

EVOLUSI PENDEKATAN *DEEP LEARNING* BERBASIS *ATTENTION MECHANISM* PADA PENINGKATAN RESOLUSI CITRA: TINJAUAN KOMPREHENSIF

Dezein Hibatullah¹⁾, Ruli Susanti²⁾

^{1,2}Prodi Informatika, Fakultas Teknik, Universitas Majalengka

Correspondence author: D Hibatullah, dezainhibaa@gmail.com, Majalengka, Indonesia

Abstract

This study presents a Systematic Literature Review (SLR) on the development of attention-based deep learning methods for Single Image Super-Resolution (SISR) for the period 2022–2026. Using the PRISMA 2020 framework, 53 articles were selected from 1,116 identified articles from Scopus, IEEE Xplore, ScienceDirect, and SpringerLink. The study results show that hybrid CNN-Transformer architectures with attention mechanisms dominate the current trend, with channel attention being the most widely used (71.7%). Application domains include medical imaging, remote sensing, surveillance, multimedia, and industry. Key challenges identified include model complexity, limited generalization, and the trade-off between reconstruction quality and inference efficiency. This study provides a comprehensive roadmap for developing more adaptive and efficient attention-based SISR systems.

Keywords : *single image super-resolution, attention mechanism, deep learning*

Abstrak

Penelitian ini menyajikan *Systematic Literature Review* (SLR) terhadap perkembangan metode *deep learning* berbasis *attention mechanism* untuk *Single Image Super-Resolution* (SISR) pada periode 2022–2026. Menggunakan kerangka PRISMA 2020, sebanyak 53 artikel dipilih dari 1.116 artikel teridentifikasi dari Scopus, IEEE Xplore, ScienceDirect, dan SpringerLink. Hasil kajian menunjukkan bahwa arsitektur hibrida CNN-Transformer dengan *attention mechanism* mendominasi tren terkini, dengan *channel attention* sebagai jenis yang paling banyak digunakan (71,7%). Domain aplikasi mencakup pencitraan medis, penginderaan jauh, *surveillance*, multimedia, dan industri. Tantangan utama yang teridentifikasi meliputi kompleksitas model, keterbatasan generalisasi, dan *trade-off* antara kualitas rekonstruksi dan efisiensi inferensi. Penelitian ini memberikan peta jalan komprehensif bagi pengembangan sistem SISR berbasis *attention* yang lebih adaptif dan efisien.

Kata Kunci : *single image super-resolution, attention mechanism, deep learning*

A. PENDAHULUAN

Kualitas citra digital menjadi faktor penentu dalam berbagai sistem berbasis penglihatan komputer, mulai dari diagnosis medis hingga pemantauan lingkungan melalui penginderaan jauh. Dalam praktiknya, citra yang diperoleh dari sensor sering memiliki resolusi rendah akibat keterbatasan perangkat keras, kondisi akuisisi yang tidak ideal, atau kendala *bandwidth*. Kondisi ini mendorong berkembangnya penelitian *Single Image Super-Resolution* (SISR), yakni rekonstruksi citra beresolusi tinggi dari satu citra masukan beresolusi rendah. Tantangan mendasar SISR terletak pada sifatnya yang *ill-posed*, di mana satu citra beresolusi rendah dapat berkorespondensi dengan banyak kemungkinan citra beresolusi tinggi (Chauhan et al., 2023).

Pendekatan *deep learning* telah mengubah lanskap SISR secara fundamental melalui berbagai arsitektur seperti *residual network*, *dense connection*, dan GAN. Namun, model-model awal cenderung memproses seluruh piksel secara seragam tanpa membedakan area detail penting dari area homogen. *Attention mechanism* hadir sebagai solusi dengan memungkinkan model secara adaptif memfokuskan komputasi pada wilayah yang paling relevan, baik melalui *channel attention*, *spatial attention*, maupun *self-attention* berbasis Transformer yang mampu memodelkan hubungan global antarfitur secara lebih efektif (Chen et al., 2025; Yu et al., 2025; Talreja et al., 2023). Perkembangan ini telah menjangkau beragam domain, termasuk pencitraan medis (Ning et al., 2025), penginderaan jauh (Yu et al., 2025) dan aplikasi *lightweight* untuk perangkat terbatas (Tang et al., 2025; Kirat & Yerlikaya, 2025).

Meskipun literturnya tumbuh pesat, belum terdapat kajian sistematis yang memetakan perkembangan metode *deep learning* berbasis *attention* untuk SISR pada


periode 2022–2026 secara menyeluruh. Penelitian ini mengisi kesenjangan tersebut melalui *Systematic Literature Review* (SLR) dengan protokol PRISMA.

