



Penerapan *Deep Convolutional Autoencoder* dengan *Skip Connection* untuk Menghilangkan Derau pada Citra Digital

Martha Richa Anggraeni^{1*}, Bagus Satrio Waluyo Poetro²

¹⁻²Program Studi Teknik Informatika, Universitas Islam Sultan Agung, Indonesia

Email: marthaicha92@gmail.com^{1*}, bagusswp@unissula.ac.id²

*Penulis Korespondensi: marthaicha92@gmail.com

Abstract. *Digital images often experience noise disturbances that can reduce visual quality and interfere with the image analysis process. One common type of noise is salt and pepper noise, especially in grayscale images, which is characterized by the random appearance of black and white dots. This study applied the Deep Convolutional Autoencoder (DCAE) method with a skip connection mechanism to eliminate salt and pepper noise in grayscale images measuring 256×256 pixels. The dataset used consists of 300 pairs of clean images and noisy images that have gone through the preprocessing stage, including normalization and data augmentation. The model was trained using an Adam optimizer with a Mean Squared Error (MSE) loss function and validated through a train-test split scheme to avoid overfitting. Model performance was evaluated using Peak Signal-to-Noise Ratio (PSNR) and Structural Similarity Index (SSIM) metrics. The test results showed that the DCAE model with skip connections was able to effectively reduce noise while maintaining the main structure of the image based on the PSNR and SSIM values obtained, and showed better performance than conventional median filters. In addition, the model was successfully implemented into a Streamlit-based application to perform the image denoising process interactively, making it easier for users to experiment and visualize results in real-time.*

Keywords: *Auto-Encoder; Deep Learning; Image Processing; Noise Elimination; Streamlit.*

Abstrak. Citra digital sering mengalami gangguan derau yang dapat menurunkan kualitas visual dan mengganggu proses analisis citra. Salah satu jenis derau yang umum dijumpai adalah derau *salt and pepper*, khususnya pada citra grayscale, yang ditandai dengan munculnya titik-titik hitam dan putih secara acak. Penelitian ini menerapkan metode *Deep Convolutional Autoencoder* (DCAE) dengan mekanisme skip connection untuk menghilangkan derau *salt and pepper* pada citra grayscale berukuran 256×256 piksel. Dataset yang digunakan terdiri dari 300 pasangan citra bersih dan citra berderau yang telah melalui tahap preprocessing, termasuk normalisasi dan augmentasi data. Model dilatih menggunakan optimizer Adam dengan fungsi loss Mean Squared Error (MSE) serta divalidasi melalui skema train-test split untuk menghindari overfitting. Kinerja model dievaluasi menggunakan metrik *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index* (SSIM). Hasil pengujian menunjukkan bahwa model DCAE dengan *skip connection* mampu mengurangi derau secara efektif serta tetap mempertahankan struktur utama citra berdasarkan nilai PSNR dan SSIM yang diperoleh, dan menunjukkan performa lebih baik dibandingkan filter median konvensional. Selain itu, model berhasil diimplementasikan ke dalam aplikasi berbasis Streamlit untuk melakukan proses denoising citra secara interaktif, sehingga mempermudah pengguna dalam melakukan eksperimen dan visualisasi hasil secara *real-time*.

Kata kunci: *Autoencoder; Pembelajaran Mendalam; Penghilangan Derau; Pengolahan Citra; Streamlit.*

1. LATAR BELAKANG

Perkembangan di bidang teknologi informasi serta sistem berbasis komputer telah mendorong pemanfaatan citra digital secara luas pada beragam bidang, termasuk sektor kesehatan serta keamanan, dokumentasi digital, hingga sistem berbasis kecerdasan buatan. Dalam berbagai aplikasi tersebut, citra digital berperan sebagai sumber utama informasi visual yang selanjutnya dianalisis untuk mendukung proses pengambilan keputusan. Oleh karena itu, kualitas citra menjadi faktor yang sangat penting, karena citra dengan kualitas rendah dapat

menurunkan akurasi sistem dan berpotensi menimbulkan kesalahan dalam proses analisis visual (Gunadi dkk., 2020).

Dalam penerapannya, citra yang diperoleh dari perangkat akuisisi seperti kamera atau sensor digital sering kali mengalami gangguan yang menyebabkan penurunan kualitas visual. Salah satu bentuk gangguan yang umum dijumpai adalah derau, yaitu perubahan nilai intensitas piksel yang muncul secara acak dan tidak mencerminkan kondisi sebenarnya dari objek pada citra. Keberadaan derau dapat mengaburkan detail visual, merusak struktur citra, serta menyulitkan proses pengolahan citra lanjutan, terutama pada sistem yang menuntut tingkat ketelitian yang tinggi.

Derau *salt and pepper* merupakan salah satu jenis gangguan yang umum dijumpai pada citra digital. Derau ini ditandai dengan kemunculan titik-titik terang dan gelap yang tersebar secara acak di seluruh bagian citra. Gangguan tersebut umumnya disebabkan oleh kesalahan pada proses transmisi data, gangguan sinyal, maupun keterbatasan sensor saat proses akuisisi citra. Keberadaan derau *salt-and-pepper* dapat menghilangkan detail halus seperti tepi dan tekstur objek, sehingga objek pada citra menjadi sulit dikenali dan berdampak pada penurunan kinerja sistem pengolahan citra secara keseluruhan (Jiang dkk., 2022)

Untuk mengatasi permasalahan tersebut, berbagai metode penghilangan derau berbasis filter telah banyak digunakan, antara lain *median filter*, *mean filter*, dan *Gaussian filter*. Meskipun metode-metode tersebut relatif sederhana dan mudah diterapkan, hasil pengolahan yang diperoleh sering kali menimbulkan efek penghalusan yang berlebihan. Akibatnya, detail penting pada citra turut terhapus, terutama pada area yang memiliki struktur visual kompleks. Kondisi tersebut mengindikasikan bahwa pendekatan konvensional masih mempunyai sejumlah keterbatasan dalam menangani derau secara efektif, khususnya pada tingkat derau yang cukup tinggi (Sugandi, 2023).

