

Restorasi Citra Penginderaan Jarak Jauh Menggunakan Metode U-Net

Kevin Iansyah, Nanda Syarla Hariyanti, Alya Izzah Zalfa Rihadah Ramadhani
Nirwana Putri, Muhamad Albert Nur Agathon, *Fetty Tri Anggraeni
Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan
Nasional Veteran Jawa Timur, Indonesia

Diterima: 11 April 2025 | Revisi: 26 Mei 2025 | Diterbitkan: 10 Juni 2025

DOI: <https://doi.org/10.33005/scan.v20i1.5659>

ABSTRAK

Restorasi citra adalah proses untuk meningkatkan kualitas citra yang mengalami degradasi, seperti akibat gangguan noise. Penelitian ini berfokus pada peningkatan kualitas citra penginderaan jarak jauh yang terdegradasi menggunakan model Convolutional Neural Network (CNN) dengan arsitektur U-Net. Dataset FAIR1M, yang terdiri dari citra resolusi tinggi hasil penginderaan jarak jauh, digunakan dalam penelitian ini. Pada tahap pra-proses, citra resolusi tinggi diubah ke format grayscale, diubah ukurannya, dan ditambahkan noise. Proses pelatihan model menggunakan fungsi Mean Squared Error (MSE), sementara optimasi dilakukan dengan Algoritma Adam. Model dievaluasi menggunakan metrik Peak Signal-to-Noise Ratio (PSNR) dan Structural Similarity Index (SSIM). Hasil penelitian menunjukkan bahwa model U-Net secara efektif dan signifikan mampu mengurangi noise dan meningkatkan kualitas citra. Proses pengujian terhadap 2.000 data menghasilkan rata-rata nilai PSNR sebesar 39,7892 dB dan rata-rata nilai SSIM sebesar 0,9814.

Kata Kunci: restorasi citra, penginderaan jarak jauh, noise, CNN, U-Net

Remote Sensing Image Restoration Using U-Net Method

ABSTRACT

Image restoration is the process of improving the quality of images that have undergone degradation, such as those affected by noise interference. This study focuses on enhancing the quality of degraded remote sensing images using a Convolutional Neural Network (CNN) model with a U-Net architecture. The FAIR1M dataset, which consists of high-resolution remote sensing images, is used in this research. In the preprocessing stage, high-resolution images are converted to grayscale format, resized, and noise is added. The model training process uses the Mean Squared Error (MSE) function, while optimization is performed using the Adam Algorithm. The model is evaluated using the Peak Signal-to-Noise Ratio (PSNR) and Structural Similarity Index (SSIM) metrics. The results show that the U-Net model effectively and significantly reduces noise and improves image quality. Testing on 2,000 data samples yields an average PSNR value of 39.7892 dB and an average SSIM value of 0.9814.

Keywords: image restoration, remote sensing, noise, CNN, U-Net

*Corresponding Author:

Email : fettyanggraeny.if@upnjatim.ac.id
Alamat : Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur 60294

This article is published under a Creative Commons Attribution 4.0 International License.



PENDAHULUAN

Teknologi penginderaan jarak jauh adalah teknologi yang memanfaatkan sensor untuk menangkap informasi gelombang elektromagnetik yang dipancarkan oleh objek dari jarak jauh. Informasi ini kemudian diolah menjadi gambar untuk tujuan pengamatan, pencitraan, dan analisis objek tersebut. Dengan bantuan teknologi ini, perangkat observasi di luar angkasa mampu melakukan deteksi dan pengenalan permukaan bumi dengan tingkat presisi yang tinggi. Gambar resolusi tinggi yang dihasilkan melalui penginderaan jarak jauh telah banyak dimanfaatkan dalam berbagai bidang, seperti perencanaan kota, eksplorasi sumber daya alam, hingga observasi untuk keperluan militer [1].

