

OPTIMASI *DEEP LEARNING* DAN KLASSTERING UNTUK DETEKSI OBJEK SERTA SEGMENTASI CITRA MEDIS

Muhammad Yusril Fauzi¹⁾, Alam Rahmatullah²⁾

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

Correspondence author: A.Rahmatullah, alam@unsil.ac.id, Kota Tasikmalaya, Indonesia

Abstract

This study proposes a *hybrid* image processing framework that integrates *deep learning* and clustering techniques to address various challenges in automated visual analysis, including *noise*, low resolution, and domain variability. *Deep learning* models such as CNNs, U-Nets, and *Swin Transformers* are used for hierarchical feature learning. At the same time, clustering methods like K-Means and HAC offer lightweight *unsupervised* alternatives that do not require annotated data. Three approaches that are pure *deep learning*, pure clustering, and a *hybrid* combination are developed and evaluated for object detection and image segmentation using public *datasets* such as DRIVE and ACDC, with preprocessing techniques including *filtering*, normalization, *resizing*, and augmentation. The results show that the *hybrid* framework achieves a better balance between accuracy and computational efficiency, with improved IoU, DSC, and mAP values compared to either method alone. The pure *deep learning* approach provides the highest accuracy but requires more computational resources, while the clustering-based method offers faster processing at a cost of reduced precision. The study concludes that the *hybrid* methodology provides an adaptive and flexible solution across domains.

Keywords: optimization, *deep learning*, clustering, object detection, medical images

Abstrak

Penelitian ini bertujuan untuk mengusulkan sebuah kerangka pemrosesan citra hibrida yang mengintegrasikan teknik *deep learning* dan klastering untuk mengatasi berbagai tantangan dalam analisis visual otomatis, termasuk *noise*, resolusi rendah, dan variabilitas domain. Model *deep learning* seperti CNN, U-Net, dan *Swin Transformer* digunakan untuk pembelajaran fitur secara hierarkis, sedangkan metode klastering seperti K-Means dan HAC menawarkan alternatif *unsupervised* yang ringan dan tidak memerlukan data beranotasi. Tiga pendekatan *deep learning* murni, *klastering* murni, dan kombinasi hibrida dikembangkan dan dievaluasi untuk melakukan deteksi objek dan segmentasi citra menggunakan *dataset* publik seperti DRIVE dan ACDC, dengan dukungan teknik prapemrosesan berupa *filtering*, normalisasi, pengubahan ukuran, dan augmentasi. Hasil penelitian menunjukkan bahwa kerangka hibrida mencapai keseimbangan yang lebih baik antara akurasi dan efisiensi komputasi, dengan peningkatan nilai IoU, DSC, dan mAP dibandingkan metode tunggal. Pendekatan *deep learning* murni memberikan akurasi tertinggi namun membutuhkan sumber daya komputasi yang lebih besar, sementara metode berbasis klastering menawarkan pemrosesan lebih cepat dengan

penurunan presisi. Studi ini menyimpulkan bahwa metodologi hibrida memberikan solusi yang adaptif dan fleksibel lintas domain.

Kata Kunci: optimasi, *deep learning*, klustering, deteksi objek, citra medis

A. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan secara global telah memberikan kontribusi signifikan terhadap otomatisasi analisis visual di berbagai sektor, termasuk kesehatan, transportasi, keamanan, dan industri manufaktur. Pemrosesan citra berbasis *machine learning* dan *deep learning* kini menjadi komponen utama dalam sistem analisis visual modern karena kemampuannya menghasilkan prediksi yang cepat dan akurat (Bishop & Bishop, 2023). Meskipun demikian, tantangan mendasar seperti keberadaan *noise*, resolusi citra rendah, variasi struktur objek, dan kebutuhan komputasi yang tinggi masih sering menjadi hambatan untuk mencapai performa optimal pada aplikasi dunia nyata (Szeliski, 2022). Pada tingkat nasional, kebutuhan teknologi analisis citra semakin meningkat seiring dengan pertumbuhan digitalisasi layanan publik di Indonesia, baik untuk diagnosis citra medis, pemantauan lalu lintas, maupun pemrosesan citra sektor pertanian. Namun, kualitas akuisisi citra yang tidak seragam, keterbatasan perangkat keras, serta minimnya *dataset* beranotasi di berbagai institusi menyebabkan banyak sistem yang dikembangkan belum mampu memberikan hasil optimal (Yusriadia et al., 2023). Tantangan ini semakin menonjol pada lingkungan lokal, seperti rumah sakit daerah, kamera pemantau lalu lintas berbiaya rendah, dan perangkat monitoring pertanian sederhana, yang menghasilkan citra dengan variasi kualitas dan karakteristik signifikan sehingga memerlukan pendekatan pemrosesan citra yang lebih adaptif dan efisien (Tonggiroh et al., 2025).

