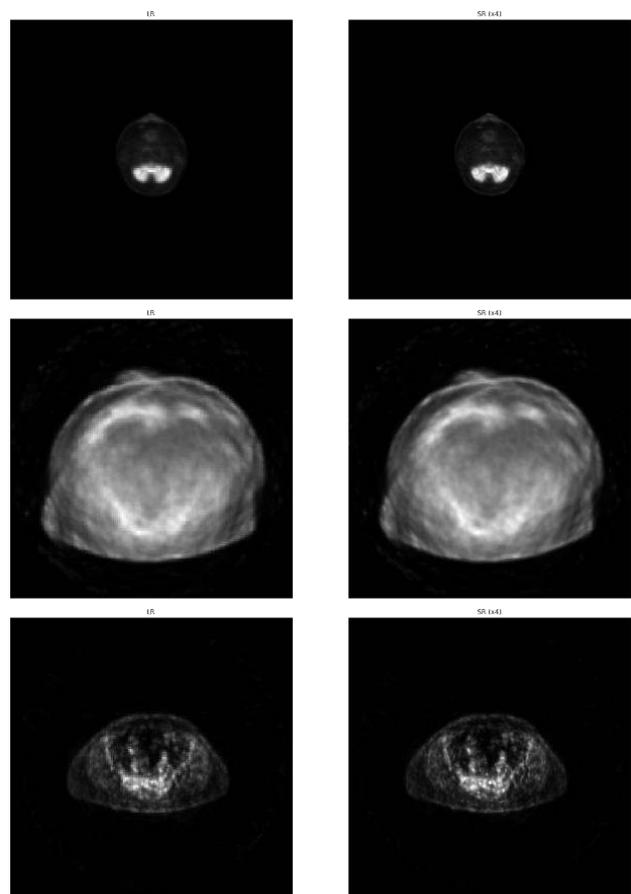
BLOK	EDSR		WDSR	
	PSNR	SSIM	PSNR	SSIM
8	41,7913	0,9785	41,7620	0,9761
16	41,9240	0,9765	42,0103	0,9768
32	44,1168	0,9779	42,1730	0,9773
64	41,9736	0,9768	42,3083	0,9777

**Gambar 7.** Hasil Testing EDSR

berbeda-beda pada tiap bloknya. Output yang dihasilkan berupa *PSNR* (dB) dan *SSIM*. Dengan mengubah blok menjadi 8, 32, dan 64 blok didapatkan *PSNR* dan *SSIM* yang berbeda-beda. Umumnya, *PSNR* yang didapatkan tiap ditambahkan jumlah bloknya akan bertambah juga, dengan waktu *training* yang juga meningkat.

#### Testing EDSR

Hasil *Testing* menggunakan *dataset PET Y-90* dengan menggunakan model *EDSR* yang paling optimal yang berjumlah 64 blok. Citra yang diproses sudah diperbesar menjadi 4 kali lipat dengan masing-masing dimensi citra yang digunakan yaitu 64 kali 64 dan 128 kali 128. Dengan menggunakan *Google Colab*, untuk menganalisis data *PET* lain, masukkan folder ke dalam *database model*, lalu kemudian pada *Google Colab*, pada bagian *testing database* akan diarahkan untuk memproses gambar yang diinginkan.

**Gambar 8.** Hasil Testing WDSR

#### Testing WDSR

Hasil *Testing* menggunakan *dataset PET Y-90* dengan menggunakan model *WDSR* yang paling optimal yang berjumlah 64 blok. Citra yang diproses sudah diperbesar menjadi 4 kali lipat dengan masing-masing dimensi citra yang digunakan yaitu 64 kali 64 dan 128 kali 128. Dengan menggunakan *Google Colab*, untuk menganalisis data *PET* lain, masukkan folder ke dalam *database model*, lalu kemudian pada *Google Colab*, pada bagian *testing database* akan diarahkan untuk memproses gambar yang diinginkan.

