



Pengembangan Model Super Resolution Lightweight Berbasis Hybrid untuk Lingkungan Komputasi Terbatas

Ade Soekarno Putra Santoso^{1*}, Kahfi Heryandi Suradiradja², Choirul Basir³

^{1,2}Fakultas Teknik Program Studi Magister Teknik Informatika, Universitas Pamulang, Indonesia

³Fakultas Matematika dan Ilmu Pengetahuan Alam Program Studi Matematika, Universitas Pamulang, Indonesia

Email: adesoekarno1@gmail.com¹, dosen01514@unpam.ac.id², dosen02278@unpam.ac.id³

*Penulis Korespondensi: adesoekarno1@gmail.com

Abstract. Computational resource limitations, particularly the use of CPU-based systems without GPU acceleration, require super-resolution models that can achieve a balance between reconstruction quality and computational efficiency. This study proposes a lightweight hybrid super-resolution model designed for resource-constrained computing environments. The proposed architecture integrates lightweight feature extraction, residual learning, and an efficient image reconstruction module to enhance image resolution while maintaining low computational complexity. Model performance is evaluated using Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), computation time, CPU utilization, and memory consumption under different scaling factors. Experimental results show that the proposed model achieves competitive reconstruction performance while maintaining computational efficiency compared with several lightweight benchmark models. These findings indicate that the proposed hybrid architecture is suitable for deployment in resource-limited computing environments. Future work may focus on evaluating and optimizing the model on edge computing platforms, including smartphones and embedded systems, to validate its performance under real-world operating conditions.

Keywords: Hybrid Method; Image Processing; Lightweight Model; Limited Computation; Super-Resolution.

Abstrak. Keterbatasan sumber daya komputasi, khususnya penggunaan CPU tanpa akselerasi GPU, menuntut pengembangan model *super-resolution* yang mampu menghasilkan keseimbangan antara kualitas rekonstruksi citra dan efisiensi komputasi. Penelitian ini bertujuan mengembangkan model *super-resolution* ringan (*lightweight*) berbasis *hybrid* yang dirancang untuk lingkungan komputasi dengan sumber daya terbatas. Arsitektur yang diusulkan mengintegrasikan mekanisme ekstraksi fitur ringan (*lightweight feature extraction*), *residual learning*, dan modul rekonstruksi citra yang efisien untuk meningkatkan resolusi citra dengan kompleksitas komputasi yang rendah. Evaluasi dilakukan menggunakan metrik *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM) pada berbagai faktor pembesaran (*scaling factor*), serta pengukuran waktu komputasi, penggunaan CPU, dan konsumsi memori. Hasil eksperimen menunjukkan bahwa model yang diusulkan mampu menghasilkan kualitas rekonstruksi yang kompetitif dengan tetap mempertahankan efisiensi komputasi dibandingkan beberapa model *lightweight* pembandingan. Hasil tersebut menunjukkan bahwa arsitektur *hybrid* yang diusulkan berpotensi untuk diterapkan pada lingkungan komputasi dengan sumber daya terbatas. Sebagai pengembangan lebih lanjut, model ini dapat diuji dan dioptimalkan pada perangkat *edge computing*, seperti *smartphone* dan *embedded system*, untuk mengevaluasi kestabilan kinerjanya pada kondisi operasional nyata dengan keterbatasan daya dan memori.

Kata Kunci: Komputasi Terbatas; *Lightweight Model*; Metode *Hybrid*; Pemrosesan Citra; *Super-Resolution*.

1. LATAR BELAKANG

Perkembangan teknologi pengolahan citra digital telah mendorong pemanfaatan teknik *image super-resolution* (SR) pada berbagai bidang, seperti pengawasan visual (*visual surveillance*), penginderaan jauh (*remote sensing*), pencitraan medis, sistem transportasi cerdas, hingga perangkat bergerak.

Teknik *super-resolution* bertujuan merekonstruksi citra beresolusi rendah (*low-resolution/LR*) menjadi citra beresolusi tinggi (*high-resolution/HR*) dengan mempertahankan detail tekstur, struktur, dan informasi visual yang hilang selama proses akuisisi maupun kompresi. Seiring berkembangnya metode berbasis *deep learning*, khususnya *Convolutional Neural Network* (CNN), kualitas rekonstruksi citra mengalami peningkatan yang signifikan dibandingkan metode interpolasi konvensional. Berbagai model, seperti SRCNN, FSRCNN, VDSR, EDSR, dan RFDN, menunjukkan bahwa pembelajaran fitur secara *end-to-end* mampu menghasilkan nilai *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM) yang lebih tinggi pada berbagai *benchmark dataset*.

Meskipun demikian, peningkatan kualitas rekonstruksi pada sebagian besar model modern dicapai melalui arsitektur yang semakin dalam dan kompleks, sehingga diikuti oleh bertambahnya jumlah parameter, kebutuhan memori, serta waktu komputasi. Kondisi tersebut menyebabkan implementasi model *super-resolution* menjadi kurang efisien ketika dijalankan pada lingkungan dengan sumber daya komputasi terbatas, seperti perangkat yang hanya mengandalkan CPU, *edge devices*, maupun *embedded systems*. Untuk mengatasi permasalahan tersebut, berbagai penelitian mengembangkan model *lightweight* yang berfokus pada pengurangan kompleksitas komputasi melalui penyederhanaan arsitektur jaringan, optimalisasi mekanisme ekstraksi fitur, penerapan *depthwise convolution*, *information distillation*, serta *residual learning*. Pendekatan tersebut terbukti mampu menurunkan kebutuhan komputasi secara signifikan, namun pada beberapa kasus masih menghasilkan penurunan kualitas rekonstruksi dibandingkan model berukuran besar.