Namun, gambar yang dihasilkan selama proses penginderaan jarak jauh sering kali mengalami degradasi atau penurunan kualitas. Degradasi ini dapat disebabkan oleh berbagai faktor, diantaranya adalah gangguan atmosfer, aberasi pada sistem optik, getaran platform penginderaan (baik frekuensi tinggi maupun rendah), serta *noise* dari detektor dan perangkat elektronik pencitraan. Efek degradasi ini dapat memunculkan berbagai bentuk gangguan pada gambar, seperti keburaman, hilangnya detail penting, dan meningkatnya tingkat *noise* [1], [2].

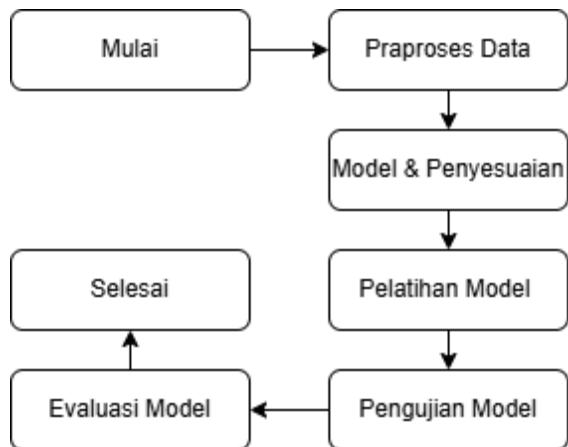
Untuk memperbaiki kualitas citra yang terdegradasi, penelitian ini mengusulkan model berbasis *Convolutional Neural Network (CNN)* dengan pendekatan *U-Net* untuk menghapus *noise* pada citra penginderaan jarak jauh. Meskipun awalnya dirancang untuk tugas segmentasi citra, struktur *encoder-decoder* dan *skip connection* pada *U-Net* terbukti efektif dalam menangani *noise*, sehingga mampu meningkatkan kualitas citra secara signifikan [3].

Dibandingkan dengan penelitian sebelumnya yang dilakukan oleh Pengfei Zhang dalam jurnal yang berjudul “*A method for remote sensing image restoration based on the system degradation model*”, metode yang digunakan dalam penelitian ini memiliki pendekatan yang berbeda untuk melakukan restorasi citra penginderaan jarak jauh. Penelitian sebelumnya menggunakan jaringan multi tahap *MARRNet* yang berfokus pada penghapusan keburaman dan peningkatan detail citra. Sementara itu, penelitian ini berfokus pada penghapusan *noise* sebagai langkah utama untuk meningkatkan kualitas citra.

METODE PENELITIAN

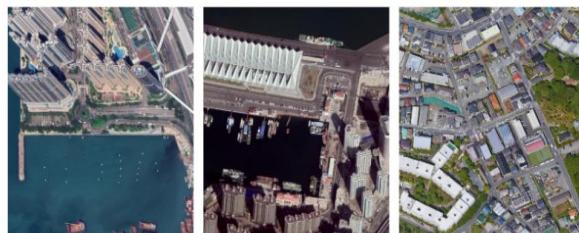
Pada bagian ini, kami menjelaskan metode yang digunakan untuk melakukan restorasi gambar pada citra penginderaan jarak jauh. Penjelasan mencakup deskripsi dataset, langkah-langkah pra-proses data, arsitektur model, fungsi kerugian (*loss function*), algoritma optimasi (*optimizer*), dan metrik pengujian. Selain itu, diagram alir penelitian ini disajikan pada Gambar 1 sebagai panduan alur kerja secara keseluruhan.

Dalam diagram alur tersebut, dijelaskan bahwa langkah pertama yang dilakukan adalah pra-proses data, yaitu menyiapkan dataset agar sesuai dengan kebutuhan model. Selanjutnya, model dilatih dengan penyesuaian parameter untuk mengoptimalkan kinerjanya. Proses ini diakhiri dengan evaluasi model menggunakan metrik *PSNR (Peak Signal-to-Noise Ratio)* dan *SSIM (Structural Similarity Index)* untuk mengukur kualitas hasil restorasi.



