

Anaslis Pnggunaan Super Image Resolution Dengan Menggunakan EDSR dan WDSR Pada Sel Manusia

1st Farhan Sulthan Rifqi,
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

farhansulthan@student.telkomuniversity.
ac.id,

2nd Irma Safitri
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

irmasaf@telkomuniversity.ac.id,

3rd Nur Ibrahim
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

nuribrahim@telkomuniversity.ac.id

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*.

Kata kunci : EDSR, WDSR, Super-Resolution, Deep Learning.

I. PENDAHULUAN

Sel adalah penyusun yang paling penting pada tubuh makhluk 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 [2]. Namun pengamatan sel tersebut memerlukan waktu yang lama serta biaya yang cukup tinggi [3]. 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) [4, 9]. 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 [9]. 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.

II. KAJIAN TEORI

A. 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 akan memudahkan dokter dalam mendeteksi aktifitas 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 [12]. 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.

B. 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 [14]. Normalisasi batch dilakukan agar ANN lebih cepat dan stabil dengan normalisasi input lapisan dengan pemusatan dan penskalaan ulang.

C. 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, 9, 16]. 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 “*shortcut*” dimana 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 [14, 15].

dataset PET untuk memperoleh citra dengan resolusi super dari citra dengan resolusi tinggi. Setelah proses *training*, proses *testing* akan dijalankan untuk mengetahui kemiripan gambar yang sudah dilatih dengan gambar asli melalui parameter SSIM. Parameter tersebut akan mengetahui


D. Convolution Layer

Salah satu cara untuk menaikkan *scale* dari citra LR adalah dengan mengkonvolusikan dengan penambahan pecahan $\frac{1}{r}$. operasi kovolusi 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.

E. 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. *Aritfatcs* merupakan fitur yang muncul pada gambar yang dihasilkan yang tidak terdapat pada gambar original. 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.


F. EDSR



GAMBAR 2. 1
Gambaran Arsitektur EDSR

EDSR merupakan sebuah model untuk SR yang menggunakan arsitektur tingkat tinggi, jika dilihat pada Gambar 2.1 [16]. 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.

G. WDSR



GAMBAR 2. 2

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

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 [9]. Pada Gambar 2.2 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 [21].

III. METODE



GAMBAR 3. 1

Penggambaran Desain Sistem

Tugas akhir ini dibuat untuk mengimplemetasikan antara bidang medis dengan teknologi *deep learning* dengan proses gambar. Pengimplementasian tersebut yaitu dengan menggunakan model EDSR dan WDSR yang sudah dengan menggunakan *bicubic downsampling* untuk menurunkan kualitas citra untuk proses *training*. Pada gambar 3.1 skema sistem untuk memperoleh hasil berupa citra gambar beresolusi super terbagi menjadi 3 proses, yaitu; *data preparation*, *training*, dan *testing*.

TABEL 3. 1
Perbedaan Variabel Pada Model

Opsi	SRRN	VDSR	EDSR	WDSR
Scale	4	4	4	4
Blok Residual	16	16	16	32
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

A. 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 di turunkan 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*.

B. 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 melakukan 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.

C. Testing

Testing dilakukan untuk mengkonversi gambar beresolusi rendah menjadi resolusi super atau SR. Dengan parameter yang dihasilkan berupa SSIM untuk melihat seberapa mirip gambar yang sudah di proses 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.

D. Parameter Peningkatan Kualitas Gambar

1. PSNR

$$PSNR = 10 \log_{10} \left(\frac{MAX_1^2}{MSE} \right)$$

MAX merupakan nilai maksimal yang valid pada pixel, yaitu pada rentang 0-255. *MSE* merupakan *mean squared error*.

2. Loss Perseptual

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

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

$$MSE = \frac{\sum (y_1 - \hat{y}_1)^2}{n}$$

y_1 dan $\hat{y}_1$ masing-masing merupakan nilai *pixel* dari gambar asli dan nilai *pixel* merupakan nilai *pixel* dari gambar yang diproses. Sementara n merupakan *pixel* jumlah dari *pixel* gambar.

3. SSIM

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

μ_x , μ_y , σ_x dan σ_y masing-masing mewakili rata-rata serta standar deviasi dari kedua gambar asli serta referensi gambar itu sendiri, sementara C1, C2 merupakan konstanta.

IV. HASIL DAN PEMBAHASAN

Penelitian dilakukan dengan menggunakan algoritma dari resolusi super EDSR dan WDSR menggunakan bahasa coding 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 blok yang digunakan. Jumlah residual blok yang digunakan masing-masing diubah menjadi 8, 16, 32, dan 64 blok. Pergantian blok tersebut akan mengetahui PSNR, loss, SSIM, dan waktu training dataset yang paling optimal dari kedua model.