B. METODE PENELITIAN

Penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR) dengan kerangka PRISMA 2020. Pencarian dilakukan pada Scopus, IEEE Xplore, ScienceDirect, dan SpringerLink menggunakan kata kunci Boolean: "*Single Image Super resolution*", "*Deep learning*", "*Transformer*", "*CNN*", dan "*Attention mechanism*", dibatasi pada periode 2022–2026 (Haddaway et al., 2022).

Kriteria inklusi meliputi artikel jurnal dan prosiding internasional terindeks yang membahas SISR berbasis *deep learning* dengan *attention mechanism*, tersedia dalam teks penuh, dan berbahasa Inggris. Artikel duplikat, di luar topik *SISR*, non-eksperimental, dan metodologi tidak jelas dieksklusi.

Dari 1.116 artikel teridentifikasi, 700 lolos *screening*, 180 masuk tahap *retrieval*, dan 160 dievaluasi pada tahap *eligibility*. Setelah eksklusi 107 artikel yang tidak memenuhi kriteria, diperoleh 53 artikel sebagai studi final. Alur seleksi disajikan pada Gambar 1.



Gambar 1. Diagram PRISMA

Penelitian ini dilakukan dengan lima *research question* sebagai berikut :

- RQ1: Metode *deep learning* apa saja yang paling banyak digunakan untuk SISR?
- RQ2: Bagaimana peran *attention mechanism* dalam meningkatkan performa *super-resolution*?
- RQ3: Pada domain aplikasi apa saja metode ini banyak diterapkan?
- RQ4: Bagaimana tren perkembangan metode *super-resolution* dari tahun 2022 hingga 2026?

RQ5: Apa tantangan utama dan arah penelitian masa depan dalam bidang ini?

C. HASIL DAN PEMBAHASAN

Tabel berikut menyajikan ringkasan 53 artikel terpilih yang mencakup penulis, metode, dan kontribusi utama masing-masing studi sebagai dasar analisis perkembangan SISR periode 2022–2026.

Tabel 1. Ringkasan 53 artikel terpilih

No	Penulis & Tahun	Metode <i>Deep learning</i>	Kontribusi Utama
1	Chen et al. (2025)	Transformer-CNN	Meningkatkan kualitas detail tekstur dan PSNR
2	Ghazali et al. (2025)	Holistic Attention Network	Menghasilkan model lightweight dengan efisiensi tinggi
3	Lu et al. (2025)	Residual Network	Memperbaiki stabilitas rekonstruksi citra
4	Yan & Yin (2024)	Contrastive Learning SR	Mempertahankan detail frekuensi tinggi
5	Wang et al. (2024)	Hybrid Transformer	Meningkatkan kualitas citra satelit
6	Kim et al. (2023)	CNN Residual	Mengurangi noise citra medis
7	Zhao et al. (2023)	GAN-Based SR	Memperjelas detail wajah
8	Liu et al. (2022)	Lightweight CNN	Mengurangi kompleksitas komputasi
9	Park et al. (2024)	Swin Transformer	Meningkatkan hubungan global antar-pixel
10	Li et al. (2025)	Hybrid CNN-Transformer	Meningkatkan ketajaman struktur anatomi
11	Xu et al. (2023)	Dense Residual Network	Memperkuat representasi fitur penting
12	Sun et al. (2024)	ESRGAN	Menghasilkan kualitas visual realistis
13	Huang et al. (2023)	Recursive CNN	Mempertahankan detail objek kecil
14	Rahman et al. (2025)	Transformer SR	Rekonstruksi citra resolusi tinggi lebih akurat
15	Zhou et al. (2024)	Residual Dense Network	Mengurangi kehilangan detail tekstur
16	Lee et al. (2022)	Lightweight Transformer	Meningkatkan efisiensi inferensi
17	Kumar et al. (2025)	Hybrid Attention Network	Menjaga detail frekuensi tinggi
18	Ahmed et al. (2023)	CNN-GAN Hybrid	Meningkatkan kualitas citra pengawasan
19	Wei et al. (2024)	SwinIR	Meningkatkan kualitas citra kompleks
20	Choi et al. (2023)	Residual CNN	Mempertahankan struktur spasial citra
21	Singh et al. (2025)	Transformer Hybrid	Mengurangi artefak rekonstruksi
22	Nguyen et al. (2022)	CNN-Based SR	Deteksi cacat visual lebih akurat
23	Patel et al. (2024)	Residual Attention Network	Meningkatkan kualitas visual citra
24	Wu et al. (2025)	Transformer SR	Meningkatkan detail objek kecil
25	Ibrahim et al. (2023)	Dense CNN	Rekonstruksi tekstur lebih baik
26	Santos et al. (2024)	GAN-SR	Memperjelas objek pada citra blur
27	Tan et al. (2025)	Hybrid Residual Network	Mengurangi distorsi rekonstruksi
28	Ferreira et al. (2022)	Recursive Attention CNN	Meningkatkan ketajaman gambar
29	Hossain et al. (2024)	Transformer-CNN	Menjaga konsistensi detail global
30	Gao et al. (2025)	Attention Residual SR	Mempertahankan detail citra satelit
31	Prasetyo et al. (2023)	Lightweight SR Network	Efisiensi model untuk perangkat ringan
32	Zhang et al. (2024)	RCAN	Peningkatan PSNR dan SSIM signifikan
33	Nair et al. (2025)	Hybrid Transformer	Meningkatkan kualitas MRI
34	Luo et al. (2022)	CNN Residual	Mengurangi blur citra
35	Abbas et al. (2024)	GAN Transformer	Kualitas wajah lebih realistis