Gambar 1. Diagram Alur Penelitian

Sumber: Idris, 2023



Gambar 2. Contoh Citra pada Dataset FAIR1M

Dataset

Pada penelitian ini, kami menggunakan dataset *FAIR1M*, sebuah dataset citra penginderaan jarak jauh yang dirancang oleh Xian Sun dalam jurnal yang berjudul "*FAIR1M: A Benchmark Dataset for Fine-grained Object Recognition in High-Resolution Remote Sensing Imagery*". Dataset ini memiliki keragaman objek dan lokasi geografis, mencakup wilayah seperti Asia, Eropa, Amerika Utara, Cape Town, dan Sydney. Dataset ini terdiri dari 15.000 citra RGB beresolusi tinggi yang diambil oleh satelit *Gaofen (GF)* dan *Google Earth* [4]. Contoh citra dari dataset dapat dilihat pada Gambar 2.

Dataset *FAIR1M* memiliki resolusi spasial tinggi, yaitu 1024x1024 piksel per citra, dengan total lebih dari 1 juta instance objek. Keunggulan ini menjadikannya ideal untuk penelitian yang membutuhkan analisis mendalam, seperti restorasi citra penginderaan jarak jauh yang menjadi fokus utama penelitian ini. Dalam studi ini, kami memanfaatkan 12.000 citra yang dibagi menjadi 8.000 citra untuk pelatihan, serta masing-masing 2.000 citra untuk validasi dan pengujian.

Pra-Proses

Pada tahap ini, data citra dalam dataset dipersiapkan agar sesuai dengan kebutuhan model restorasi citra. Langkah pertama adalah mengonversi setiap citra ke format *grayscale* untuk mengurangi kompleksitas data, karena model yang digunakan bekerja secara khusus pada citra *grayscale*. Setelah itu, citra *grayscale* diubah ukurannya menjadi resolusi 256x256 piksel guna memastikan keseragaman dimensi antar data. Langkah berikutnya adalah menambahkan *noise* secara acak pada citra input dengan

tipe *gaussian*, *salt and pepper*, atau *speckle*. Penambahan *noise* ini bertujuan untuk mensimulasikan kondisi citra realistik di dunia nyata. Sementara itu, citra asli digunakan sebagai target atau *ground truth*. Data citra yang telah melalui tahap pra-proses ini kemudian siap digunakan untuk pelatihan dan pengujian model. Contoh citra hasil pra-proses dapat dilihat pada Gambar 3.

Arsitektur Model

U-Net adalah arsitektur jaringan saraf konvolusional (*Convolutional Neural Network*) yang awalnya dirancang khusus untuk tugas segmentasi citra [5]. Namun, berkat struktur *encoder-decoder* dan *skip connections* yang dimilikinya, *U-Net* mampu memanfaatkan informasi pada berbagai tingkat resolusi secara optimal, sehingga juga sangat efektif untuk tugas restorasi citra khususnya *denoising*. Selain itu, arsitektur *U-Net* dirancang untuk menangani pola-pola hierarkis yang kompleks dalam citra, memungkinkan penghapusan *noise* dengan tetap mempertahankan detail penting dalam gambar [6]. Penjelasan lebih rinci tentang arsitektur *U-Net* disajikan pada Gambar 4.

Pada implementasi ini, *U-Net* terdiri dari tiga komponen utama, yaitu *encoder*, *bottleneck*, dan *decoder*, yang terhubung melalui *skip connections* untuk mempertahankan informasi spasial pada setiap tingkat resolusi.

1. Encoder

Jalur *encoder* bertugas mengekstrak fitur dari citra input. Proses ini dilakukan melalui empat tahap konvolusi, masing-masing terdiri dari dua lapisan konvolusi 3x3, diikuti oleh operasi *Batch Normalization* dan *ReLU* sebagai fungsi aktivasi. Setelah setiap tahap konvolusi, resolusi data diperkecil menggunakan operasi *max pooling* 2x2 untuk mengurangi dimensi spasial. Fitur yang diekstraksi pada setiap tahap disimpan melalui mekanisme *skip connections* untuk digunakan pada jalur *decoder*. Pada tahap pertama, citra dengan resolusi awal diproses menjadi 64 saluran fitur. Resolusi kemudian terus berkurang secara bertahap, sementara jumlah saluran bertambah menjadi 128, 256, dan akhirnya 512 pada tahap keempat.