A. Hasil Perbandingan EDSR dan WDSR

TABEL 4. 1
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

Terlihat pada Tabel 4.1 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 , serta SSIM pada EDSR dan WDSR-B masing-masing sebesar 0,98 pada dataset Y-90.


B. Perbandingan dengan Model Lain




GAMBAR 4. 1
Perbandingan Dengan Model Lain

Pada gambar 4.1 diatas terlihat nilai PSNR yang dihasilkan dengan scale $\times 4$ dengan menggunakan dataset Y-90 untuk model EDSR dan WDSR-B memiliki nilai PSNR yang lebih rendah dengan 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 yang didapat diambil dari jurnal referensi[31]. Perlu diketahui, model lain tersebut dilatih dengan dataset PET VDG yang berjumlah 800 gambar dan model EDSR dan WDSR dilatih dengan dataset PET Y-90 yang berjumlah 120 gambar.

C. Perbandingan Waktu dan loss



GAMBAR 4.2
Perbandingan Waktu Kedua Model Saat Proses Training.



GAMBAR 4.3

Perbandingan Loss kedua Model Saat Proses Training

Pada gambar 4.2 menjelaskan masing masing waktu yang dibutuhkan untuk menyelesaikan proses training dan loss dengan steps sebanyak 300.000. Perbedaan lamanya waktu saat proses training dilakukan disebabkan perbedaan cara aktivasi algoritma ANN dari model WDSR yang memiliki cara proses pengaktifan kanal yang dilakukan secara melebar. Hal tersebut yang menjadikan proses training pada WDSR yang memakan banyak waktu jika dibandingkan dengan EDSR.

Gambar 4.3 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 dikarenakan 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.


D. Pergantian Blok Kedua Model

TABEL 4.2
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

Pada Tabel 4.3 dilakukan beberapa percobaan dengan mengganti banyaknya blok yang digunakan pada model tersebut dengan menggunakan dataset yang sama. Dari percobaan tersebut, didapatkan hasil yang berbeda-beda pada tiap bloknya. Output yang dihasilkan berupa PSNR (dB) dan SSIM. Dengan merubah 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.

E. Testing EDSR





GAMBAR 4.4

Hasil 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, jika ingin menganalisis data PET lain yaitu dengan memasukan folder ke dalam database model, lalu kemudian pada google colab, pada bagian *testing* database akan diarahkan untuk memproses gambar yang diinginkan.

F. Testing WDSR





GAMBAR 4.5
Hasil Testing WDSR

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, jika ingin menganalisis data PET lain yaitu dengan memasukkan folder ke dalam database model, lalu kemudian pada google colab, pada bagian testing database akan diarahkan untuk memproses gambar yang diinginkan.

V. KESIMPULAN

A. 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 0,9777B,

B. 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.

6. DAFTAR PUSTAKA

[1] Hon, C. C., Shin, J. W., Carninci, P., & Stubbington, M. J. T. (2018). The human cell atlas: Technical approaches and challenges. <https://doi.org/10.1093/bfpg/elx029>.

[2] Regev, A., Teichmann, S., Lander, E., Amit, I., Benoist, C., Birney, E., Bodenmiller, B., Campbell, P., Carninci, P., & Enard, W. (2017). Science Forum: The Human Cell Atlas. *ELife*.

[3] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z., & Shi, W. (2017). Photo-realistic single image

super-resolution using a generative adversarial network. <https://doi.org/10.1109/CVPR.2017.19>

[4] Kim, J., Lee, J. K., & Lee, K. M. (2016). Accurate image super-resolution using very deep convolutional networks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR.2016.182>

[5] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Inverted Residuals and Linear Bottlenecks: Mobile Networks for Classification, Detection and Segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*.

[6] Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.

[7] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11). <https://doi.org/10.1145/3422622>.

[8] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-December. <https://doi.org/10.1109/CVPR.2016.90>

[9] Yu, J., Fan, Y., & Huang, T. (2020). Wide activation for efficient image and video super-resolution. 2019. <https://doi.org/10.1016/j.nima.2020.164293>

[10] Nenclares, P., & Harrington, K. J. (2020). The biology of cancer. In *Medicine (United Kingdom)* (Vol. 48, Issue 2). <https://doi.org/10.1016/j.mpmed.2019.11.001>

[11] Roizen, M. F. (2012). Hallmarks of Cancer: The Next Generation. *Yearbook of Anesthesiology and Pain Management*, 2012. <https://doi.org/10.1016/j.yane.2012.02.046>.

[12] Rosilawati, N. E., Nasution, I., & Murni, T. W. (2018). PENGGUNAAN RADIOFARMAKA UNTUK DIAGNOSA DAN TERAPI DI INDONESIA DAN ASAS KEAMANAN PENGGUNAAN OBAT. *SOEPRA*, 3(1). <https://doi.org/10.24167/shk.v3i1.697>.