Sebagai upaya memperoleh keseimbangan antara kualitas rekonstruksi dan efisiensi komputasi, beberapa penelitian mulai menerapkan pendekatan *hybrid* dalam pengembangan model *super-resolution*. Pendekatan ini mengombinasikan beberapa mekanisme pembelajaran untuk memanfaatkan keunggulan masing-masing komponen dalam proses ekstraksi dan rekonstruksi fitur. Sebagai contoh, DRFAN memanfaatkan mekanisme *hybrid attention* dan *residual fusion* untuk meningkatkan representasi fitur pada model ringan, sedangkan LFMix mengombinasikan CNN dan Transformer untuk *light field image super-resolution*. Penelitian lain mengembangkan *hybrid attention network*, *attention-sharing transformer*, maupun *hybrid separable attention* guna meningkatkan kemampuan ekstraksi fitur tanpa meningkatkan kompleksitas secara berlebihan. Walaupun menunjukkan performa yang kompetitif, sebagian besar pendekatan tersebut masih difokuskan pada domain tertentu, seperti *light field image*, *remote sensing*, atau citra medis, serta masih bergantung pada modul *attention* dan Transformer yang relatif meningkatkan kebutuhan komputasi.

Selain itu, evaluasi pada penelitian terdahulu umumnya lebih menitikberatkan pada kualitas rekonstruksi berdasarkan metrik PSNR dan SSIM, sedangkan analisis terhadap efisiensi implementasi pada lingkungan komputasi terbatas, khususnya perangkat berbasis CPU tanpa akselerasi GPU, masih belum banyak dilaporkan secara komprehensif.

Berdasarkan kajian tersebut, masih terdapat kesenjangan penelitian dalam pengembangan model *super-resolution* yang mampu mempertahankan kualitas rekonstruksi citra sekaligus memiliki kompleksitas komputasi yang rendah. Sebagian besar penelitian masih berorientasi pada peningkatan akurasi melalui penambahan modul jaringan yang semakin kompleks, sedangkan aspek efisiensi implementasi pada perangkat dengan keterbatasan memori, daya komputasi, dan waktu inferensi belum menjadi perhatian utama. Oleh karena itu, diperlukan suatu pendekatan yang mampu mengintegrasikan beberapa mekanisme ringan (*lightweight modules*) ke dalam sebuah arsitektur *hybrid* yang sederhana, efisien, serta mudah diimplementasikan tanpa mengurangi kualitas visual hasil rekonstruksi.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan model *lightweight super-resolution* berbasis *hybrid* yang dirancang khusus untuk lingkungan komputasi terbatas. Arsitektur yang diusulkan mengintegrasikan mekanisme *lightweight feature extraction*, *residual learning*, dan modul rekonstruksi citra berbasis *PixelShuffle* untuk menghasilkan keseimbangan antara kualitas rekonstruksi dan efisiensi komputasi. Berbeda dengan sebagian besar penelitian sebelumnya yang mengandalkan modul *attention* atau Transformer untuk meningkatkan performa, model yang diusulkan difokuskan pada penyederhanaan arsitektur sehingga tetap mampu dijalankan secara efisien pada perangkat berbasis CPU tanpa akselerasi GPU. Selain mengevaluasi kualitas rekonstruksi menggunakan metrik PSNR dan SSIM, penelitian ini juga mengukur waktu komputasi, penggunaan CPU, dan konsumsi memori sebagai indikator efisiensi implementasi. Dengan demikian, penelitian ini diharapkan dapat memberikan alternatif model *super-resolution* yang lebih efisien untuk diterapkan pada lingkungan komputasi terbatas serta memperluas peluang implementasinya pada berbagai perangkat *edge computing* dan sistem cerdas berdaya rendah.

2. KAJIAN TEORITIS

Image Super Resolution

Image Super-Resolution (SR) merupakan teknik rekonstruksi citra yang bertujuan meningkatkan resolusi citra beresolusi rendah (*Low-Resolution/LR*) menjadi citra beresolusi tinggi (*High-Resolution/HR*).

Tujuan utama SR adalah memulihkan detail tekstur, tepi objek, serta informasi visual yang hilang selama proses akuisisi, kompresi, maupun transmisi citra. Teknologi ini telah diterapkan secara luas pada berbagai bidang, seperti sistem pengawasan (*surveillance*), pencitraan medis, *remote sensing*, kendaraan cerdas, hingga perangkat bergerak. Perkembangan metode *super-resolution* diawali dengan teknik interpolasi konvensional, seperti *Nearest Neighbor*, *Bilinear*, dan *Bicubic*. Seiring berkembangnya *deep learning*, pendekatan berbasis *Convolutional Neural Network* (CNN) menjadi metode yang paling banyak digunakan karena mampu mempelajari hubungan nonlinier antara citra LR dan HR secara langsung melalui proses pembelajaran *end-to-end*. Pendekatan ini menghasilkan kualitas rekonstruksi yang lebih baik dibandingkan metode interpolasi konvensional, baik dari aspek ketajaman detail maupun kesamaan struktur citra.