Seiring dengan kemajuan teknologi komputasi, pendekatan berbasis *deep learning* mulai banyak diterapkan dalam bidang restorasi citra. Kondisi tersebut memungkinkan model mempelajari hubungan yang terdapat antara citra berderau dan citra bersih secara langsung melalui proses pembelajaran berbasis data. Salah satu arsitektur yang sering digunakan adalah *Convolutional Autoencoder* (CAE), karena mampu mengekstraksi fitur-fitur penting citra melalui proses *encoder* dan merekonstruksi kembali citra melalui proses *decoder*. Pendekatan ini dinilai lebih adaptif dibandingkan metode konvensional dalam mengatasi berbagai jenis gangguan pada citra digital (Chandra & Anuradha, 2022)

Namun demikian, *autoencoder* konvensional masih memiliki keterbatasan dalam mempertahankan informasi detail citra akibat proses kompresi pada tahap *encoding*. Hilangnya informasi resolusi tinggi selama proses tersebut dapat menyebabkan citra hasil rekonstruksi menjadi kurang tajam dan tidak sepenuhnya merepresentasikan citra aslinya. Untuk mengatasi permasalahan ini, mekanisme *skip connection* diperkenalkan sebagai penghubung langsung antara lapisan *encoder* dan *decoder*. Dengan adanya *skip connection*, informasi penting dari lapisan awal jaringan dapat diteruskan hingga tahap rekonstruksi, sehingga kualitas citra hasil restorasi dapat ditingkatkan (Bhute dkk., 2024).

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penerapan *Deep Convolutional Autoencoder* (DCAE) dengan mekanisme *skip connection* untuk melakukan penghilangan derau *salt-and-pepper* pada citra *grayscale* berukuran 256×256 piksel. Selain perancangan dan pelatihan model, penelitian ini juga mengembangkan aplikasi berbasis *Streamlit* yang memungkinkan pengguna mengunggah citra berderau, menampilkan hasil restorasi citra, membandingkannya dengan citra bersih, serta memperoleh nilai evaluasi berupa PSNR dan SSIM secara otomatis. Diharapkan pendekatan ini mampu menghasilkan metode penghilangan derau yang tidak hanya efektif secara visual dan kuantitatif, tetapi juga mudah digunakan dalam praktik pengolahan citra digital.

2. KAJIAN TEORITIS

Citra Digital

Citra digital merupakan gambar dari objek nyata yang disimpan dan diolah dalam bentuk data numerik sehingga dapat diproses oleh komputer. Citra digital tersusun dari piksel yang masing-masing memiliki nilai terang-gelap, dan kumpulan piksel tersebut membentuk gambar utuh. Dalam sistem komputer, citra digital disimpan dalam bentuk matriks dua dimensi, terutama pada citra *grayscale*, sehingga memudahkan proses pengolahan. Citra digital memiliki peranan penting dalam berbagai bidang seperti kesehatan, keamanan, industri, pertanian, dan arsip digital, di mana keberhasilan penggunaannya sangat bergantung pada kualitas citra (Idris dkk., 2023). Kualitas citra dapat menurun akibat gangguan pada nilai piksel, sehingga diperlukan proses perbaikan citra untuk mendukung pengolahan lanjutan, khususnya pada penelitian yang berfokus pada pengurangan derau.

Jenis-Jenis Citra

Citra digital dibedakan berdasarkan jumlah informasi dan cara penyimpanannya, yang memengaruhi metode pengolahan dan kebutuhan komputasi. Citra biner merupakan citra paling sederhana dengan dua nilai piksel dan umum digunakan untuk pemisahan objek, namun

tidak mampu menampilkan detail. Citra *grayscale* menggunakan satu kanal terang–gelap, memiliki struktur data sederhana, efisien secara komputasi, dan efektif menampilkan bentuk serta pola objek, sehingga banyak digunakan pada analisis dan pengurangan derau. Citra RGB terdiri dari tiga kanal warna (*red, green, blue*) dan kaya informasi warna, namun memiliki kompleksitas komputasi lebih tinggi. Oleh karena itu, citra *grayscale* dipilih dalam penelitian ini karena paling sesuai untuk perbaikan kualitas citra dan pengurangan derau berbasis struktur terang–gelap.

Derau pada Citra Digital

Derau merupakan gangguan acak yang mengubah nilai piksel dan menyebabkan penurunan kualitas citra sehingga informasi visual sulit dianalisis. Derau dapat muncul pada tahap pengambilan, penyimpanan, maupun pengiriman citra. Untuk mengurangi derau dan meningkatkan kualitas visual citra, berbagai metode filtering seperti Gaussian filter dan median filter telah banyak diterapkan dalam pengolahan citra digital karena terbukti efektif dalam mereduksi gangguan derau serta mempermudah analisis lebih lanjut (Fauzi, 2022; Salsabilla & Ayu Saputri, 2026). Salah satu jenis derau yang sering dijumpai adalah derau *salt and pepper*, yaitu derau impulsif yang tampak sebagai titik hitam dan putih acak pada citra *grayscale*. Derau ini merusak detail lokal seperti tepi dan tekstur objek sehingga menyulitkan proses analisis. Metode konvensional seperti *mean filter*, *Gaussian filter*, dan *median filter* digunakan untuk mengurangi derau, namun sering menyebabkan citra terlalu halus dan kehilangan detail. Oleh karena itu, pendekatan berbasis *deep learning* mulai digunakan karena mampu mempelajari pola derau dan struktur citra secara langsung dari data.