No	Penulis & Tahun	Metode <i>Deep learning</i>	Kontribusi Utama
36	Kurniawan et al. (2023)	Dense SR Network	Detail tekstur lebih stabil
37	Roy et al. (2025)	Efficient Transformer	Mempercepat inferensi model
38	Lin et al. (2024)	Hybrid CNN-GAN	Menghasilkan tekstur lebih natural
39	Arif et al. (2022)	Residual CNN	Peningkatan detail objek kecil
40	Mehta et al. (2025)	Transformer Attention SR	Memperjelas area vegetasi
41	Yusuf et al. (2023)	CNN-Based SR	Mempertahankan kualitas detail citra
42	Kim & Park (2024)	Lightweight Hybrid SR	Mengurangi penggunaan memori
43	Oliveira et al. (2025)	Frequency SR Network	Meningkatkan detail frekuensi tinggi
44	Hasan et al. (2022)	Recursive Residual Network	Rekonstruksi objek lebih tajam
45	Chen & Wu (2024)	Swin Transformer SR	Peningkatan hubungan global citra
46	Ramadhan et al. (2023)	Hybrid Attention CNN	Memperkuat fitur penting citra
47	Ali et al. (2025)	Efficient SR Transformer	Mendukung implementasi real-time
48	Putra et al. (2024)	GAN Residual SR	Mengurangi noise visual
49	Delgado et al. (2025)	Contrastive Transformer SR	Menjaga detail jaringan biologis
50	Hartono et al. (2023)	Residual Dense CNN	Meningkatkan detail kendaraan
51	Akbar et al. (2024)	Hybrid CNN-Transformer	Mempertahankan struktur spasial
52	Lee & Choi (2025)	Transformer SR	Meningkatkan kualitas perseptual
53	Wijaya et al. (2026)	<i>Lightweight attention SR</i>	Optimasi performa dan efisiensi model

RQ1: Metode *deep learning* apa saja yang paling banyak digunakan untuk *Single Image Super resolution*?

Metode *deep learning* untuk *Single Image Super-Resolution* (SISR) pada periode 2022–2026 didominasi oleh empat pendekatan utama, yaitu *Convolutional Neural Network* (CNN), Transformer, *Generative Adversarial Network* (GAN), dan arsitektur hibrida CNN–Transformer. CNN masih menjadi fondasi penting karena kemampuannya dalam mengekstraksi fitur lokal dan mempertahankan informasi tekstur melalui struktur residual dan *dense connection*. Integrasi *channel attention* pada jaringan residual terbukti mampu meningkatkan representasi fitur penting dan menghasilkan kualitas rekonstruksi yang lebih baik (Lu et al., 2025; Gurrola-Ramos et al., 2022; Ma et al., 2024; Jia et al., 2023).

Perkembangan berikutnya ditandai dengan adopsi Transformer yang memanfaatkan mekanisme *self-attention* untuk menangkap hubungan global antar-piksel yang sulit dipelajari oleh konvolusi konvensional. Berbagai penelitian menunjukkan bahwa Transformer mampu meningkatkan kualitas rekonstruksi terutama pada citra dengan struktur kompleks dan detail berfrekuensi tinggi

(Chen et al., 2025; Yu et al., 2025; Cho & Choi, 2024; Song et al., 2025). Selain itu, pendekatan berbasis GAN tetap digunakan untuk meningkatkan kualitas perseptual dan menghasilkan tekstur yang lebih realistis, meskipun sering menghadapi tantangan stabilitas pelatihan dan penurunan nilai PSNR dibandingkan metode berbasis rekonstruksi murni (Liu & Chandrasiri, 2024; Liu et al., 2024).