2. Bottleneck

Bagian *bottleneck* terletak di antara *encoder* dan *decoder*. Pada tahap ini, fitur dari resolusi terendah yang dihasilkan oleh *encoder* diproses lebih lanjut menggunakan lapisan konvolusi tambahan. Proses ini bertujuan untuk menangkap informasi global yang diperlukan untuk restorasi citra. Struktur *bottleneck* mencakup lapisan *max pooling* dan dua lapisan konvolusi ganda, menghasilkan fitur yang sangat terkompresi dengan dimensi spasial kecil namun mengandung informasi yang kaya.

3. Decoder

Jalur *decoder* bertugas untuk mengembalikan dimensi spasial citra ke ukuran aslinya, sambil memanfaatkan fitur dari jalur *encoder* melalui *skip connections*. Pada setiap langkah, data *di-upsample* menggunakan lapisan transpos konvolusi (*ConvTranspose2d*) untuk meningkatkan dimensi spasial. Fitur hasil *upsampling* digabungkan dengan fitur dari tahap *encoder* yang bersesuaian, memastikan bahwa detail penting tidak hilang selama proses pemrosesan. Setelah penggabungan, data diproses lebih lanjut melalui lapisan konvolusi ganda untuk menghasilkan fitur dengan resolusi tinggi.

4. Output Akhir

Lapisan terakhir *U-Net* menggunakan konvolusi 1x1 untuk menghasilkan citra output dengan jumlah saluran yang sesuai (1 saluran untuk gambar *grayscale*). Output ini merupakan citra hasil restorasi, dengan *noise* yang telah diminimalkan.

Loss Function dan Optimizer

Pada penelitian ini, *Mean Squared Error (MSE)* digunakan sebagai metrik untuk *loss function* karena mampu mengukur rata-rata kuadrat perbedaan nilai prediksi dengan *ground truth* (nilai sebenarnya) [7]. *Mean Squared Error (MSE)* dirumuskan sebagai:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

(1)

Dengan n merupakan jumlah sampel data, Y_i merupakan *ground truth* (nilai sebenarnya) untuk sampel ke-i, dan \hat{Y} merupakan nilai prediksi untuk sampel ke-i.

Dalam proses optimasinya, penelitian ini menggunakan Algoritma Adam, yaitu algoritma yang menentukan nilai parameter optimal dengan meminimalkan nilai *loss function*. Algoritma ini menggabungkan metode *Momentum* dan *RMSProp*, sehingga lebih stabil. Dengan memanfaatkan arah gradien sebelumnya, *Momentum* membantu mempercepat konvergensi, sementara *RMSProp* secara adaptif menyesuaikan *learning rate* untuk setiap parameter [8].

Algoritma Adam memiliki dua *hyperparameter* utama: β_1 , yang mengontrol *exponential moving average* dari gradien, dan β_2 , yang mengontrol *exponential moving average* dari kuadrat gradien.

Metrik Pengujian

Pada penelitian ini, proses pengujian dilakukan dengan menggunakan metrik Peak *Signal-to-Noise Ratio (PSNR)* dan *Structural Similarity Index Measure (SSIM)*. *PSNR* merupakan rasio antara kekuatan sinyal maksimum terhadap noise yang memengaruhi keakuratan data saat dikirimkan. Nilai *PSNR* dihitung berdasarkan *Mean Squared Error (MSE)* dan dinyatakan dalam satuan desibel (dB) [9]. Perhitungan *PSNR* didefinisikan sebagai berikut:

$$\begin{aligned} PSNR &= 10 \cdot 10 \log \left(\frac{maks_I^2}{MSE} \right) \\ &= 20 \cdot 10 \log \left(\frac{maks_I}{\sqrt{MSE}} \right) \\ &= 20 \cdot 10 \log(maks_I) - \\ &\quad 10 \cdot 10 \log(MSE) \end{aligned}$$

(2)

dengan $maks_I$ adalah nilai maksimum sinyal (puncak sinyal).