Lightweight Super Resolution Network

Peningkatan kualitas rekonstruksi pada model *super-resolution* modern umumnya dicapai melalui arsitektur yang semakin dalam dan kompleks. Konsekuensinya, jumlah parameter, kebutuhan memori, serta beban komputasi juga meningkat sehingga sebagian besar model hanya dapat berjalan secara optimal pada perangkat yang dilengkapi GPU. Untuk mengatasi permasalahan tersebut, berbagai penelitian mengembangkan *lightweight super-resolution network* yang berfokus pada pengurangan kompleksitas komputasi tanpa mengurangi kualitas rekonstruksi secara signifikan. Strategi yang banyak diterapkan meliputi penyederhanaan blok konvolusi, *residual learning*, *information distillation*, *depthwise convolution*, serta optimalisasi proses ekstraksi fitur. Model seperti FSRCNN, LapSRN-Tiny, IMDN, dan RFDN merupakan contoh arsitektur ringan yang mampu memberikan keseimbangan antara kualitas rekonstruksi dan efisiensi komputasi. Namun demikian, sebagian besar model tersebut masih mengalami penurunan performa ketika diterapkan pada perangkat dengan sumber daya komputasi yang sangat terbatas, khususnya sistem berbasis CPU tanpa akselerasi GPU.

Hybrid Architecture

Pendekatan *hybrid* merupakan salah satu strategi yang berkembang dalam pengembangan model *super-resolution* untuk memperoleh keseimbangan antara kualitas rekonstruksi dan efisiensi komputasi. Konsep *hybrid* mengacu pada penggabungan beberapa mekanisme pembelajaran dalam satu arsitektur sehingga setiap komponen dapat saling melengkapi selama proses ekstraksi fitur maupun rekonstruksi citra. Berbagai penelitian telah mengombinasikan CNN dengan Transformer, *attention mechanism*, *feature fusion*, maupun *residual learning* untuk meningkatkan kemampuan representasi fitur.

Pendekatan tersebut terbukti mampu meningkatkan kualitas rekonstruksi, tetapi umumnya diikuti oleh peningkatan jumlah parameter dan kebutuhan komputasi sehingga kurang sesuai diterapkan pada perangkat dengan sumber daya terbatas. Pada penelitian ini, konsep *hybrid* diterapkan dengan mengintegrasikan mekanisme *lightweight feature extraction*, *residual learning*, dan modul rekonstruksi citra berbasis *PixelShuffle* dalam satu arsitektur yang sederhana dan efisien. Kombinasi tersebut dirancang untuk mempertahankan kualitas rekonstruksi sekaligus menekan kompleksitas komputasi sehingga sesuai untuk implementasi pada lingkungan berbasis CPU.

Evaluasi Kualitas Citra Visual

Kinerja model *super-resolution* umumnya dievaluasi menggunakan metrik objektif yang mengukur tingkat kesamaan antara citra hasil rekonstruksi dan citra referensi. *Peak Signal-to-Noise Ratio* (PSNR) digunakan untuk mengukur tingkat kesalahan rekonstruksi berdasarkan nilai *Mean Squared Error* (MSE). Semakin tinggi nilai PSNR menunjukkan semakin kecil kesalahan rekonstruksi sehingga kualitas citra yang dihasilkan semakin baik. Selain PSNR, *Structural Similarity Index Measure* (SSIM) digunakan untuk mengevaluasi kesamaan struktur, luminansi, dan kontras antara citra hasil rekonstruksi dan citra referensi. Nilai SSIM berada pada rentang 0 hingga 1, dengan nilai yang semakin mendekati 1 menunjukkan tingkat kemiripan struktur yang semakin tinggi. Selain kualitas rekonstruksi, penelitian ini juga mengevaluasi efisiensi model berdasarkan waktu komputasi, penggunaan CPU, dan konsumsi memori. Ketiga parameter tersebut digunakan untuk menilai kelayakan implementasi model pada lingkungan komputasi dengan sumber daya terbatas.

Penelitian Terdahulu

Penelitian mengenai *lightweight super-resolution* berkembang pesat dalam beberapa tahun terakhir. Berbagai pendekatan telah diusulkan untuk meningkatkan kualitas rekonstruksi tanpa meningkatkan kompleksitas komputasi secara berlebihan. DRFAN menggabungkan *hybrid attention* dan *residual fusion* untuk meningkatkan representasi fitur pada model ringan. LFMix memanfaatkan kombinasi CNN dan Transformer untuk *light field super-resolution*, sedangkan HASN menerapkan *hybrid separable attention* guna meningkatkan efisiensi proses ekstraksi fitur. Penelitian lain, seperti ASID Transformer, DLGSANet, dan DRSAN, juga menunjukkan bahwa mekanisme *attention* mampu meningkatkan kualitas rekonstruksi citra. Meskipun demikian, sebagian besar pendekatan tersebut masih memerlukan sumber daya komputasi yang relatif tinggi atau difokuskan pada domain tertentu, seperti *remote sensing*, *light field imaging*, maupun citra medis.

Selain itu, evaluasi umumnya lebih berfokus pada peningkatan akurasi rekonstruksi dibandingkan efisiensi implementasi pada perangkat dengan sumber daya terbatas. Berdasarkan kajian tersebut, masih terdapat peluang untuk mengembangkan model *lightweight super-resolution* yang mampu mempertahankan kualitas rekonstruksi dengan kompleksitas komputasi yang rendah. Oleh karena itu, penelitian ini mengusulkan AdeSRTiny, yaitu model *hybrid lightweight super-resolution* yang mengintegrasikan *lightweight feature extraction*, *residual learning*, dan modul rekonstruksi citra yang efisien untuk mencapai keseimbangan antara kualitas visual dan efisiensi komputasi pada lingkungan berbasis CPU.