## Kesimpulan

### Kesimpulan

Berdasarkan hasil analisis dari sistem IMPLEMENTASI SUPER IMAGE RESOLUTION DENGAN MENGGUNAKAN EDSR DAN WDSR PADA SEL MANUSIA, dapat disimpulkan bahwa:

1. Model EDSR dan WDSR-B bekerja cukup optimal pada dataset Y-90 dan lebih optimal jika menaikkan jumlah data pada dataset.
2. Penambahan dan pengurangan jumlah blok yang digunakan juga akan mempengaruhi hasil dari PSNR yang didapat.
3. Model EDSR jika dibandingkan dengan WDSR-B dengan proses training menggunakan jumlah blok yang sama, lebih baik dari model WDSR-B. Dengan hasil terbaik yaitu pada penggunaan sebanyak 32 blok PSNR (dB) dan SSIM masing-masing sebesar 44,1168 dB dan 0,9779 dibandingkan dengan WDSR-B yang

memiliki nilai PSNR dan SSIM terbaik pada 64 blok, yang masing-masing sebesar 42,3083 dB dan 0.9777.

## Saran

1. Melakukan penelitian apakah dengan meningkatkan resolusi citra terhadap pendeteksian suatu penyakit akan mempengaruhi kualitas deteksi citra. 2. Mengganti jenis dataset dan menambahkan isi dataset serta parameter lainnya agar menguji kedua model mampu diimplementasikan selain dari hasil scan PET.