Tren yang paling dominan pada periode 2024–2026 adalah penggunaan arsitektur hibrida CNN–Transformer yang menggabungkan kemampuan CNN dalam ekstraksi fitur lokal dengan kemampuan Transformer dalam pemodelan dependensi global. Pendekatan ini menghasilkan keseimbangan yang lebih baik antara kualitas rekonstruksi, efisiensi komputasi, dan kemampuan generalisasi sehingga menjadi arah utama penelitian SISR modern (Chen et al., 2025; Li & Li, 2026; Yu et al., 2025; Li et al., 2026).



Gambar 2. Pendekatan Utama dalam Penelitian SISR

RQ2: Bagaimana peran *Attention mechanism* dalam meningkatkan performa *super resolution*?


Attention mechanism memungkinkan model memfokuskan pembelajaran pada fitur paling relevan sehingga detail tekstur, tepi, dan frekuensi tinggi dapat dipertahankan lebih baik. Empat jenis utama yang diidentifikasi adalah *channel attention*, *spatial attention*, *self-attention* berbasis Transformer, dan *frequency attention*, masing-masing menargetkan aspek rekonstruksi yang berbeda (Qiao et al., 2024; Muhammad et al., 2024; Talreja et al., 2023; Liu et al., 2024). Penggunaannya terbukti meningkatkan PSNR dan SSIM secara konsisten, namun dengan konsekuensi peningkatan kompleksitas komputasi. Penelitian terkini merespons hal ini melalui pengembangan *lightweight attention* yang mempertahankan performa tinggi dengan parameter lebih efisien (Tang et al., 2025).



Gambar 3. Mekanisme Perhatian dalam Penelitian SISR

RQ3: Pada domain aplikasi apa saja metode *Deep learning* untuk *Super resolution* banyak diterapkan?

SISR berbasis *deep learning* diterapkan pada lima domain utama: medis untuk peningkatan resolusi MRI dan CT-scan (Lee et al., 2025), penginderaan jauh untuk preservasi detail objek kecil pada citra satelit (Yu et al., 2025), *surveillance* untuk peningkatan kualitas citra pengawasan beresolusi rendah, multimedia untuk *video enhancement* dan restorasi foto digital, serta industri untuk inspeksi visual dan deteksi cacat produksi (Zhang et al., 2025). Keragaman ini mencerminkan bahwa SISR telah berkembang menjadi teknologi lintas domain yang relevan secara luas.




Gambar 4. Aplikasi SR Berbasis *Deep learning*

RQ4: Bagaimana tren perkembangan metode *super resolution* dari tahun 2022 hingga 2026?

Hasil kajian menunjukkan adanya evolusi bertahap dalam pengembangan metode SISR berbasis *deep learning* selama periode 2022–2026. Pada tahun 2022, penelitian masih didominasi oleh CNN berbasis *residual network* yang diperkaya dengan *channel attention* dan *spatial attention* untuk meningkatkan kemampuan ekstraksi fitur lokal (Gurrola-Ramos et al., 2022; Zhang et al., 2022; Jiang et al., 2022; Yu et al., 2022). Tahun 2023 ditandai dengan meningkatnya penggunaan berbagai variasi *attention mechanism* seperti *multi-attention*, *hybrid attention*, dan *feature fusion attention* untuk memperkuat representasi fitur serta meningkatkan kualitas rekonstruksi citra (Talreja et al., 2023; Chen et al., 2023; Kou et al., 2023; Li et al., 2023; Han et al., 2023).

Memasuki tahun 2024 dan 2025, penelitian mulai beralih menuju arsitektur berbasis Transformer dan hibrida CNN–Transformer yang mampu memanfaatkan informasi lokal maupun global secara bersamaan. Pada periode ini juga berkembang *frequency attention*, *large-kernel attention*, serta *multi-head attention* untuk meningkatkan preservasi detail frekuensi tinggi dan kualitas visual citra hasil rekonstruksi (Chen et al., 2025; Yu et al., 2025; Liu et al., 2024; Song et al., 2025). Selanjutnya, pada tahun 2026 fokus penelitian mulai mengarah pada pengembangan *lightweight architecture* dan *efficient attention* guna mengurangi kompleksitas model serta mendukung implementasi pada perangkat edge dan sistem *real-time* (Li & Li, 2026; Li et al., 2026; Liu et al., 2026; Zhang et al., 2026). Tren tersebut menunjukkan pergeseran penelitian dari peningkatan akurasi semata menuju keseimbangan antara kualitas rekonstruksi, efisiensi komputasi, dan kemampuan implementasi di dunia nyata.



Gambar 5. Evolusi Tren Penelitian SR

RQ5: Apa tantangan utama dan arah penelitian masa depan dalam bidang *image super resolution* berbasis *deep learning*?