3. METODE PENELITIAN

Penelitian ini menggunakan metode *Research and Development (R&D)* dengan pendekatan *experimental research* untuk mengembangkan model *lightweight super-resolution* berbasis *hybrid* yang dirancang bagi lingkungan komputasi dengan sumber daya terbatas. Tahapan penelitian meliputi studi literatur, analisis kebutuhan, persiapan dataset, perancangan arsitektur model, implementasi sistem, proses pelatihan (*training*), serta evaluasi terhadap kualitas rekonstruksi dan efisiensi komputasi. Seluruh proses pengembangan dan pengujian dilakukan menggunakan lingkungan komputasi berbasis CPU tanpa memanfaatkan akselerasi GPU sehingga dapat merepresentasikan kondisi implementasi pada perangkat dengan sumber daya terbatas.

Desain Penelitian

Tahapan penelitian ditunjukkan pada Gambar 1. Penelitian diawali dengan studi literatur mengenai perkembangan metode *image super-resolution*, khususnya model *lightweight* yang dirancang untuk lingkungan komputasi terbatas. Tahap berikutnya adalah analisis kebutuhan sistem untuk mengidentifikasi karakteristik model yang mampu menghasilkan kualitas rekonstruksi yang baik dengan kompleksitas komputasi yang rendah.

Selanjutnya dilakukan proses persiapan dataset dengan membentuk pasangan citra Low-Resolution (LR) dan High-Resolution (HR) sebagai data pelatihan dan pengujian. Setelah proses prapengolahan (*preprocessing*) selesai, dilakukan perancangan arsitektur model AdeSRTiny yang mengintegrasikan mekanisme *lightweight feature extraction*, *residual learning*, dan modul rekonstruksi citra berbasis *PixelShuffle*. Model kemudian dilatih menggunakan pasangan citra LR-HR hingga mencapai kondisi konvergen berdasarkan fungsi kehilangan (*loss function*) yang digunakan.

Tahap terakhir adalah evaluasi performa model dengan membandingkan kualitas rekonstruksi menggunakan metrik Peak Signal-to-Noise Ratio (PSNR) dan Structural Similarity Index Measure (SSIM), serta mengevaluasi efisiensi implementasi berdasarkan waktu komputasi, penggunaan CPU, dan konsumsi memori. Hasil evaluasi selanjutnya dibandingkan dengan beberapa model *lightweight super-resolution* sebagai pembanding untuk mengetahui efektivitas model yang diusulkan.



Gambar 1. Diagram Alur Penelitian.

Dataset Penelitian

Dataset penelitian menggunakan 20.000 pasangan citra yang terdiri atas citra Low-Resolution (LR) dan High-Resolution (HR) untuk proses pelatihan (*training*) dan pengujian (*testing*) model. Citra HR dipotong menjadi *patch* berukuran 48×48 piksel, kemudian citra LR dihasilkan menggunakan metode bicubic downsampling dengan *scaling factor* $\times 4$. Proses tersebut menghasilkan pasangan citra LR-HR yang memiliki korespondensi piksel sehingga dapat digunakan sebagai data masukan dan target selama proses pembelajaran model. Sebelum digunakan pada proses pelatihan, seluruh citra melalui tahap *preprocessing* untuk memastikan ukuran *patch* yang seragam sehingga meningkatkan konsistensi data dan efisiensi komputasi. Selanjutnya, dataset dibagi menjadi data pelatihan dan data pengujian dengan rasio 80:20, sehingga proses evaluasi dilakukan menggunakan data yang tidak terlibat selama pelatihan. Pembagian dataset tersebut bertujuan untuk mengukur kemampuan generalisasi model dalam merekonstruksi citra beresolusi rendah menjadi citra beresolusi tinggi secara objektif.

Perancangan Model

Model yang diusulkan adalah AdeSRTiny, yaitu arsitektur *lightweight super-resolution* berbasis *hybrid* yang dirancang untuk menghasilkan keseimbangan antara kualitas rekonstruksi citra dan efisiensi komputasi pada lingkungan berbasis CPU. Konsep *hybrid* pada penelitian ini diterapkan melalui integrasi mekanisme *lightweight feature extraction*, *residual learning*, dan modul rekonstruksi citra berbasis *PixelShuffle* dalam satu arsitektur yang sederhana sehingga mampu meningkatkan kualitas rekonstruksi tanpa menambah kompleksitas komputasi secara berlebihan.