Denoising Citra

Denoising citra merupakan proses untuk memperbaiki kualitas citra yang menurun akibat derau atau gangguan lain agar mendekati kondisi aslinya. Berbeda dengan peningkatan citra berbasis persepsi visual, denoising berfokus pada restorasi citra secara sistematis berdasarkan karakteristik gangguan. Metode konvensional berbasis filter relatif mudah diterapkan, namun kurang optimal pada derau tinggi karena menghilangkan detail penting. Pendekatan *deep learning* memungkinkan model mempelajari hubungan antara citra berderau dan citra bersih secara langsung. Salah satu pendekatan yang banyak digunakan adalah *Deep Convolutional Autoencoder (DCAE)*, yang mampu mempertahankan hubungan antar piksel dan menghasilkan citra rekonstruksi yang lebih mendekati citra asli (Fauzi, 2022). Dalam penelitian ini, denoising difokuskan pada penghilangan derau *salt and pepper* pada citra *grayscale*.

Deep Learning

Deep learning merupakan pendekatan pembelajaran mesin berbasis jaringan saraf tiruan berlapis yang mampu mempelajari pola data secara otomatis tanpa perancangan fitur manual. Pada pengolahan citra, *deep learning* digunakan untuk pengenalan pola, deteksi objek, dan perbaikan kualitas citra. Keunggulan *deep learning* terletak pada kemampuannya mempelajari hubungan kompleks antara citra berderau dan citra bersih secara langsung dari data. Pendekatan ini dinilai lebih fleksibel dibandingkan metode konvensional karena tidak bergantung pada asumsi tertentu mengenai jenis derau, meskipun membutuhkan data dan sumber daya komputasi yang memadai.

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan jaringan saraf tiruan yang dirancang untuk mengolah data berbentuk grid seperti citra digital dan mampu mengekstraksi fitur visual secara otomatis (Venkataraman, 2022). CNN memanfaatkan hubungan lokal antar piksel melalui lapisan konvolusi, pooling, dan *fully connected*. Lapisan konvolusi mengekstraksi fitur dari tingkat sederhana hingga kompleks, sementara pooling mengurangi ukuran data dan meningkatkan efisiensi. CNN banyak digunakan dalam klasifikasi, deteksi objek, serta perbaikan kualitas citra, termasuk denoising. Dalam penelitian ini, CNN menjadi dasar pengembangan arsitektur *Autoencoder* dan *Deep Convolutional Autoencoder (DCAE)*.

Autoencoder

Autoencoder merupakan jaringan saraf tiruan yang dirancang untuk merekonstruksi kembali data masukan melalui proses encoding dan decoding. Model ini bekerja dengan memampatkan data ke dalam *latent space* untuk menyimpan informasi penting dan mengabaikan bagian yang kurang relevan, sehingga termasuk pendekatan *unsupervised learning*. Dalam pengolahan citra, *Autoencoder* digunakan untuk kompresi, ekstraksi fitur, dan denoising. Proses rekonstruksi dievaluasi menggunakan fungsi *loss* seperti *Mean Squared Error (MSE)*, di mana nilai MSE yang kecil menunjukkan kemiripan tinggi antara citra asli dan citra rekonstruksi. Namun, *Autoencoder* berbasis *fully connected* memiliki keterbatasan dalam mempertahankan hubungan spasial antar piksel, sehingga dikembangkan arsitektur berbasis konvolusi.

Deep Convolutional Autoencoder (DCAE)

Deep Convolutional Autoencoder (DCAE) merupakan pengembangan *Autoencoder* yang menggunakan operasi konvolusi pada encoder dan decoder untuk mempertahankan hubungan spasial antar piksel. Encoder mengekstraksi fitur dan menekan komponen derau, sedangkan decoder merekonstruksi citra dari representasi laten menggunakan *upsampling* atau

transposed convolution. DCAE dilatih secara *end-to-end* menggunakan pasangan citra berderau dan citra bersih sehingga mampu mempelajari pemetaan derau secara langsung. Dibandingkan metode konvensional, DCAE lebih efektif dalam mempertahankan detail citra dan menghasilkan rekonstruksi yang lebih alami.

Skip Connection

Skip connection merupakan mekanisme yang menghubungkan langsung lapisan encoder dan decoder pada tingkat kedalaman yang sama untuk mencegah hilangnya detail selama proses *downsampling*. Mekanisme ini memungkinkan informasi awal diteruskan langsung ke lapisan akhir sehingga detail spasial tetap terjaga. Konsep *skip connection* dinyatakan dengan persamaan $y = F(x) + x$, yang menunjukkan bahwa informasi awal ditambahkan kembali ke hasil transformasi. Dalam konteks DCAE, *skip connection* berperan penting untuk mempertahankan detail citra yang terpengaruh derau *salt and pepper* serta menstabilkan proses pelatihan jaringan.

Metrik Evaluasi: PSNR dan SSIM

Evaluasi kualitas hasil denoising dilakukan menggunakan *Peak Signal-to-Noise Ratio (PSNR)* dan *Structural Similarity Index Measure (SSIM)*. PSNR mengukur tingkat kesalahan nilai piksel berdasarkan *Mean Squared Error (MSE)*, di mana nilai PSNR yang lebih tinggi menunjukkan kualitas rekonstruksi yang lebih baik. SSIM menilai kesamaan struktur visual, kecerahan, dan kontras citra berdasarkan persepsi visual manusia, dengan nilai mendekati 1 menunjukkan kemiripan struktur yang tinggi. Penggunaan PSNR dan SSIM secara bersamaan memberikan evaluasi yang lebih menyeluruh, baik secara numerik maupun visual, terhadap kualitas citra hasil denoising.

3. METODE PENELITIAN

Penelitian ini menggunakan metode penelitian *experimental research* untuk menguji kinerja model *Deep Convolutional Autoencoder (DCAE)* dengan mekanisme *skip connection* dalam menghilangkan derau *salt and pepper* pada citra *grayscale*. Penelitian dilaksanakan pada data citra digital yang bersumber dari dataset publik dan diolah selama periode pengembangan dan pengujian model, dengan objek penelitian berupa pasangan citra bersih (*clean image*) dan citra berderau (*noisy image*). Data yang digunakan dibagi menjadi data latih dan data uji dengan perbandingan 80% dan 20%. Instrumen penelitian berupa model DCAE berbasis *deep learning* yang dirancang untuk proses denoising citra. Teknik pengumpulan data dilakukan melalui pengunduhan dataset publik yang menyediakan pasangan citra bersih dan citra berderau secara *supervised*. Data kemudian melalui tahapan *preprocessing* meliputi penyesuaian ukuran citra

menjadi 256×256 piksel, normalisasi nilai piksel ke rentang 0–1, serta penyesuaian dimensi kanal. Teknik analisis data dilakukan melalui proses pelatihan dan pengujian model menggunakan *optimizer Adam*, dengan evaluasi performa model berdasarkan metrik *Peak Signal to Noise Ratio (PSNR)* dan *Structural Similarity Index (SSIM)* untuk menilai kualitas numerik dan kesamaan struktur visual citra hasil denoising.