## Daftar Pustaka

- Hon CC, Shin JW, Carninci P, Stubbington MJT. The human cell atlas: Technical approaches and challenges. 2018. <https://doi.org/10.1093/bfpg/elix029>.
- Regev A, Teichmann S, Lander E, Amit I, Benoist C, Birney E, et al. Science Forum: The Human Cell Atlas. *ELife*. 2017.
- Ledig C, Theis L, Huszár F, Caballero J, Cunningham A, Acosta A, et al. Photo-realistic single image super-resolution using a generative adversarial network. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2017. <https://doi.org/10.1109/CVPR.2017.19>.
- Kim J, Lee JK, Lee KM. Accurate image super-resolution using very deep convolutional networks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016. <https://doi.org/10.1109/CVPR.2016.182>.
- Rosilawati NE, Nasution I, Murni TW. PENGGUNAAN RADIO-FARMAKA UNTUK DIAGNOSA DAN TERAPI DI INDONESIA DAN ASAS KEAMANAN PENGGUNAAN OBAT. *SOEPRA*. 2018;3(1). <https://doi.org/10.24167/shk.v3i1.697>.
- Mayerhoefer ME, Prosch H, Beer L, Tamandl D, Beyer T, Hoeller C, et al. PET/MRI versus PET/CT in oncology: a prospective single-center study of 330 examinations focusing on implications for patient management and cost considerations. *European Journal of Nuclear Medicine and Molecular Imaging*. 2020;47(11). <https://doi.org/10.1007/s00259-019-04452-y>.
- Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative adversarial networks. *Communications of the ACM*. 2020;63(11). <https://doi.org/10.1145/3422622>.
- Yu J, Fan Y, Huang T. Wide activation for efficient image and video super-resolution; 2020. <https://doi.org/10.1016/j.nim.a.2020.164293>.
- Lim B, Son S, Kim H, Nah S, Lee KM. Enhanced Deep Residual Networks for Single Image Super-Resolution. In: IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops; 2017. <https://doi.org/10.1109/CVPRW.2017.151>.
- Kim J, Lee JK, Lee KM. Accurate image super-resolution using very deep convolutional networks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016. <https://doi.org/10.1109/CVPR.2016.182>.
- Salimans T, Kingma DP. Weight normalization: A simple reparameterization to accelerate training of deep neural networks. Proceedings of the 30th International Conference on Neural Information Processing Systems (NIPS). 2016.
- Wang YRJ, Wang P, Adams LC, Sheybani ND, Qu L, Sarrami AH, et al. Low-count whole-body PET/MRI restoration: an evaluation of dose reduction spectrum and five state-of-the-art artificial intelligence models. 2023. <https://doi.org/10.1007/s00259-022-06097-w>.
- Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC. Inverted Residuals and Linear Bottlenecks: Mobile Networks for Classification, Detection and Segmentation. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2018. .
- Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. In: 3rd International Conference on Learning Representations (ICLR); 2015. .
- He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016. <https://doi.org/10.1109/CVPR.2016.90>.
- Nenclares P, Harrington KJ. The biology of cancer. *Medicine (United Kingdom)*. 2020;48(2). <https://doi.org/10.1016/j.mpm.ed.2019.11.001>.
- Roizen MF. Hallmarks of Cancer: The Next Generation. *Yearbook of Anesthesiology and Pain Management*. 2012. <https://doi.org/10.1016/j.yane.2012.02.046>.
- Fendler WP, Czernin J, Herrmann K, Beyer T. Variations in PET/MRI operations: Results from an international survey among 39 active sites. *Journal of Nuclear Medicine*. 2016. <https://doi.org/10.2967/jnumed.116.174169>.
- Shelhamer E, Long J, Darrell T. Fully Convolutional Networks for Semantic Segmentation. vol. 39; 2017. <https://doi.org/10.1109/TPAMI.2016.2572683>.
- Xie S, Girshick R, Dollár P, Tu Z, He K. Aggregated residual transformations for deep neural networks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2017. <https://doi.org/10.1109/CVPR.2017.634>.
- Osendorfer C, Soyer H, van der Smagt P. Image super-resolution with fast approximate convolutional sparse coding; 2014. [https://doi.org/10.1007/978-3-319-12643-2\\_31](https://doi.org/10.1007/978-3-319-12643-2_31).
- Shi W, Caballero J, Huszar F, Totz J, Aitken AP, Bishop R, et al. Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016. .
- Wang Q, Ma Y, Zhao K, Tian Y. A Comprehensive Survey of Loss Functions in Machine Learning. *Annals of Data Science*. 2022. <https://doi.org/10.1007/s40745-020-00253-5>.
- Wang Z, Bovik AC, Sheikh HR, Simoncelli EP. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*. 2004. <https://doi.org/10.1109/TIP.2003.819861>.
- Afaq S, Rao S. Significance Of Epochs On Training A Neural Network. *International Journal of Scientific & Technology Research*. 2020;9(06).
- Mujilawati S, Sholihin M, Wardhani R. Optimasi Hyperparameter TensorFlow dengan Menggunakan Optuna di Python: Study Kasus Klasifikasi Dokumen Abstrak Skripsi. *JURNAL MEDIA INFORMATIKA BUDIDARMA*. 2021;5(3). <https://doi.org/10.30865/mib.v5i3.3090>.
- Abdelaziz Ismael SA, Mohammed A, Hefny H. An enhanced deep learning approach for brain cancer MRI images classification using residual networks. *Artificial Intelligence in Medicine*. 2020;102. <https://doi.org/10.1016/j.artmed.2019.101779>.
- Refianti R, Mutiara AB, Priyandini RP. Classification of melanoma skin cancer using convolutional neural network. *International Journal of Advanced Computer Science and Applications*. 2019. <https://doi.org/10.14569/IJACSA.2019.0100353>.
- Yuliani E, Aini AN, Khasanah CU. Perbandingan Jumlah Epoch Dan Steps Per Epoch Pada Convolutional Neural Network Untuk Meningkatkan Akurasi Dalam Klasifikasi Gambar. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*. 2020. <https://doi.org/10.46808/informa.v5i3.140>.
- Mujilawati S, Sholihin M, Wardhani R. Optimasi Hyperparameter TensorFlow dengan Menggunakan Optuna di Python: Study Kasus

Klasifikasi Dokumen Abstrak Skripsi. JURNAL MEDIA INFORMATIKA BUDIDARMA. 2021;5(3). <https://doi.org/10.30865/mib.v5i3.3090>.

31. Nurfitia RD, Ariyanto G. Implementasi Deep Learning berbasis Tensorflow untuk Pengenalan Sidik Jari. Emitter: Jurnal Teknik Elektro.

2018;18(01). <https://doi.org/10.23917/emitor.v18i01.6236>.