Arsitektur model terdiri atas empat komponen utama sebagai berikut: 1) *Feature Extraction Layer*, yang berfungsi mengekstraksi fitur awal dari citra *Low-Resolution* (LR) menggunakan lapisan konvolusi sehingga informasi dasar citra dapat direpresentasikan sebagai fitur yang siap diproses pada tahap berikutnya; 2) *Residual Feature Learning*, yang mempelajari representasi fitur secara bertahap melalui blok *residual* ringan. Mekanisme ini bertujuan meningkatkan kemampuan ekstraksi fitur sekaligus menjaga stabilitas proses pelatihan tanpa menambah jumlah parameter secara signifikan; 3) *Hybrid Reconstruction Module*, yang mengintegrasikan hasil ekstraksi fitur dan pembelajaran *residual* untuk menghasilkan representasi fitur yang lebih informatif sebelum proses *upsampling*. Integrasi tersebut memungkinkan model mempertahankan detail tekstur dan struktur citra dengan kompleksitas komputasi yang tetap rendah; 4) *Upsampling Layer*, yang menggunakan metode *PixelShuffle* untuk meningkatkan resolusi citra secara efisien sehingga menghasilkan citra *High-Resolution* (HR) dengan kualitas rekonstruksi yang lebih baik dibandingkan metode interpolasi konvensional. Pendekatan tersebut dipilih karena mampu menghasilkan keseimbangan antara jumlah parameter, kecepatan komputasi, konsumsi memori, dan kualitas rekonstruksi citra, sehingga sesuai diterapkan pada lingkungan komputasi dengan sumber daya terbatas.

Implementasi dan Pelatihan Model

Model dikembangkan menggunakan bahasa pemrograman Python dengan *framework* *PyTorch*. Seluruh proses pelatihan dan pengujian dilakukan pada lingkungan komputasi berbasis CPU tanpa memanfaatkan akselerasi GPU, sehingga kondisi eksperimen merepresentasikan implementasi pada perangkat dengan sumber daya komputasi terbatas. Sebelum proses pelatihan, dilakukan beberapa percobaan awal untuk memperoleh konfigurasi parameter yang stabil. Model dilatih menggunakan fungsi kehilangan (*loss function*) L1 Loss karena memiliki kemampuan yang baik dalam mempertahankan detail citra serta menghasilkan kualitas rekonstruksi yang lebih baik pada permasalahan *image super-resolution*.

Proses optimasi parameter dilakukan menggunakan algoritma *Adam Optimizer* yang dipilih karena memiliki kemampuan konvergensi yang cepat dan stabil pada proses pelatihan jaringan saraf. Selama proses pelatihan, model mempelajari hubungan antara pasangan citra *Low-Resolution* (LR) dan *High-Resolution* (HR) untuk meminimalkan nilai *loss* hingga mencapai kondisi konvergen. Model yang telah dilatih selanjutnya digunakan pada tahap pengujian untuk mengevaluasi kualitas rekonstruksi citra dan efisiensi komputasi berdasarkan metrik yang telah ditentukan.

Model Pemandangan

Untuk mengevaluasi performa model yang diusulkan, dilakukan perbandingan dengan beberapa model *lightweight super-resolution* yang telah banyak digunakan sebagai *baseline* dalam penelitian sebelumnya. Model pembandingan dipilih karena memiliki karakteristik arsitektur yang ringan serta dirancang untuk menghasilkan keseimbangan antara kualitas rekonstruksi dan efisiensi komputasi.

Model yang digunakan sebagai pembandingan meliputi: a) FSRCNN, sebagai salah satu model *lightweight super-resolution* dengan arsitektur sederhana dan kecepatan komputasi yang tinggi; b) LapSRN-Tiny, yang menerapkan pendekatan *progressive upsampling* untuk meningkatkan kualitas rekonstruksi dengan kompleksitas yang relatif rendah; c) IMDN-Light, yang menggunakan mekanisme *information distillation* untuk meningkatkan efisiensi ekstraksi fitur; d) RFDN-Light, yang menerapkan *residual feature distillation* guna memperoleh keseimbangan antara akurasi dan efisiensi komputasi; e) DSRDRCNN-Lite, sebagai model *lightweight* berbasis pembelajaran residual yang dirancang untuk lingkungan dengan sumber daya komputasi terbatas. Seluruh model dilatih dan diuji menggunakan dataset, konfigurasi pelatihan, serta parameter evaluasi yang sama sehingga perbandingan performa dilakukan secara objektif dan adil (*fair comparison*). Evaluasi dilakukan berdasarkan kualitas rekonstruksi menggunakan metrik *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM), serta efisiensi komputasi yang meliputi waktu komputasi, penggunaan CPU, dan konsumsi memori.

Evaluasi Model

Evaluasi model dilakukan berdasarkan dua aspek utama, yaitu kualitas rekonstruksi citra dan efisiensi komputasi. Kualitas rekonstruksi dievaluasi menggunakan metrik *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM). PSNR digunakan untuk mengukur tingkat kesalahan rekonstruksi antara citra hasil prediksi dan citra referensi berdasarkan nilai *Mean Squared Error* (MSE), sedangkan SSIM digunakan untuk mengevaluasi tingkat kemiripan struktur, luminansi, dan kontras antara kedua citra.

Selain kualitas rekonstruksi, penelitian ini juga mengevaluasi efisiensi komputasi melalui pengukuran waktu komputasi (*runtime*), penggunaan CPU (*CPU usage*), dan konsumsi memori (*memory usage*) selama proses pengujian. Ketiga parameter tersebut digunakan untuk menilai kemampuan model dalam menghasilkan kualitas rekonstruksi yang baik dengan kebutuhan sumber daya komputasi yang rendah.

Seluruh hasil evaluasi kemudian dibandingkan dengan model pembanding menggunakan dataset dan konfigurasi pengujian yang sama sehingga proses perbandingan dilakukan secara objektif dan adil (*fair comparison*). Melalui evaluasi tersebut dapat diketahui kemampuan model yang diusulkan dalam mempertahankan keseimbangan antara kualitas rekonstruksi citra dan efisiensi komputasi.