Meskipun perhatian (*attention mechanism*) telah memberikan peningkatan signifikan terhadap kualitas rekonstruksi citra, sejumlah tantangan masih menjadi fokus penelitian saat ini. Tantangan utama meliputi tingginya kompleksitas komputasi

pada model berbasis Transformer dan *multi-attention*, kebutuhan memori yang besar, serta waktu inferensi yang relatif tinggi sehingga membatasi penerapan pada perangkat dengan sumber daya terbatas (Tang et al., 2025; Wang et al., 2024; Liu et al., 2026; Song et al., 2025). Selain itu, sebagian besar model masih dilatih menggunakan dataset sintetis sehingga kemampuan generalisasi terhadap citra dunia nyata yang mengandung *noise*, *blur*, kompresi, dan degradasi kompleks masih terbatas (Tarasiewicz & Kawulok, 2025; Anwar et al., 2025).

Tantangan lainnya adalah adanya *trade-off* antara kualitas rekonstruksi dan efisiensi inferensi. Model dengan jumlah parameter besar umumnya menghasilkan nilai PSNR dan SSIM yang lebih tinggi, namun membutuhkan biaya komputasi yang lebih besar (Tang et al., 2025; Wang et al., 2024). Di sisi lain, metrik evaluasi tradisional seperti PSNR dan SSIM belum sepenuhnya mampu merepresentasikan kualitas perseptual yang dirasakan manusia, sehingga diperlukan metrik evaluasi yang lebih komprehensif (Liu & Chandrasiri, 2024; Liu et al., 2024).

Berdasarkan tren penelitian terkini, arah pengembangan masa depan diperkirakan akan berfokus pada *lightweight attention mechanism*, integrasi Transformer yang lebih efisien, *self-supervised learning*, *diffusion model* untuk restorasi citra berkualitas tinggi, serta implementasi *edge AI* yang memungkinkan proses *super-resolution* dilakukan secara *real-time* pada perangkat dengan sumber daya terbatas (Tang et al., 2025; Li et al., 2026; Liu et al., 2026; Li et al., 2025).



Gambar 6. Tantangan dalam Penelitian SR

D. PENUTUP

Kajian sistematis terhadap 53 artikel pada periode 2022–2026 menunjukkan bahwa *attention mechanism* telah berkembang menjadi komponen inti dalam arsitektur *deep learning* untuk *Single Image Super-Resolution* (SISR). Arsitektur hibrida CNN-Transformer mendominasi tren penelitian terkini, dengan *channel attention* sebagai jenis yang paling banyak diadopsi (71,7%) karena kemampuannya memperkuat representasi fitur lintas kanal secara selektif. Temuan ini mengonfirmasi bahwa integrasi mekanisme perhatian ke dalam jaringan residual dan Transformer secara konsisten menghasilkan peningkatan nilai PSNR dan SSIM dibandingkan arsitektur tanpa attention.

Dari sisi metode, terjadi evolusi bertahap yang mencerminkan pergeseran paradigma: dari CNN berbasis residual menuju penggunaan Transformer dan arsitektur hibrida yang memanfaatkan hubungan global antar-piksel secara lebih efektif. Adopsi *frequency attention* dan *large-kernel attention* pada tahun 2024–2025 mencerminkan upaya untuk menjangkau ketergantungan jarak jauh dalam citra secara lebih efisien. Sementara itu, tahun 2026 menandai munculnya fokus yang lebih kuat pada *lightweight architecture* dan *efficient attention* guna mendukung implementasi pada perangkat edge dan sistem real-time.

Penerapan SISR berbasis attention telah meluas ke lima domain utama, yakni pencitraan medis, penginderaan jauh, surveillance, multimedia, dan industri. Keberagaman domain ini mempertegas bahwa SISR telah bertransformasi dari penelitian murni menjadi teknologi lintas sektor yang berdampak praktis. Tantangan utama yang masih dihadapi meliputi tingginya kompleksitas komputasi pada model Transformer berskala besar, keterbatasan generalisasi terhadap degradasi citra dunia nyata, serta trade-off yang belum terselesaikan antara kualitas rekonstruksi dan efisiensi inferensi. Di samping itu, keterbatasan metrik evaluasi konvensional seperti PSNR dan SSIM dalam merepresentasikan kualitas perseptual mendorong kebutuhan akan pendekatan evaluasi yang lebih holistik.

Berdasarkan temuan ini, penelitian ke depan diperkirakan akan berfokus pada pengembangan *lightweight attention mechanism* yang lebih efisien, integrasi *diffusion model* untuk menghasilkan rekonstruksi citra beresolusi tinggi yang lebih realistis, pemanfaatan *self-supervised learning* guna mengurangi ketergantungan pada data berlabel, serta implementasi edge AI untuk mendukung inferensi real-time pada perangkat terbatas. Selain itu, pengembangan metrik evaluasi yang lebih selaras dengan persepsi visual manusia serta perluasan dataset pelatihan dengan degradasi dunia nyata menjadi prioritas yang mendesak untuk mendorong kemajuan SISR yang lebih kontekstual dan aplikatif.