4. HASIL DAN PEMBAHASAN

Hasil Pengumpulan Data



Gambar 1. Contoh Pasangan Citra bersih dan citra derau.

Gambar 1 menampilkan contoh pasangan citra bersih dan citra yang terkontaminasi derau salt and pepper yang digunakan dalam penelitian ini. Setiap pasangan terdiri atas citra bersih sebagai acuan (*ground truth*) dan citra berderau sebagai data masukan. Derau muncul dalam bentuk titik-titik terang dan gelap yang tersebar secara acak sehingga menyebabkan penurunan kualitas visual serta berkurangnya kejelasan detail objek pada citra.

Dataset yang digunakan diperoleh dari platform Kaggle dan terdiri atas 300 pasangan citra grayscale. Setiap pasangan memiliki dimensi dan konten visual yang identik sehingga dapat dimanfaatkan secara langsung dalam proses pelatihan model. Variasi objek pada dataset mencakup wajah manusia, hewan, serta berbagai objek umum lainnya. Keberagaman tersebut

bertujuan untuk meningkatkan kemampuan generalisasi model agar tidak terbatas pada satu jenis citra tertentu.

Derau pada dataset merupakan derau impulsif salt and pepper dengan pola sebaran yang relatif merata. Penelitian ini tidak melakukan pengelompokan berdasarkan tingkat intensitas derau tertentu, melainkan berfokus pada kemampuan model dalam mempelajari karakteristik derau secara umum serta melakukan proses restorasi citra secara menyeluruh.

Seluruh citra diseragamkan menjadi ukuran 256×256 piksel untuk menyesuaikan kebutuhan masukan model Deep Convolutional Autoencoder. Penyeragaman dimensi ini bertujuan menjaga konsistensi data sehingga proses pelatihan dan evaluasi dapat berlangsung secara stabil. Dataset selanjutnya dibagi menjadi data latih dan data uji untuk mendukung proses pembelajaran serta pengujian kinerja model.

Pemilihan dataset dari Kaggle didasarkan pada kemudahan akses, kesesuaian karakteristik data dengan tujuan penelitian, serta penggunaannya pada beberapa penelitian sebelumnya sehingga memungkinkan perbandingan hasil secara objektif. Jumlah data sebanyak 300 pasangan citra dinilai memadai untuk merepresentasikan karakteristik derau pada citra grayscale dengan tetap mempertimbangkan keterbatasan sumber daya komputasi. Dataset ini menjadi dasar utama pada seluruh tahapan penelitian, mulai dari preprocessing, pelatihan, evaluasi kinerja menggunakan PSNR dan SSIM, hingga tahap implementasi sistem.

Hasil Preprocessing Data

Pada tahap preprocessing dilakukan sebelum data digunakan pada proses pelatihan dan evaluasi model. Tahapan ini bertujuan untuk memastikan seluruh citra memiliki karakteristik yang seragam sehingga dapat diproses secara optimal oleh model Deep Convolutional Autoencoder. Tanpa preprocessing yang memadai, perbedaan skala dan dimensi citra berpotensi menyebabkan ketidakstabilan selama proses pembelajaran serta menurunkan kinerja model.

Dataset pada penelitian ini telah tersedia dalam format grayscale sehingga tidak diperlukan proses konversi warna. Penggunaan citra satu kanal dipilih karena tugas denoising impulsif berfokus pada pemulihan intensitas piksel, sehingga penyederhanaan kanal warna dapat meningkatkan efisiensi komputasi sekaligus mempermudah proses pembelajaran model.

Langkah utama preprocessing meliputi penyeragaman ukuran citra menjadi 256×256 piksel. Dimensi yang konsisten memungkinkan seluruh data diproses secara seragam oleh jaringan saraf tanpa memerlukan penyesuaian tambahan. Pemilihan ukuran tersebut mempertimbangkan keseimbangan antara kualitas visual citra dan efisiensi komputasi, sehingga detail penting tetap terjaga tanpa meningkatkan beban pelatihan secara berlebihan.

Selain itu, dilakukan normalisasi nilai piksel untuk menyamakan rentang intensitas pada seluruh citra. Normalisasi berperan dalam meningkatkan stabilitas proses pelatihan serta mempercepat konvergensi model, karena perbedaan skala nilai piksel dapat memengaruhi pembaruan bobot jaringan saraf. Dengan distribusi nilai yang lebih seragam, model dapat lebih fokus mempelajari pola derau dibandingkan menyesuaikan variasi skala data.

Secara keseluruhan, tahap preprocessing menghasilkan pasangan citra bersih dan citra berderau dengan dimensi serta rentang intensitas yang konsisten. Data yang telah diproses tersebut selanjutnya digunakan sebagai data masukan dan target pada proses pelatihan model Deep Convolutional Autoencoder.

Hasil Pemodelan

Tahap pemodelan merupakan bagian inti dalam penelitian ini karena pada tahap inilah model Deep Convolutional Autoencoder (DCAE) dilatih untuk mempelajari pola gangguan derau impulsif salt and pepper serta menghasilkan citra hasil rekonstruksi yang mendekati citra bersih. Proses pemodelan dilakukan menggunakan data yang telah melalui tahap preprocessing sehingga seluruh citra memiliki ukuran dan rentang nilai piksel yang seragam. Kondisi data yang seragam ini bertujuan untuk memastikan proses pelatihan berjalan secara stabil dan konsisten.