Dalam menilai perubahan struktur yang terjadi pada citra, *Structural Similarity Index Measure (SSIM)* digunakan sebagai metrik pengujian. *SSIM* mengevaluasi

kualitas gambar berdasarkan aspek struktur, kontras, dan luminansi, yang disesuaikan dengan persepsi visual manusia [10]. Perhitungan *SSIM* didefinisikan sebagai berikut:

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

(3)

dengan $\mu_x\mu_y$ adalah rata-rata luminasi gambar x dan y , σ_x^2, σ_y^2 merupakan variansi gambar x dan y , σ_{xy} merupakan kovarians antara x dan y , dan C_1, C_2 merupakan konstanta stabilitas.

HASIL DAN PEMBAHASAN

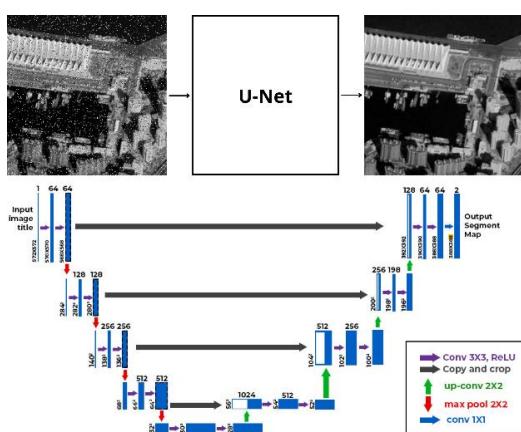
Evaluasi Proses Pelatihan

Pada penelitian ini, proses pelatihan digambarkan dengan *learning curves* yang menunjukkan perubahan *loss* model. *Learning curves* menunjukkan *epoch* berhubungan dengan nilai *loss* pada proses pelatihan. Penjelasan rinci terkait hubungan *epoch* dan nilai *loss* ditunjukkan pada Gambar 5.

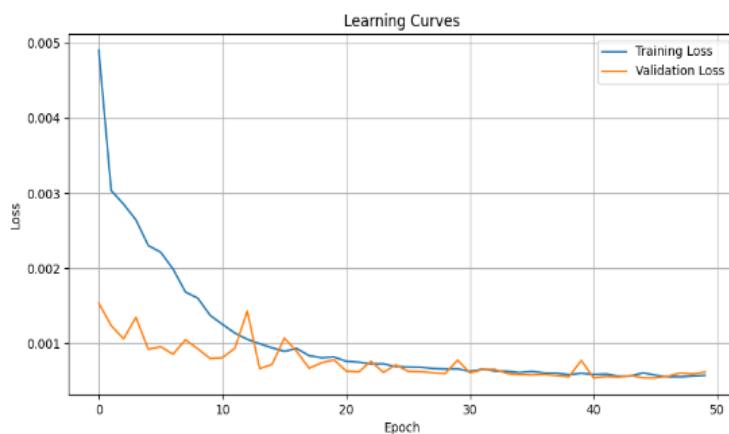
Grafik pada Gambar 5 menunjukkan bahwa pada tahapan awal, *training loss* menurun secara tajam, yang mengindikasikan bahwa model dengan cepat belajar dan menyesuaikan parameter untuk mengurangi *loss*. Setelah beberapa epoch, *training loss* mencapai nilai yang stabil dan sangat rendah, menunjukkan bahwa model mampu mengoptimalkan diri pada data pelatihan dengan baik.