Analisis Data


Data hasil pengujian dianalisis menggunakan pendekatan komparatif dengan membandingkan nilai PSNR, SSIM, waktu komputasi, penggunaan CPU, dan konsumsi memori dari seluruh model yang diuji. Analisis dilakukan untuk mengidentifikasi hubungan antara kualitas rekonstruksi citra dan efisiensi komputasi pada masing-masing model.

Selain membandingkan nilai kuantitatif, analisis juga dilakukan terhadap hasil rekonstruksi secara visual untuk mengamati kemampuan setiap model dalam mempertahankan detail tekstur, ketajaman tepi, dan struktur objek pada citra hasil *super-resolution*. Pendekatan tersebut memberikan gambaran yang lebih komprehensif mengenai keunggulan dan keterbatasan model AdeSRTiny dibandingkan model *lightweight super-resolution* lainnya pada lingkungan komputasi berbasis CPU.

4. HASIL DAN PEMBAHASAN

Hasil Penelitian


Penelitian ini berhasil mengimplementasikan model AdeSRTiny, yaitu arsitektur *lightweight super-resolution* berbasis *hybrid* yang dirancang untuk lingkungan komputasi dengan sumber daya terbatas. Seluruh proses pelatihan dan pengujian dilakukan pada sistem berbasis CPU tanpa menggunakan akselerasi GPU, sehingga implementasi model dapat merepresentasikan kondisi penggunaan pada perangkat dengan kemampuan komputasi yang terbatas. Model dilatih menggunakan pasangan citra *Low-Resolution* (LR) dan *High-Resolution* (HR) hingga mencapai kondisi konvergen. Setelah proses pelatihan selesai, model digunakan untuk merekonstruksi citra LR menjadi citra *High-Resolution* (HR). Hasil implementasi kemudian dievaluasi berdasarkan kualitas rekonstruksi citra serta efisiensi komputasi menggunakan metrik yang telah ditentukan.



Gambar 2. Arsitektur ADESRTiny.

Hasil Pelatihan Model

Model AdeSRTiny dilatih menggunakan pasangan citra Low-Resolution (LR) dan High-Resolution (HR) hingga mencapai kondisi konvergen. Selama proses pelatihan, nilai *loss* dicatat pada setiap *epoch* untuk mengevaluasi stabilitas proses pembelajaran serta kemampuan model dalam meminimalkan kesalahan rekonstruksi citra.



Gambar 3. Perbandingan Loss dengan Epoch.

Berdasarkan Gambar 3, seluruh model menunjukkan tren penurunan nilai *loss* seiring bertambahnya jumlah *epoch*, yang mengindikasikan bahwa proses pembelajaran berlangsung dengan baik. Model AdeSRTiny memperlihatkan penurunan *loss* yang konsisten dari sekitar 0,025 pada awal pelatihan menjadi sekitar 0,0225 pada *epoch* ke-10.

Penurunan yang stabil tanpa fluktuasi yang signifikan menunjukkan bahwa proses optimasi menggunakan Adam Optimizer dan fungsi kehilangan L1 Loss mampu mengarahkan model menuju kondisi konvergen. Selain memiliki kurva pelatihan yang stabil, AdeSRTiny juga menghasilkan nilai *loss* akhir yang lebih rendah dibandingkan sebagian besar model pembanding. Hal tersebut menunjukkan bahwa arsitektur yang diusulkan memiliki kemampuan yang baik dalam mempelajari hubungan antara citra Low-Resolution (LR) dan High-Resolution (HR) sehingga kesalahan rekonstruksi dapat diminimalkan secara efektif. Setelah sekitar *epoch* ke-5, laju penurunan *loss* mulai melambat hingga kurva cenderung mendatar, yang mengindikasikan bahwa model telah mencapai kondisi pembelajaran yang stabil (*converged*). Kondisi ini menjadi dasar untuk melanjutkan evaluasi terhadap kualitas rekonstruksi citra dan efisiensi komputasi pada tahap berikutnya.


Evaluasi Kualitas Rekonstruksi

Tabel 1. Data Hasil Training Model.

Model	Loss	PSNR (dB)	SSIM	Δ PSNR vs Bicubic (dB)	Waktu (menit)	CPU (%)	RAM (GB)
FSRCNN	0.0240	32.34	0.8454	32.34	3.6	201.3	0.36
LapSRN-Tiny	0.0225	32.88	0.8572	32.88	7.9	630.8	0.15
IMDN-Light	0.0229	32.83	0.8554	32.83	6.5	649.8	0.37
RFDN-Light	0.0233	32.63	0.8515	32.63	5.3	552.9	0.35
DSRDRCNN-Lite	0.0252	31.84	0.8340	31.84	4.2	320.0	0.36
ADESRTiny	0.0225	32.91	0.8575	32.91	4.8	456.6	0.11


Hasil evaluasi kuantitatif dilakukan untuk membandingkan performa model AdeSRTiny dengan beberapa model *lightweight super-resolution*, yaitu FSRCNN, LapSRN-Tiny, IMDN-Light, RFDN-Light, dan DSRDRCNN-Lite. Evaluasi dilakukan menggunakan dataset dan konfigurasi pengujian yang sama sehingga perbandingan dapat dilakukan secara objektif. Parameter yang dianalisis meliputi nilai *loss*, *Peak Signal-to-Noise Ratio* (PSNR), *Structural Similarity Index Measure* (SSIM), peningkatan PSNR terhadap metode Bicubic (Δ PSNR), waktu komputasi (*runtime*), penggunaan CPU (*CPU usage*), serta konsumsi memori.