Proses pemodelan diawali dengan pelatihan model menggunakan pasangan citra berderau sebagai data masukan dan citra bersih sebagai target keluaran. Pendekatan ini memungkinkan model mempelajari hubungan langsung antara citra yang terkontaminasi derau dan citra acuan yang bersih. Dengan skema tersebut, model diharapkan mampu mengurangi derau tanpa menghilangkan struktur utama citra.

Fungsi loss yang digunakan pada proses pelatihan adalah Mean Squared Error (MSE). Fungsi loss ini digunakan untuk mengukur selisih antara citra hasil rekonstruksi dengan citra bersih pada tingkat piksel. Semakin kecil nilai MSE yang dihasilkan, semakin mendekati citra hasil rekonstruksi terhadap citra bersih. Penggunaan MSE dinilai sesuai untuk tugas denoising karena mampu merepresentasikan perbedaan intensitas piksel secara langsung dan sensitif terhadap keberadaan derau.


Optimizer yang digunakan dalam pelatihan model adalah Adam dengan nilai learning rate sebesar 0,001. Optimizer ini dipilih karena mampu melakukan pembaruan bobot secara adaptif, sehingga proses pelatihan dapat berjalan lebih stabil. Dengan nilai learning rate tersebut, model dapat mempelajari pola derau secara bertahap tanpa mengalami perubahan bobot yang terlalu drastis.

Proses pelatihan dilakukan selama sejumlah epoch agar model memiliki cukup waktu untuk mempelajari karakteristik derau dan struktur citra. Pada epoch awal, model mulai mempelajari pola dasar derau salt and pepper yang tersebar secara acak pada citra. Hal ini ditandai dengan penurunan nilai loss yang cukup signifikan pada tahap awal pelatihan, yang menunjukkan bahwa model mampu menyesuaikan bobot awal dengan cepat.

Seiring bertambahnya jumlah epoch, penurunan nilai loss berlangsung lebih lambat dan cenderung stabil. Kondisi ini menunjukkan bahwa model telah mulai memahami struktur citra dan pola derau secara lebih mendalam. Pada tahap ini, pembaruan bobot jaringan saraf tidak lagi menghasilkan perubahan nilai loss yang besar karena model mendekati kondisi konvergen.

Perbandingan antara nilai training loss dan validation loss juga menjadi indikator penting dalam proses pemodelan. Berdasarkan hasil pelatihan, nilai training loss dan validation loss menunjukkan pola penurunan yang searah dan tidak memperlihatkan perbedaan yang mencolok. Hal ini mengindikasikan bahwa model tidak mengalami overfitting secara signifikan serta masih mampu mempertahankan kemampuan generalisasi terhadap data validasi.

Untuk menjaga performa model selama proses pelatihan, digunakan mekanisme Early Stopping dan Model Checkpoint. Early Stopping berfungsi untuk menghentikan proses pelatihan apabila tidak terjadi peningkatan performa pada data validasi dalam beberapa epoch berturut-turut, sehingga dapat mencegah pelatihan yang berlebihan. Sementara itu, Model Checkpoint digunakan untuk menyimpan bobot model terbaik selama proses pelatihan berlangsung. Dengan mekanisme ini, model yang digunakan pada tahap evaluasi merupakan model dengan performa paling optimal.



Gambar 2. Grafik Perkembangan Training Loss dan Validation Loss.

Pada Gambar 2 ditunjukkan grafik perkembangan nilai training loss dan validation loss selama proses pelatihan model Deep Convolutional Autoencoder. Pada beberapa epoch awal terlihat penurunan nilai loss yang cukup tajam, yang menunjukkan bahwa model mampu dengan cepat mempelajari pola dasar derau impulsif pada citra. Penurunan ini mengindikasikan bahwa proses pembelajaran pada tahap awal berjalan efektif.

Seiring bertambahnya jumlah epoch, penurunan nilai training loss dan validation loss berlangsung lebih bertahap hingga mencapai kondisi yang relatif stabil. Pola ini menunjukkan bahwa model telah mendekati kondisi konvergen, di mana pembaruan bobot jaringan saraf tidak lagi menghasilkan perubahan nilai loss yang signifikan. Selain itu, pergerakan training loss dan validation loss yang cenderung sejalan menandakan bahwa model tidak mengalami overfitting secara signifikan selama proses pelatihan.


Hasil Evaluasi

Tahap evaluasi dilakukan untuk menilai kinerja model Deep Convolutional Autoencoder dalam melakukan restorasi citra berderau. Evaluasi bertujuan untuk mengukur kemampuan model dalam mereduksi derau sekaligus mempertahankan kualitas visual serta struktur citra hasil rekonstruksi. Pengujian dilakukan menggunakan data uji yang tidak terlibat pada proses pelatihan sehingga hasil yang diperoleh merepresentasikan kemampuan generalisasi model.

Penilaian kinerja dilakukan menggunakan dua metrik kuantitatif, yaitu Peak Signal-to-Noise Ratio (PSNR) dan Structural Similarity Index Measure (SSIM). PSNR digunakan untuk mengukur tingkat kesalahan numerik antara citra hasil rekonstruksi dan citra bersih, sedangkan SSIM mengevaluasi kesamaan struktur visual kedua citra. Kombinasi kedua metrik tersebut memberikan gambaran yang komprehensif mengenai kualitas restorasi citra.

Evaluasi Menggunakan Grafik PSNR dan SSIM

Untuk melihat kinerja model secara menyeluruh pada seluruh data uji, hasil evaluasi disajikan dalam bentuk grafik nilai PSNR dan SSIM. Grafik ini memberikan gambaran mengenai variasi performa model pada setiap citra uji.



Gambar 3. Grafik Nilai PSNR dan SSIM Hasil Evaluasi Model.