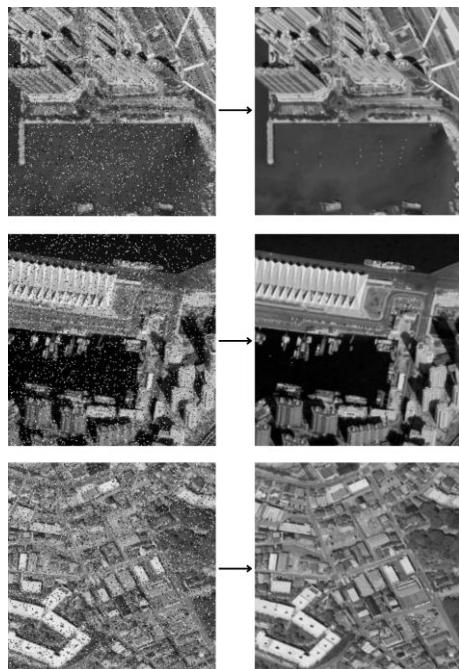
Gambar 3. Contoh Citra yang Melalui Tahap Pra-Proses



Gambar 4. Arsitektur U-Net
Sumber: GeeksForGeeks, 2023



Gambar 5. Hasil Proses Pelatihan



Gambar 6. Hasil Sebelum dan Sesudah Restorasi Citra

Pada tahapan awal, *validation loss* tidak menurun secepat *training loss*. Namun, meskipun terdapat indikasi *overfitting*, model masih berfungsi dengan baik. *Overfitting* ini terjadi karena model terlalu menyesuaikan diri pada data pelatihan sehingga kurang fleksibel dalam memproses data validasi baru.

Hasil Restorasi Citra

Proses peningkatan kualitas citra melibatkan beberapa langkah penting, terutama dalam tahap restorasi citra. Restorasi ini bertujuan untuk memperbaiki kualitas citra yang terpengaruh oleh *noise*, sehingga menghasilkan citra yang lebih detail dan jelas. Melalui proses restorasi, kualitas citra dapat ditingkatkan secara signifikan dengan hasil yang memuaskan. Perbandingan antara citra sebelum dan sesudah diproses dapat dilihat lebih jelas pada Gambar 6.

Tabel 1
Sampel Pengujian

Gambar	PSNR	SSIM
1	44.49	0.984
2	42.71	0.992
3	38.93	0.988
4	38.02	0.971
5	39.58	0.985
6	39.19	0.983
7	39.08	0.982
8	42.73	0.985
9	37.02	0.984
10	33.22	0.975

Sumber: Data Diolah

Pada Gambar 6 menunjukkan hasil perbandingan pada citra terdegradasi oleh *noise* dengan citra yang sudah melalui proses restorasi. Pada gambar sebelah kiri, terdapat adanya *noise* yang mempengaruhi kualitas citra, sehingga detail citra terlihat blur dan terganggu. Melalui proses restorasi, citra yang mengalami degradasi berhasil diperbaiki, dapat dilihat pada gambar sebelah kanan. Perbedaan kualitas citra sangat mencolok karena hasil citra hasil restorasi lebih jelas sehingga menunjukkan perbaikan detail dan pengurangan *noise* yang signifikan.

Pengujian

Pada pengujian yang telah dilakukan, *PSNR* (*Peak Signal-to-Noise Ratio*) dan *SSIM* (*Structural Similarity Index*) digunakan sebagai metrik untuk mengevaluasi performa model restorasi citra. Sampel hasil pengujian disajikan pada Tabel 1. Tabel 1 menyajikan hasil pengujian 10 sampel citra dari 2.000 data pengujian. Nilai rata-rata *PSNR* adalah 39,78 dB, sedangkan nilai rata-rata *SSIM* adalah 0,981. Hal ini menunjukkan bahwa model *U-Net* memiliki performa yang sangat baik dalam mengurangi noise sekaligus memperbaiki kualitas citra.

Nilai *PSNR* menggambarkan rasio antara sinyal citra dan *noise*, di mana semakin tinggi nilainya, semakin baik kualitas citra yang dihasilkan. Sementara itu, nilai *SSIM* mengukur kesamaan struktur antara citra hasil restorasi dengan citra asli. Pada Tabel 1, nilai *PSNR* berkisar antara 33 hingga 44 dB, yang termasuk tinggi, menunjukkan kualitas restorasi citra yang baik. Nilai *SSIM* yang mendekati 1 menunjukkan bahwa struktur citra hasil restorasi sangat mirip dengan citra aslinya.