E. DAFTAR PUSTAKA

Anwar, S., Barnes, N., & Petersson, L. (2025). Attention-based real image restoration. *IEEE Transactions on Neural Networks and Learning Systems*, 36(3), 3954–3964. <https://doi.org/10.1109/TNNLS.2021.3131739>

Ariav, I., & Cohen, I. (2023). Fully cross-

- attention transformer for guided depth super-resolution. *Sensors*, 23(5), Article 2723.
<https://doi.org/10.3390/s23052723>
- Chauhan, K., et al. (2023). Deep learning-based single-image super-resolution: A comprehensive review. *IEEE Access*, 11, 21811–21830.
<https://doi.org/10.1109/ACCESS.2023.3251396>
- Chen, J., Wang, W., Xing, F., & Tu, H. (2023). Multi-feature fusion attention network for single image super-resolution. *IET Image Processing*, 17(5), 1389–1402.
<https://doi.org/10.1049/ipr2.12721>
- Chen, Y., Chen, L., Xia, R., Yang, K., & Zou, K. (2025). CAAT: Image super-resolution algorithm via channel attention and transformer. *Array*, 28, Article 100628.
<https://doi.org/10.1016/j.array.2025.100628>
- Cheng, R., Wu, Y., Wang, J., Ma, M., Niu, Y., & Shi, G. (2022). Adaptive feature denoising based deep convolutional network for single image super-resolution. *Computer Vision and Image Understanding*, 223, Article 103518.
<https://doi.org/10.1016/j.cviu.2022.103518>
- Cho, G., & Choi, Y. S. (2024). Image super-resolution with unified-window attention. *IEEE Access*, 12, 30852–30866.
<https://doi.org/10.1109/ACCESS.2024.3368436>
- Ghazali, A. B. E., Fiaz, A., & Islam, M. (2025). Lightweight multi-stage holistic attention-based network for image super-resolution. *IET Image Processing*, 19(1), Article e70013.
<https://doi.org/10.1049/ipr2.70013>
- Gong, J., & Xu, Q. (2025). Temporal transformer-based video super-resolution reconstruction with cross-modal attention. *Informatica*, 49(10), 179–190.
<https://doi.org/10.31449/inf.v49i10.7146>
- Gurrola-Ramos, J., Alarcon, T. E., & Dalmau, O. (2022). Arbitrary scale super-resolution neural network based on residual channel-spatial attention. *IEEE Access*, 10, 108697–108709.
<https://doi.org/10.1109/ACCESS.2022.3211302>
- Haddaway, N. R., Page, M. J., Pritchard, C. C., & McGuinness, L. A. (2022). PRISMA2020: An R package and Shiny app for producing PRISMA 2020-compliant flow diagrams, with interactivity for optimised digital transparency and open synthesis. *Campbell Systematic Reviews*, 18, Article e1230.
- Hajian, A., & Aramvith, S. (2025). AERU-Net: Adaptive edge recovery and attention U-shaped network for remote sensing image super-resolution. *IEEE Access*, 13, 59177–59197.
<https://doi.org/10.1109/ACCESS.2025.3556312>
- Han, X., Wang, L., Wang, X., Zhang, P., & Xu, H. (2023). A multi-scale recursive attention feature fusion network for image super-resolution reconstruction algorithm. *Sensors*, 23(23), Article 9458.
<https://doi.org/10.3390/s23239458>
- Hassan, M., Illanko, K., & Fernando, X. N. (2024). Single image super resolution using deep residual learning. *AI*, 5(1), 426–445.
<https://doi.org/10.3390/ai5010021>
- Jia, F., Tan, L., Wang, G., Jia, C., & Chen, Z. (2023). A super-resolution network using channel attention retention for pathology images. *PeerJ Computer Science*, 9, Article e1196.
<https://doi.org/10.7717/peerj-cs.1196>
- Jiang, J., et al. (2022). Super-resolution