Evaluasi kualitas rekonstruksi citra dilakukan menggunakan metrik *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM). Kedua metrik tersebut digunakan untuk mengukur kemampuan model dalam menghasilkan citra beresolusi tinggi yang mendekati citra referensi. Nilai PSNR menunjukkan tingkat akurasi rekonstruksi berdasarkan kesalahan piksel, sedangkan SSIM mengukur kesamaan struktur, kontras, dan luminansi antara citra hasil rekonstruksi dengan citra referensi.



Gambar 4. Perbandingan PSNR dan Epoch.

Berdasarkan Gambar 4, seluruh model menunjukkan peningkatan nilai PSNR seiring bertambahnya *epoch*, yang menunjukkan bahwa proses pembelajaran berlangsung secara efektif. Model AdeSRTiny secara konsisten menghasilkan nilai PSNR tertinggi dibandingkan model pembanding. Pada akhir pelatihan, nilai PSNR AdeSRTiny mencapai sekitar 32,91 dB, sedikit lebih tinggi dibandingkan LapSRN-Tiny (32,88 dB) dan IMDN-Light (32,83 dB). Meskipun selisihnya relatif kecil, hasil tersebut menunjukkan bahwa arsitektur yang diusulkan mampu meningkatkan kualitas rekonstruksi citra secara konsisten.




Gambar 5. Perbandingan SSIM dan Epoch.

Hasil yang serupa juga terlihat pada metrik SSIM. Berdasarkan Gambar 5, seluruh model mengalami peningkatan nilai SSIM selama proses pelatihan. AdeSRTiny memperoleh nilai SSIM tertinggi, yaitu sekitar 0,8575, diikuti oleh LapSRN-Tiny (0,8572) dan IMDN-Light (0,8554). Peningkatan nilai SSIM menunjukkan bahwa citra hasil rekonstruksi semakin mampu mempertahankan struktur, tekstur, dan detail visual sehingga lebih mendekati citra referensi.

Keunggulan AdeSRTiny pada kedua metrik tersebut menunjukkan bahwa integrasi *lightweight feature extraction*, *residual learning*, dan *PixelShuffle* mampu menghasilkan representasi fitur yang lebih efektif tanpa meningkatkan kompleksitas model secara signifikan. Dengan demikian, model yang diusulkan tidak hanya menghasilkan kualitas rekonstruksi yang kompetitif, tetapi juga tetap sesuai untuk diterapkan pada lingkungan komputasi dengan sumber daya terbatas

Analisis Visual

Analisis visual dilakukan untuk membandingkan kualitas hasil rekonstruksi citra yang dihasilkan oleh setiap model terhadap citra referensi (*High Resolution*). Evaluasi ini bertujuan untuk mengamati kemampuan masing-masing model dalam mempertahankan tekstur, ketajaman tepi, dan detail lokal yang tidak sepenuhnya dapat direpresentasikan oleh nilai PSNR dan SSIM.



Gambar 7. Perbandingan Hasil Visual.

Gambar 7 menampilkan perbandingan hasil rekonstruksi pada area yang ditandai dengan kotak merah pada objek kupu-kupu. Area tersebut dipilih karena mengandung pola tekstur dan batas tepi yang cukup kompleks sehingga dapat menunjukkan kemampuan masing-masing model dalam merekonstruksi detail citra.

Metode Bicubic menghasilkan citra yang masih terlihat kabur sehingga batas tepi pola sayap kupu-kupu belum terbentuk dengan jelas. FSRCNN dan DSRDRCNN-Lite mampu meningkatkan ketajaman citra dibandingkan Bicubic, namun kontur garis hitam pada sayap masih tampak kurang tegas dan beberapa detail halus belum direkonstruksi secara optimal.

Sementara itu, LapSRN-Tiny, IMDN-Light, dan RFDN-Light menghasilkan rekonstruksi dengan kualitas yang lebih baik. Pola pada sayap kupu-kupu terlihat lebih jelas dan batas antara warna hitam serta kuning menjadi lebih tegas dibandingkan model sebelumnya. Meskipun demikian, pada beberapa bagian masih terlihat sedikit efek kabur sehingga detail lokal belum sepenuhnya menyerupai citra referensi. Model AdeSRTiny menghasilkan rekonstruksi yang paling mendekati citra *High Resolution*. Garis tepi pada pola sayap tampak lebih tajam, transisi antarwarna lebih jelas, dan tekstur lokal lebih terjaga dibandingkan model pembanding.