Berdasarkan Gambar 3 dapat diamati bahwa nilai PSNR pada sebagian besar citra berada pada rentang yang relatif stabil, dengan fluktuasi yang tidak terlalu ekstrem. Hal ini menunjukkan bahwa model mampu melakukan proses restorasi citra secara konsisten pada berbagai jenis citra uji. Nilai PSNR yang lebih tinggi mengindikasikan bahwa citra hasil rekonstruksi memiliki tingkat kesalahan yang rendah dibandingkan citra bersih.

Sementara itu, nilai SSIM menunjukkan kecenderungan berada mendekati nilai 1 pada sebagian besar data uji. Hal ini menandakan bahwa struktur citra hasil restorasi memiliki tingkat kemiripan yang baik terhadap citra bersih. Meskipun terdapat beberapa titik dengan nilai SSIM yang lebih rendah, kondisi tersebut umumnya disebabkan oleh tingkat gangguan derau yang cukup tinggi sehingga memengaruhi kemampuan model dalam mempertahankan struktur lokal citra.

Statistik Nilai PSNR Hasil Evaluasi Model

Selain ditampilkan dalam bentuk grafik, hasil evaluasi menggunakan metrik PSNR juga dirangkum dalam bentuk statistik. Penyajian statistik ini bertujuan untuk memberikan gambaran kuantitatif yang lebih ringkas mengenai performa model secara keseluruhan

Tabel 1. Statistik Nilai PSNR Hasil Evaluasi Model.

Parameter	Nilai
Nilai Minimum	10,8187 dB
Nilai Maksimum	33,5335 dB
Rata - Rata	27,0185 dB

Pada Tabel 1, nilai PSNR rata-rata sebesar 27,0185 dB menunjukkan bahwa secara umum model mampu menghasilkan citra hasil restorasi dengan kualitas yang baik. Nilai PSNR minimum muncul pada citra dengan tingkat gangguan derau yang sangat tinggi, sehingga proses restorasi menjadi lebih sulit. Sebaliknya, nilai PSNR maksimum diperoleh pada citra dengan struktur yang relatif sederhana dan tingkat derau yang lebih mudah dipelajari oleh model.

Statistik Nilai SSIM Hasil Evaluasi Model

Sebagai pelengkap evaluasi berbasis PSNR, penilaian kinerja model juga dilakukan menggunakan metrik *Structural Similarity Index Measure* (SSIM), yang berfokus pada kesesuaian struktur citra hasil rekonstruksi terhadap citra bersih.

Tabel 2. Statistik Nilai SSIM Hasil Evaluasi Model.

Parameter	Nilai
Nilai Minimum	0,1645
Nilai Maksimum	0,9313
Rata - Rata	0,8072

Berdasarkan Tabel 2, nilai SSIM rata-rata sebesar 0,8072 menunjukkan bahwa struktur citra hasil restorasi memiliki tingkat kemiripan yang cukup tinggi terhadap citra bersih. Nilai SSIM maksimum yang mendekati 1 menunjukkan bahwa pada beberapa citra, model mampu mempertahankan struktur visual dengan sangat baik. Nilai SSIM minimum terjadi pada citra dengan gangguan derau yang sangat dominan sehingga memengaruhi detail struktur citra secara signifikan.

Analisis Hasil Evaluasi Model

Berdasarkan hasil evaluasi yang telah dilakukan, model *Deep Convolutional Autoencoder* (DCAE) dengan penambahan mekanisme *skip connection* menunjukkan kemampuan yang baik dalam menghilangkan derau *salt and pepper* pada citra grayscale. Hal ini dapat dilihat dari nilai PSNR dan SSIM yang diperoleh pada seluruh data uji yang digunakan dalam penelitian ini.

Nilai PSNR yang dihasilkan berada pada rentang yang cukup bervariasi, dengan nilai terendah sebesar 10,8187 dB dan nilai tertinggi mencapai 33,5335 dB. Perbedaan nilai tersebut dipengaruhi oleh karakteristik masing-masing citra, seperti tingkat kerumitan tekstur dan sebaran derau yang terdapat pada citra. Citra dengan tekstur yang lebih sederhana dan gangguan derau yang tidak terlalu padat cenderung menghasilkan nilai PSNR yang lebih tinggi. Sebaliknya, citra dengan detail halus dan tingkat derau yang lebih tinggi menghasilkan nilai PSNR yang lebih rendah.

Rata-rata nilai PSNR sebesar 27,0185 dB menunjukkan bahwa secara umum hasil denoising yang dihasilkan oleh model berada pada kategori baik. Nilai ini menandakan bahwa perbedaan antara citra hasil denoising dan citra bersih relatif kecil, sehingga model mampu memperbaiki kualitas citra tanpa menghilangkan informasi visual utama yang terkandung di dalamnya.

Selain PSNR, evaluasi juga dilakukan menggunakan metrik SSIM untuk menilai kesesuaian struktur citra hasil denoising terhadap citra aslinya. Hasil evaluasi menunjukkan bahwa nilai SSIM yang diperoleh cenderung stabil dan mendekati nilai satu. Hal ini menunjukkan bahwa struktur penting pada citra, seperti bentuk objek dan tepi, masih dapat dipertahankan dengan baik setelah proses penghilangan derau dilakukan.

Secara keseluruhan, penggunaan PSNR dan SSIM secara bersamaan memberikan gambaran yang lebih lengkap mengenai kualitas hasil denoising. Nilai PSNR yang cukup tinggi menunjukkan kesesuaian nilai piksel antara citra hasil dan citra asli, sedangkan nilai SSIM yang baik menunjukkan bahwa struktur visual citra tetap terjaga. Dengan demikian, model DCAE dengan *skip connection* yang digunakan dalam penelitian ini dapat dikatakan efektif dalam melakukan restorasi citra berderau *salt and pepper* pada citra grayscale.

Hasil Implementasi Aplikasi

Model *Deep Convolutional Autoencoder* (DCAE) yang telah dilatih selanjutnya diterapkan untuk melakukan denoising citra secara langsung. Penerapan ini digunakan untuk mengamati kinerja model ketika dihadapkan pada citra uji, khususnya dalam mengurangi derau *salt and pepper* pada citra *grayscale*.