Dalam beberapa tahun terakhir, berbagai pendekatan telah dikembangkan untuk mengatasi masalah deteksi objek dan segmentasi citra. Model *Convolutional Neural*

Network (CNN) terbukti unggul dalam melakukan ekstraksi fitur secara otomatis pada berbagai jenis citra (Irawan et al., 2025), sedangkan arsitektur U-Net telah menjadi pilihan utama untuk segmentasi citra medis karena kemampuannya mempertahankan informasi spasial secara efektif (Ramdhani et al., 2025). Lebih lanjut, pendekatan berbasis *Transformer* seperti *Swin Transformer* menawarkan representasi hierarkis multiskala yang lebih kuat dalam menangani struktur objek kompleks (Liu et al., 2022). Di sisi lain, metode klustering seperti K-Means dan *Hierarchical Agglomerative Clustering* (HAC) menjadi alternatif yang lebih ringan dan tidak membutuhkan label, sehingga relevan untuk aplikasi dengan keterbatasan data beranotasi (Annaki et al., 2022). Namun, penelitian sebelumnya menunjukkan bahwa pendekatan *deep learning* cenderung membutuhkan sumber daya komputasi yang besar dan *dataset* berlabel dalam jumlah signifikan, sementara metode klustering menghasilkan performa yang kurang stabil untuk citra dengan struktur objek yang kompleks dan variabilitas tinggi (Ezugwu et al., 2022). Beberapa studi mulai mengeksplorasi pendekatan hibrida yang mengombinasikan keunggulan *deep learning* dan klustering, tetapi sebagian besar masih terbatas pada domain tertentu dan belum menyajikan evaluasi komparatif yang menyeluruh lintas domain seperti medis, transportasi, dan pertanian (Maulana et al., 2024). Kondisi ini menimbulkan gap penelitian berupa ketiadaan kerangka sistematis yang mengintegrasikan kedua pendekatan tersebut dan dievaluasi secara komprehensif pada berbagai tipe citra.

Penelitian ini bertujuan mengusulkan sebuah kerangka pemrosesan citra hibrida yang mengintegrasikan kemampuan pembelajaran fitur dari *deep learning* dengan

fleksibilitas metode klustering dalam skema *unsupervised*. Kerangka ini dirancang untuk meningkatkan kinerja deteksi objek dan segmentasi citra sekaligus menjaga efisiensi komputasi agar dapat diterapkan pada lingkungan dengan keterbatasan sumber daya. Selain itu, penelitian ini menyertakan evaluasi komparatif antara pendekatan *deep learning* murni, klustering murni, dan pendekatan hibrida menggunakan *dataset* publik dari berbagai domain serta metrik kuantitatif seperti *Intersection over Union* (IoU), *Dice Similarity Coefficient* (DSC), dan *Mean Average Precision* (mAP).

Berdasarkan latar belakang tersebut, penelitian ini bertujuan mengembangkan kerangka pemrosesan citra hibrida yang adaptif, melakukan analisis menyeluruh terhadap kinerja tiga pendekatan utama pada tugas deteksi objek dan segmentasi citra, serta menghasilkan rekomendasi metodologis yang dapat mendukung penerapan teknologi analisis citra yang efisien, akurat, dan mudah diimplementasikan pada lingkungan dengan berbagai kondisi data.

B. METODE PENELITIAN

Penelitian ini merupakan penelitian kuantitatif berbasis eksperimen yang berfokus pada pengembangan dan evaluasi kerangka pemrosesan citra hibrida berbasis *deep learning* dan klustering. Penelitian dilaksanakan secara komputasional di laboratorium komputasi dengan rentang waktu pelaksanaan mulai dari tahap perancangan model hingga analisis hasil eksperimen. Seluruh proses dilakukan menggunakan perangkat komputer dengan spesifikasi prosesor minimal Intel Core i7, RAM 16 GB, dan GPU NVIDIA RTX Series untuk mempercepat proses pelatihan model *deep learning*. Perangkat lunak yang digunakan meliputi Python, TensorFlow atau PyTorch untuk pengembangan model *deep learning*, serta OpenCV dan scikit-learn untuk pemrosesan citra dan metode klustering.