Selain itu, efek kabur yang masih terlihat pada beberapa model lain berhasil dikurangi sehingga struktur visual objek menjadi lebih mudah dikenali. Hasil analisis visual tersebut konsisten dengan hasil evaluasi kuantitatif yang menunjukkan bahwa AdeSRTiny memperoleh nilai PSNR dan SSIM tertinggi di antara seluruh model yang diuji. Dengan demikian, arsitektur yang diusulkan tidak hanya memberikan peningkatan pada metrik evaluasi, tetapi juga mampu menghasilkan kualitas rekonstruksi yang lebih baik secara visual pada area yang memiliki detail dan tekstur kompleks.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan model super-resolution lightweight berbasis hybrid (AdeSRTiny) yang dirancang untuk lingkungan komputasi terbatas berbasis CPU. Arsitektur yang diusulkan mengombinasikan mekanisme ekstraksi fitur ringan, *residual learning*, dan modul rekonstruksi citra yang efisien sehingga mampu menghasilkan keseimbangan antara kualitas rekonstruksi citra dan efisiensi komputasi. Berdasarkan hasil evaluasi menggunakan metrik Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), waktu komputasi, penggunaan CPU, dan konsumsi memori, model AdeSRTiny menunjukkan performa yang kompetitif dibandingkan beberapa model *lightweight super-resolution* seperti FSRCNN, LapSRN-Tiny, RFDN-Light, dan DSDRCNN-Lite. Hasil tersebut menunjukkan bahwa pendekatan *hybrid lightweight* yang diusulkan layak diterapkan pada perangkat dengan keterbatasan sumber daya komputasi tanpa mengorbankan kualitas visual hasil rekonstruksi.

Penelitian ini masih memiliki beberapa keterbatasan. Evaluasi dilakukan pada lingkungan komputasi berbasis CPU dengan dataset yang terbatas pada citra pasangan *Low-Resolution* dan *High-Resolution* hasil degradasi sintetis, sehingga kemampuan model dalam menangani degradasi citra nyata (*real-world degradation*) belum dievaluasi secara menyeluruh. Selain itu, pengujian implementasi pada perangkat *edge* maupun *embedded system* belum dilakukan sehingga efisiensi model pada kondisi operasional sebenarnya masih memerlukan pembuktian lebih lanjut.

Penelitian selanjutnya disarankan untuk mengembangkan mekanisme *adaptive feature extraction* atau *lightweight attention* yang tetap mempertahankan efisiensi komputasi. Pengujian pada dataset *real-world super-resolution* serta implementasi pada perangkat *edge computing*, *embedded system*, atau *mobile device* juga perlu dilakukan untuk mengevaluasi kemampuan model dalam berbagai skenario aplikasi nyata. Selain itu, pengukuran kompleksitas model menggunakan parameter seperti jumlah parameter (*number of parameters*), *Floating Point Operations (FLOPs)*, dan kecepatan inferensi (*Frames Per Second/FPS*) dapat ditambahkan agar evaluasi performa model menjadi lebih komprehensif.

DAFTAR REFERENSI

- Ahn, N., Kang, B., & Sohn, K. A. (2018). Fast, accurate, and lightweight super-resolution with cascading residual network. *Lecture Notes in Computer Science*, 11133, 252-268.
- Cai, J., Gu, S., Timofte, R., & Zhang, L. (2019). NTIRE 2019 challenge on real image super-resolution: Methods and results. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 0-0.
- Chen, J., Wang, L., & Huang, H. (2023). Lightweight hybrid super-resolution network for resource-constrained devices. *Signal Processing: Image Communication*, 117, 116987.
- Guo, X., Zhang, Y., Li, J., & Wang, H. (2024). Lightweight image super-resolution via adaptive feature distillation. *Knowledge-Based Systems*, 299, 112145.
- Li, Y., Zhao, H., & Chen, X. (2024). Efficient lightweight super-resolution using hybrid feature fusion. *Expert Systems with Applications*, 255, 124657.
- Liu, Z., Wang, Q., & Sun, Y. (2023). Hybrid attention-based lightweight image super-resolution network. *Neural Computing and Applications*, 35(18), 13241-13258.
- Lu, Y., Zhang, H., & Wang, S. (2024). Hybrid attention super-resolution network for lightweight image reconstruction. *Neural Computing and Applications*, 36(5), 7851-7868.
- Ma, W., Li, X., & Zhao, Y. (2024). Deep residual feature aggregation network for lightweight image super-resolution. *Knowledge-Based Systems*, 302, 112487.
- Pan, J., Yang, X., & Li, H. (2025). Efficient hybrid CNN architecture for image super-resolution. *Expert Systems with Applications*, 266, 125942.

- Shi, W., Caballero, J., Huszár, F., Aitken, A., 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 Conference on Computer Vision and Pattern Recognition*, 1874-1883.
- Sun, L., Zhao, X., & Li, H. (2023). Hybrid attention super-resolution network for lightweight image reconstruction. *Neurocomputing*, 548, 126560.
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *Image Processing*, 13(4), 600-612.
- Yin, P., Zhang, Y., & Liu, Z. (2024). Lightweight feature mixing network for image super-resolution. *Information Sciences*, 682, 121164.
- Zhang, K., Zuo, W., & Zhang, L. (2021). Deep learning for image super-resolution: A survey. *International Journal of Computer Vision*, 129(10), 2953-2976.
- Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., & Fu, Y. (2018). Image super-resolution using very deep residual channel attention networks. *Lecture Notes in Computer Science*, 11211, 294-310.
- Zhao, X., Chen, Y., & Wang, H. (2025). Adaptive lightweight super-resolution for mobile vision applications. *Pattern Recognition*, 161, 111221.
- Zhou, M., Li, C., & Huang, Y. (2024). Efficient image super-resolution using lightweight residual learning. *Multimedia Tools and Applications*, 83(17), 50371-50390.
- Zhu, L., Chen, H., & Xu, Y. (2024). Efficient residual feature learning for lightweight image super-resolution. *Multimedia Tools and Applications*, 83(14), 42115-42134.