[13] Fendler, W. P., Czernin, J., Herrmann, K., & Beyer, T. (2016). Variations in PET/MRI operations: Results from an international survey among 39 active sites. <https://doi.org/10.2967/jnumed.116.174169>.

[14] Mayerhoefer, M. E., Prosch, H., Beer, L., Tamandl, D., Beyer, T., Hoeller, C., Berzaczy, D., Raderer, M., Preusser, M., Hochmair, M., Kiesewetter, B., Scheuba, C., Ba-Ssalamah, A., Karanikas, G., Kesselbacher, J., Prager, G., Dieckmann, K., Polterauer, S., Weber, M., ... Haug, A. R. (2020). PET/MRI versus PET/CT in oncology: a prospective single-center study of 330 examinations focusing on implications for patient management and cost considerations. <https://doi.org/10.1007/s00259-019-04452-y>.

[15] Kim, J., Lee, J. K., & Lee, K. M. (2016). Accurate image super-resolution using very deep convolutional networks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR.2016.182>.

[16] Lim, B., Son, S., Kim, H., Nah, S., & Lee, K. M. (2017). Enhanced Deep Residual Networks for Single Image Super-Resolution. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 2017-July. <https://doi.org/10.1109/CVPRW.2017.151>

- [17] Shelhamer, E., Long, J., & Darrell, T. (2017). Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4). 2016. <https://doi.org/10.1109/TPAMI.2016.2574698>.
- [18] Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017). Aggregated residual transformations for deep neural networks. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-January*. <https://doi.org/10.1109/CVPR.2017.634>
- [19] Osendorfer, C., Soyer, H., & van der Smagt, P. (2014). Image super-resolution with fast approximate convolutional sparse coding. https://doi.org/10.1007/978-3-319-12643-2_31.
- [20] Shi, W., Caballero, J., Huszar, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D., & Wang, Z. (2016). Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern*.
- [21] Salimans, T., & Kingma, D. P. (2016). Weight normalization: A simple reparameterization to accelerate training of deep neural networks.
- [22] Wang, Q., Ma, Y., Zhao, K., & Tian, Y. (2022). A Comprehensive Survey of Loss Functions in Machine Learning. *Annals of Data Science*,. <https://doi.org/10.1007/s40745-020-00253-5>
- [23] Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*. <https://doi.org/10.1109/TIP.2003.819861>
- [24] Afaq, S., & Rao, S. (2020). Significance Of Epochs On Training A Neural Network. *International Journal of Scientific & Technology Research*, 9(06).
- [25] Mujilahwati, S., Sholihin, M., & Wardhani, R. (2021). Optimasi Hyperparameter TensorFlow dengan Menggunakan Optuna di Python: Study Kasus Klasifikasi Dokumen Abstrak Skripsi. *JURNAL MEDIA INFORMATIKA BUDIDARMA*,. <https://doi.org/10.30865/mib.v5i3.3090>.
- [26] Abdelaziz Ismael, S. A., Mohammed, A., & Hefny, H. (2020). An enhanced deep learning approach for brain cancer MRI images classification using residual networks. *Artificial Intelligence in Medicine*, 102. <https://doi.org/10.1016/j.artmed.2019.101779>.
- [27] Refianti, R., Mutiara, A. B., & Priyandini, R. P. (2019). Classification of melanoma skin cancer using convolutional neural network. <https://doi.org/10.14569/IJACSA.2019.0100353>.
- [28] Yuliani, E., Aini, A. N., & Khasanah, C. U. (2020). Perbandingan Jumlah Epoch Dan Steps Per Epoch Pada Convolutional Neural Network Untuk Meningkatkan Akurasi Dalam Klasifikasi Gambar. <https://doi.org/10.46808/informa.v5i3.140>
- [29] Mujilahwati, S., Sholihin, M., & Wardhani, R. (2021). Optimasi Hyperparameter TensorFlow dengan Menggunakan Optuna di Python: Study Kasus Klasifikasi Dokumen Abstrak Skripsi. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 5(3). <https://doi.org/10.30865/mib.v5i3.3090>.
- [30] Nurfita, R. D., & Ariyanto, G. (2018). Implementasi Deep Learning berbasis Tensorflow untuk Pengenalan Sidik Jari. *Emitor: Jurnal Teknik Elektro*. <https://doi.org/10.23917/emitor.v18i01.6236>
- [31] Wang, Y. R. (Joyce), Wang, P., Adams, L. C., Sheybani, N. D., Qu, L., Sarrami, A. H., Theruvath, A. J., Gatidis, S., Ho, T., Zhou, Q., Pribnow, A., Thakor, A. S., Rubin, D., & Daldrup-Link, H. E. (2023). Low-count whole-body PET/MRI restoration: an evaluation of dose reduction spectrum and five state-of-the-art artificial intelligence models. <https://doi.org/10.1007/s00259-022-06097-w>