Implementasi model dilakukan melalui sebuah aplikasi berbasis antarmuka grafis yang berfungsi untuk menampilkan hasil denoising secara visual. Aplikasi ini digunakan sebagai sarana pengujian praktis untuk melihat keluaran model tanpa perlu menjalankan ulang proses pelatihan. Dengan demikian, performa model dapat diamati secara langsung pada berbagai citra uji.

Tampilan Awal Aplikasi

Pada tampilan awal aplikasi, sistem menampilkan antarmuka utama yang menyediakan komponen unggah citra. Aplikasi menyediakan dua opsi unggah, yaitu citra ber-derau sebagai masukan utama dan citra bersih sebagai pembanding yang bersifat opsional. Antarmuka dirancang sederhana agar alur pengujian dapat dipahami dengan mudah.



Gambar 4. Tampilan Awal Aplikasi Denoising Citra.

Gambar 4. menunjukkan tampilan awal aplikasi yang menampilkan menu unggah citra berderau dan citra bersih sebelum proses denoising dilakukan

Hasil Denoising Citra Berderau

Pengguna hanya mengunggah citra berderau tanpa menyertakan citra bersih. Setelah citra diunggah, aplikasi secara otomatis memproses citra tersebut menggunakan model DCAE yang telah dilatih. Hasil *denoising* kemudian ditampilkan berdampingan dengan citra berderau sebagai masukan.

Penyajian hasil secara berdampingan memudahkan pengamatan perbedaan kualitas citra sebelum dan sesudah proses *denoising*. Dari hasil yang ditampilkan, gangguan derau pada citra masukan dapat dikurangi secara nyata, sementara struktur utama citra tetap dapat dikenali. Selain itu, aplikasi juga menyediakan fitur unduh citra hasil denoising sehingga hasil pemrosesan dapat disimpan untuk keperluan analisis lanjutan.



Gambar 5. Hasil Denoising dengan Input Citra Berderau.

Gambar 5 memperlihatkan perbandingan antara citra berderau sebagai masukan dan citra hasil denoising sebagai keluaran model.

Perbandingan Citra Berderau, Hasil Denoising, dan Citra Bersih

Pengguna mengunggah citra berderau beserta citra bersih sebagai pembanding. Pada kondisi ini, aplikasi menampilkan tiga citra secara berdampingan, yaitu citra berderau, citra hasil *denoising*, dan citra bersih. Penyajian ini memungkinkan perbandingan visual secara langsung antara hasil *denoising* dan citra acuan. Selain hasil visual, aplikasi juga menampilkan nilai PSNR dan SSIM yang dihitung berdasarkan perbandingan antara citra hasil *denoising* dan citra bersih. Nilai tersebut digunakan sebagai indikator kuantitatif untuk menilai kualitas hasil denoising yang dihasilkan oleh model.



Gambar 6. Perbandingan Citra Berderau, Hasil Denoising, dan Citra Bersih.

Gambar 6 menunjukkan perbandingan visual antara citra berderau, citra hasil denoising, dan citra bersih. Citra hasil *denoising* terlihat memiliki kemiripan yang baik dengan citra bersih, baik dari sisi struktur maupun intensitas piksel, yang didukung oleh nilai PSNR dan SSIM yang ditampilkan.

Analisis Hasil Implementasi Aplikasi

Berdasarkan hasil implementasi aplikasi, model *Deep Convolutional Autoencoder* (DCAE) menunjukkan kinerja yang konsisten ketika digunakan pada berbagai citra uji. Gangguan derau yang sebelumnya tampak jelas pada citra masukan dapat dikurangi setelah proses *denoising* dilakukan. Perubahan kualitas citra ini dapat diamati secara langsung melalui hasil visual yang ditampilkan oleh aplikasi.

Hasil *denoising* yang diperoleh menunjukkan bahwa pengurangan derau tidak menyebabkan hilangnya detail utama citra. Struktur objek, batas tepi, serta pola intensitas penting masih dapat dikenali dengan baik. Hal ini menunjukkan bahwa model tidak hanya melakukan penghalusan citra, tetapi juga mampu mempertahankan informasi visual yang memiliki makna.

Nilai PSNR dan SSIM yang ditampilkan pada aplikasi memberikan gambaran kuantitatif mengenai kualitas hasil denoising. Nilai PSNR yang relatif tinggi menunjukkan bahwa perbedaan intensitas piksel antara citra hasil *denoising* dan citra bersih berada pada tingkat yang rendah. Sementara itu, nilai SSIM yang mendekati satu mengindikasikan bahwa struktur citra hasil denoising memiliki tingkat kemiripan yang baik terhadap citra bersih.

Kesesuaian antara hasil visual dan nilai PSNR serta SSIM yang ditampilkan pada aplikasi menunjukkan bahwa model DCAE bekerja secara stabil ketika diterapkan secara langsung. Dengan demikian, hasil implementasi aplikasi ini memperkuat kesimpulan bahwa model *Deep Convolutional Autoencoder* yang dikembangkan memiliki kemampuan yang baik dalam melakukan denoising citra pada citra *grayscale* dan layak digunakan sebagai solusi untuk pengurangan derau pada citra digital.

5. KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini bertujuan untuk menerapkan metode Deep Convolutional Autoencoder (DCAE) dengan mekanisme skip connection dalam melakukan denoising citra grayscale yang terkontaminasi derau salt and pepper. Berdasarkan seluruh tahapan pengumpulan data, preprocessing, pelatihan model, evaluasi kuantitatif, serta implementasi aplikasi, model yang dikembangkan menunjukkan kemampuan yang cukup baik dalam mengurangi derau dan merekonstruksi citra mendekati kondisi aslinya. Hasil evaluasi menggunakan metrik PSNR dan SSIM menunjukkan nilai rata-rata PSNR sebesar 27,0185 dB dan SSIM sebesar 0,8072. Nilai SSIM yang mendekati 1 mengindikasikan bahwa struktur visual citra, seperti bentuk objek dan tepi, masih dapat dipertahankan dengan baik setelah proses denoising. Hal ini menandakan bahwa model berhasil menjaga kualitas visual citra sekaligus mengurangi gangguan derau.