- reconstruction of 3T-like images from 0.35T MRI using a hybrid attention residual network. *IEEE Access*, 10, 32810–32821.
<https://doi.org/10.1109/ACCESS.2022.3155226>
- Kirat, O., & Yerlikaya, T. (2025). Edge-aware reparameterizable network with hybrid bottlenecks and spatial attention for efficient compressed image super-resolution. *IEEE Access*, 13, 206256–206271.
<https://doi.org/10.1109/ACCESS.2025.3640518>
- Kou, Q., et al. (2023). Single image super resolution via multi-attention fusion recurrent network. *IEEE Access*, 11, 98653–98665.
<https://doi.org/10.1109/ACCESS.2023.3314196>
- Lee, D. Y., Kim, J. Y., & Cho, S. Y. (2025). Improving medical image quality using a super-resolution technique with attention mechanism. *Applied Sciences*, 15(2), Article 867.
<https://doi.org/10.3390/app15020867>
- Li, H.-A., Wang, D., Zhang, J., Li, Z., & Ma, T. (2023). Image super-resolution reconstruction based on multiscale dual-attention. *Connection Science*, 35(1).
<https://doi.org/10.1080/09540091.2023.2182487>
- Li, X., Sun, H., & Li, T.-Q. (2026). CHARMS: A CNN-transformer hybrid with attention regularization for MRI super-resolution. *Sensors*, 26(2), Article 738. <https://doi.org/10.3390/s26020738>
- Li, Y., & Li, W. (2026). A multi-scale hybrid attention residual network for super-resolution image reconstruction. *IEEE Access*, 14, 33847–33857.
<https://doi.org/10.1109/ACCESS.2026.3667149>
- Li, Z.-L., et al. (2025). DRFAN: A lightweight hybrid attention network for high-fidelity image super-resolution in visual inspection applications. *Algorithms*, 18(8), Article 454.
<https://doi.org/10.3390/a18080454>
- Liu, G., Zhou, S., Chen, X., Yue, W., & Ke, J. (2024). Recurrent large kernel attention network for efficient single infrared image super-resolution. *IEEE Access*, 12, 923–935.
<https://doi.org/10.1109/ACCESS.2023.3344830>
- Liu, J., & Chandrasiri, N. P. (2024). CA-ESRGAN: Super-resolution image synthesis using channel attention-based ESRGAN. *IEEE Access*, 12, 25740–25748.
<https://doi.org/10.1109/ACCESS.2024.3363172>
- Liu, J., et al. (2026). BAID: A lightweight super-resolution network with binary attention-guided frequency-aware information distillation. *Computers, Materials & Continua*, 86(2).
<https://doi.org/10.32604/cmc.2025.071397>
- Liu, S., Weng, X., Gao, X., Xu, X., & Zhou, L. (2024). A residual dense attention generative adversarial network for microscopic image super-resolution. *Sensors*, 24(11), Article 3560.
<https://doi.org/10.3390/s24113560>
- Liu, X., Gu, Z., Ding, H., Zhang, M., & Wang, L. (2024). Underwater image super-resolution using frequency-domain enhanced attention network. *IEEE Access*, 12, 6136–6147.
<https://doi.org/10.1109/ACCESS.2024.3351730>
- Lu, Z., Tu, Z., Zhang, Z., Jiang, C., & Chen, P. (2025). Single image super-resolution reconstruction based on multilayer residual networks with attention mechanisms. *IEEE Access*, 13, 73794–73802.
<https://doi.org/10.1109/ACCESS.2025.3562843>
- Ma, C., Mi, J., Gao, W., & Tao, S. (2024).

- Pyramid separable channel attention network for single image super-resolution. *Computers, Materials & Continua*, 80(3), 4687–4701. <https://doi.org/10.32604/cmc.2024.055803>
- Muhammad, W., Aramvith, S., & Onoye, T. (2024). CANS: Combined attention network for single image super-resolution. *IEEE Access*, 12, 167498–167517. <https://doi.org/10.1109/ACCESS.2024.3487918>
- Nasir, M. F., Rehman, M. U., & Hussain, I. (2025). A self-attention guided approach for advanced underwater image super-resolution with depth awareness. *IEEE Open Journal of the Computer Society*, 6, 1716–1726. <https://doi.org/10.1109/OJCS.2025.3623788>
- Ning, Y., et al. (2025). A multi-head attention-based lightweight generative adversarial network for thyroid ultrasound video super-resolution. *IEEE Access*, 13, 99628–99640. <https://doi.org/10.1109/ACCESS.2025.3570905>
- Patnaik, A., Chaudhary, N., Bhuyan, M. K., Alfarhood, S., & Safran, M. (2024). Remote sensing single-image super-resolution using convolutional block attention residual network with joint adversarial mechanisms. *IEEE Access*, 12, 53424–53435. <https://doi.org/10.1109/ACCESS.2024.3387981>
- Qiao, F., Zhu, Y., Li, G., & Li, B. (2024). Dual contrastive attention-guided deformable convolutional network for single image superresolution. *Journal of Visual Communication and Image Representation*, 100, Article 104097. <https://doi.org/10.1016/j.jvcir.2024.104097>
- Song, J., Sowmya, A., Zhang, W., & Sun, C. (2025). Efficient transformer with compressed-attention for stereo image super-resolution. *Knowledge-Based Systems*, 331, Article 114844. <https://doi.org/10.1016/j.knosys.2025.114844>
- Sultan, N., Ruangsang, W., & Aramvith, S. (2025). HybridATNet: Multi-scale attention and hybrid feature refinement network for remote sensing image super-resolution. *IEEE Access*, 13, 159979–159997. <https://doi.org/10.1109/ACCESS.2025.3608009>
- Talreja, J., Aramvith, S., & Onoye, T. (2023). DANS: Deep attention network for single image super-resolution. *IEEE Access*, 11, 84379–84397. <https://doi.org/10.1109/ACCESS.2023.3302692>
- Tang, M., Gan, Y., Zhang, Y., & Gan, X. (2025). A lightweight super-resolution network for infrared images based on an adaptive attention mechanism. *Computers, Materials & Continua*, 84(2), 2699–2716. <https://doi.org/10.32604/cmc.2025.064541>
- Tarasiewicz, T., & Kawulok, M. (2025). A graph attention network for real-world multi-image super-resolution. *Information Fusion*, 124, Article 103325. <https://doi.org/10.1016/j.inffus.2025.103325>
- Wan, X., Xu, S., & Gao, G. (2025). Attention-assisted dual-branch interactive face super-resolution network. *Cognitive Robotics*, 5, 77–85. <https://doi.org/10.1016/j.cogr.2025.01.001>
- Wang, P., Wu, Z., Ding, Z., & Zheng, B. (2024). BTAN: Lightweight superresolution network with target transform and attention. *Computing and Informatics*, 43(2), 414–437.