SIMPULAN

Penelitian ini berhasil menunjukkan kemampuan Model *U-Net* yang sangat efektif dalam melakukan restorasi citra penginderaan jarak jauh yang mengalami degradasi akibat *noise*. Melalui tahapan pra-pemrosesan hingga pengujian menggunakan metrik *PSNR* dan *SSIM*, pengurangan *noise* terbukti sangat signifikan, sehingga kualitas citra meningkat secara efektif. Performa restorasi citra yang baik ditunjukkan oleh nilai rata-rata *PSNR* sebesar 39,78 dB dan nilai rata-rata *SSIM* sebesar 0,981. Hasil restorasi ini menunjukkan kesamaan struktur yang tinggi dengan citra asli, sekaligus menghasilkan detail yang lebih jelas.

DAFTAR PUSTAKA

- [1] Zhang, P., Gong, J., Jiang, S., Shi, T., Yang, J., Bao, G., & Zhi, X. (2024). A method for remote sensing image restoration based on the system degradation model. *Results in Physics*, 56. <https://doi.org/10.1016/j.rinp.2023.107262>
- [2] Zakaria, A. I., Ernawati, E., Vatresia, A., & Oktoeberza, W. K. (2019). Perbandingan Metode High-Frequency Emphasis (HFE) Dan Contrast Limited Adaptive Histogram Equalization (CLAHE) Dalam Perbaikan Kualitas Citra Penginderaan Jauh (Remote Sensing). *Pseudocode*, 6(2), 125–137. <https://doi.org/10.33369/pseudocode.6.2.125-137>
- [3] Dua, P. (2019). *Image Denoising Using a U-net*. <https://api.semanticscholar.org/CorpusID:212684125>
- [4] Sun, X., Wang, P., Yan, Z., Xu, F., Wang, R., Diao, W., Chen, J., Li, J., Feng, Y., Xu, T., Weinmann, M., Hinz, S., Wang, C., & Fu, K. (2021). FAIR1M: A Benchmark Dataset for Fine-grained Object Recognition in High-Resolution Remote Sensing Imagery. <http://arxiv.org/abs/2103.05569>
- [5] Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V. (2021). U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications. *IEEE Access*, 9, 82031–82057. <https://doi.org/10.1109/ACCESS.2021.3086020>
- [6] Mei, S. (2024). *U-Nets as Belief Propagation: Efficient Classification, Denoising, and Diffusion in Generative Hierarchical Models*. <http://arxiv.org/abs/2404.18444>
- [7] Beheshti, S., Hashemi, M., Sejdić, E., & Chau, T. (2011). Mean square error estimation in thresholding. *IEEE Signal Processing Letters*, 18(2), 103–106. <https://doi.org/10.1109/LSP.2010.2097590>
- [8] Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. <https://arxiv.org/abs/1412.6980>
- [9] Nawansari, M. (2022). Kinerja Penapisan Gaussian dan Median Dalam Pelembutan Citra. *Journal of Information Technology*, 2, 1–4. <https://doi.org/10.46229/jifotech.v2i2.433>
- [10] Omara, A. N., Salem, T. M., Elsanadily, S., & Elsherbini, M. M. (2022). SSIM-based sparse image restoration. *Journal of King Saud University - Computer and Information Sciences*, 34(8, Part B), 6243–6254. <https://doi.org/https://doi.org/10.1016/j.jksuci.2021.07.024>
- [11] GeeksForGeeks. (2023). *U-Net Architecture Explained*. <https://www.geeksforgeeks.org/u-net-architecture-explained/>
- [12] Idris, M., Anggraeny, F. T., & Mumpuni, R. (2023). IDENTIFIKASI KANKER PARU-PARU PADA GAMBAR HISTOPATOLOGI MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. *Scan : Jurnal Teknologi Informasi Dan Komunikasi*, 18(3). <https://doi.org/10.33005/scan.v18i3.4728>