Meskipun demikian, nilai PSNR rata-rata yang masih berada di bawah 30 dB menunjukkan bahwa tingkat kesalahan piksel pada beberapa citra masih cukup tinggi, terutama pada citra dengan tingkat derau yang sangat padat. Kondisi ini mengindikasikan bahwa performa rekonstruksi model belum sepenuhnya optimal pada situasi derau ekstrem. Dengan demikian, dapat disimpulkan bahwa metode DCAE dengan skip connection telah berhasil mencapai tujuan penelitian dalam menghasilkan denoising yang efektif dan stabil, namun masih memiliki keterbatasan dalam hal peningkatan kualitas numerik citra pada kondisi tertentu.

Dari sisi implementasi, model juga berhasil diterapkan ke dalam aplikasi berbasis Streamlit yang mampu melakukan proses denoising secara langsung dan menampilkan hasil visual beserta nilai evaluasi. Hal ini menunjukkan bahwa metode yang dikembangkan tidak hanya efektif secara eksperimental, tetapi juga dapat dimanfaatkan secara praktis.

Saran

Berdasarkan hasil penelitian yang telah dilakukan, masih terdapat beberapa aspek yang dapat dikembangkan untuk meningkatkan kinerja metode denoising yang diusulkan. Nilai PSNR rata-rata yang belum mencapai kategori kualitas sangat baik menunjukkan bahwa performa rekonstruksi citra masih perlu ditingkatkan. Oleh karena itu, penelitian selanjutnya disarankan untuk mengembangkan arsitektur jaringan yang lebih optimal, seperti menambah kedalaman model, jumlah filter konvolusi, atau memanfaatkan arsitektur yang lebih kompleks seperti U-Net atau Residual Network, agar model mampu merekonstruksi detail citra secara lebih akurat, terutama pada tingkat derau yang tinggi. Selain itu, penambahan jumlah serta

variasi dataset pelatihan juga diperlukan untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting.

Penelitian ini masih terbatas pada citra grayscale dengan satu jenis derau, sehingga pengujian pada citra berwarna dan berbagai jenis derau lain, seperti Gaussian atau speckle noise, perlu dilakukan agar metode lebih adaptif terhadap kondisi nyata. Di samping itu, evaluasi sebaiknya dilengkapi dengan perbandingan terhadap metode denoising lain untuk memperoleh analisis performa yang lebih objektif. Pengembangan aplikasi juga dapat ditingkatkan dengan penambahan fitur pemrosesan batch, penyimpanan hasil, dan visualisasi metrik guna meningkatkan kemudahan penggunaan dalam praktik.

DAFTAR REFERENSI

- Al Najjar, Y. (2024). Comparative analysis of image quality assessment metrics: MSE, PSNR, SSIM and FSIM. *International Journal of Science and Research (IJSR)*, 13(3), 110–114.
- Bakır, R., Bakır, H., Demircioğlu, U., Bakır, R., & Adem, K. (2024). A deep learning-based approach for image denoising: Harnessing autoencoders for removing Gaussian and salt-pepper noises. In *Proceedings of the International Artificial Intelligence and Data Science Congress* (pp. 200–207).
- Bhute, S., Mandal, S., & Guha, D. (2024). Speckle noise reduction in ultrasound images using denoising auto-encoder with skip connection. In *Proceedings of the 2024 IEEE South Asian Ultrasonics Symposium (SAUS 2024)*. IEEE.
- Chandra, N. P., & Anuradha, B. (2022). Image denoising using deep convolutional auto-encoders. [Journal information not provided], 9(2), 8–15.
- Chen, S., & Guo, W. (2023). Auto-encoders in deep learning—A review with new perspectives. *Mathematics*, 11(8), 1–54.
- Fauzi, M. R. (2022). Analisis dan reduksi noise pada citra digital menggunakan metode filtering. *Jurnal Pengolahan Citra dan Visi Komputer*, 4(2), 55–67.
- Gunadi, I. G. A., Wicaksana, I. G. A., Dwija, M. R., & Putra, I. P. A. S. (2020). Pengurangan noise pada citra digital menggunakan filter median. *Jurnal Ilmu Komputer Indonesia (JIK)*, 5(2), 34–44.
- Idris, M., Romindo, Suryani, M. M., Manarfa, W. O. R. A. U., Mandias, G. F., Suradi, A. A. M., Lutfi, H., Nurzaeb, J., Jaya, A. K., Ruslau, F. V. M., Liem, A. T., & Andryanto. (2023). *Pengolahan citra: Teori dan implementasi*. [Penerbit tidak tersedia].
- Izadi, S., Sutton, D., & Hamarneh, G. (2023). Image denoising in the deep learning era. *Artificial Intelligence Review*, 56(7), 5929–5974.

- Jiang, Y., Wang, H., Cai, Y., & Fu, B. (2022). Salt and pepper noise removal method based on the edge-adaptive total variation model. *Frontiers in Applied Mathematics and Statistics*, 8, 1–9.
- Marpaung, F., Aulia, F., & Nabila, R. C. (2022). Computer vision dan pengolahan citra digital.
- Mulyana, D. I., & Wahyudi, I. (2025). Deteksi kerusakan jalan berdasarkan citra digital menggunakan convolutional neural network (CNN). *Jurnal Indonesia: Manajemen Informatika dan Komunikasi*, 6(1), 294–302.
- Salsabilla, R., & Saputri, A. A. (2026). Teknik penghilangan derau pada citra digital untuk peningkatan kualitas visual. *Jurnal Teknik Informatika dan Sistem Cerdas*, 8(1), 12–24.
- Science, E. (2025). Automated waste classification with VGG16 CNN model for sustainable waste management.
- Sugandi, F. (2023). Implementasi metode Gaussian filtering dalam mengurangi noise pada pengolahan citra digital. *International Research on Big-Data and Computer Technology: I-Robot*, 7(2), 21–26.