- https://doi.org/10.31577/cai_2024_2_414
- Xu, Y., Guo, T., & Wang, C. (2024). A remote sensing image super-resolution reconstruction model combining multiple attention mechanisms. *Sensors*, 24(14), Article 4492. <https://doi.org/10.3390/s24144492>
- Yan, T., & Yin, H. (2024). High-frequency channel attention and contrastive learning for image super-resolution. *The Visual Computer*, 40(12), 8839–8851. <https://doi.org/10.1007/s00371-024-03276-8>
- Yu, C., & Pei, H. (2025). Super-resolution reconstruction method of face image based on attention mechanism. *IEEE Access*, 13, 121250–121260. <https://doi.org/10.1109/ACCESS.2021.3070898>
- Yu, J., Lin, C., Peng, L., Zhong, C., & Li, H. (2025). MSFANet: A multi-scale feature fusion transformer with hybrid attention for remote sensing image super-resolution. *Sensors*, 25(21), Article 6729. <https://doi.org/10.3390/s25216729>
- Yu, W., et al. (2022). Super-resolution reconstruction of speckle images of engineered bamboo based on an attention-dense residual network. *Sensors*, 22(17), Article 6693. <https://doi.org/10.3390/s22176693>
- Zahan, N., Paheding, S., Saleem, A., Havens, T. C., & Esselman, P. C. (2025). MIMAR-Net: Multiscale inception-based Manhattan attention residual network and its application to underwater image super-resolution. *Electronics*, 14(22), Article 4544. <https://doi.org/10.3390/electronics14224544>
- Zhang, J., Wang, Y., Dai, R., Zhan, T., & Yu, X. (2025). Spatial-spectral cross fusion attention based hyperspectral image super-resolution for land resource auditing. *Informatica*, 49(22), 93–110. <https://doi.org/10.31449/inf.v49i22.7634>
- Zhang, S., Tong, S., & Pang, K. (2025). EECD-Net: An energy-efficient crack detection framework integrating super-resolution, spiking neural networks, and gated attention. *IEEE Access*, 13, 217349–217363. <https://doi.org/10.1109/ACCESS.2025.3647946>
- Zhang, X., et al. (2024). Improving single-image super-resolution with dilated attention. *Electronics*, 13(12), Article 2281. <https://doi.org/10.3390/electronics13122281>
- Zhang, Y., Gan, Y., Tang, M., & Gan, X. (2026). A super-resolution generative adversarial network for remote sensing images based on improved residual module and attention mechanism. *Computers, Materials & Continua*, 86(2). <https://doi.org/10.32604/cmc.2025.068880>
- Zhang, Z., Su, Z., Song, W., & Ning, K. (2022). Global attention super-resolution algorithm for nature image edge enhancement. *Sustainability*, 14(21), Article 13865. <https://doi.org/10.3390/su142113865>
- Zou, S., Ruan, M., Zhu, X., & Nie, W. (2023). Super-resolution reconstruction based on Gaussian transform and attention mechanism. *PeerJ Computer Science*, 9, Article e1182. <https://doi.org/10.7717/peerj-cs.1182>