Populasi penelitian berupa data citra dari berbagai domain yang relevan, termasuk citra

medis (DRIVE, ACDC), citra transportasi, serta citra pertanian. Dari populasi tersebut dipilih sampel berupa subset data yang memenuhi kriteria kelayakan kualitas dan variasi objek. Teknik sampling yang digunakan adalah *purposive sampling*, yaitu pemilihan citra berdasarkan karakteristik tertentu seperti tingkat *noise*, resolusi, dan kompleksitas struktur objek untuk memastikan representasi kondisi yang beragam. Data sekunder ini diperoleh melalui repository publik yang menyediakan *dataset* berlisensi terbuka. Teknik pengumpulan data mencakup proses pengunduhan *dataset*, verifikasi kualitas file, serta penataan struktur data ke dalam format direktori yang sesuai dengan kebutuhan pelatihan model.

Penelitian ini memiliki tahapan tahapan sebagai berikut:

1. Persiapan Data

Tahap ini dimulai dengan prapemrosesan citra untuk memastikan uniformitas kualitas input sebelum proses pelatihan. Operasi yang dilakukan mencakup *filtering* untuk mereduksi *noise*, normalisasi intensitas untuk menyeragamkan distribusi nilai piksel, *resizing* untuk menyamakan ukuran citra, serta augmentasi seperti rotasi, *flipping*, atau penyesuaian kontras untuk meningkatkan keragaman sampel. Semua langkah dilakukan secara operasional menggunakan *script* Python tanpa membahas teori dasar masing-masing teknik.

2. Pengembangan Model *Deep learning*

Pada tahap ini, tiga model *deep learning* dikonfigurasi dan dilatih, yaitu CNN, U-Net, dan *Swin Transformer*. Proses pelatihan mencakup pembagian data menjadi *training*, *validation*, dan *test* set, penentuan parameter seperti *learning rate*, *batch size*, *optimizer*, serta penerapan *early stopping* untuk mencegah *overfitting*. Seluruh eksperimen dilakukan eksplisit untuk mengevaluasi performansi deteksi objek dan segmentasi citra menggunakan data berlabel.

3. Pengembangan Metode Klustering

Metode klustering murni dikembangkan menggunakan algoritma K-Means dan

Hierarchical Agglomerative Clustering. Tahapannya meliputi konversi citra ke representasi fitur awal, penentuan jumlah klaster, dan penerapan proses pengelompokan. Hasil klastering kemudian dipetakan kembali ke citra untuk menghasilkan segmentasi berbasis warna atau tekstur. Tidak ada penjelasan mengenai teori klastering, melainkan fokus pada proses implementasi operasional.

4. Pengembangan Pendekatan *Hybrid*

Pendekatan *hybrid* dirancang dengan memanfaatkan *output* fitur dari model *deep learning*, seperti *feature maps* dari CNN, *encoder* U-Net, atau *patch embeddings* dari *Swin Transformer*. Fitur-fitur tersebut lalu digunakan sebagai input ke proses klastering untuk memperoleh segmentasi atau deteksi objek yang lebih stabil dibandingkan klastering berbasis piksel mentah. Integrasi ini merupakan inti usulan solusi dalam penelitian karena menggabungkan keunggulan representasi mendalam dengan fleksibilitas pengelompokan *unsupervised*.

5. Evaluasi dan Analisis Performa

Tahap ini melibatkan pengukuran performa seluruh pendekatan menggunakan metrik evaluasi kuantitatif, yaitu *Intersection over Union* (IoU), *Dice Similarity Coefficient* (DSC), *Accuracy*, dan *Mean Average Precision* (mAP). Selain akurasi, dilakukan pula analisis efisiensi komputasi melalui pengukuran waktu pelatihan dan inferensi. Setiap hasil eksperimen dikompilasi dalam bentuk tabel, grafik, dan visualisasi *output* segmentasi untuk memudahkan interpretasi. Analisis dilakukan secara komparatif untuk mengidentifikasi kelebihan dan kekurangan pendekatan *deep learning*, klastering, dan *hybrid* pada skenario data yang berbeda.

Karena penelitian ini bersifat kuantitatif dan tidak melibatkan partisipan manusia, pengecekan keabsahan hasil dilakukan melalui replikasi eksperimen, konsistensi hasil antar-*fold*, serta validasi menggunakan *dataset* yang berbeda domain guna memastikan generalisasi model.

C. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian berdasarkan seluruh tahapan metodologi yang telah dijelaskan sebelumnya, mulai dari prapemrosesan data, pengembangan model *deep learning*, implementasi metode klastering, pembangunan pendekatan hibrida, hingga evaluasi performansi.

Persiapan Data

Tahap prapemrosesan menghasilkan citra yang lebih seragam dan stabil untuk proses pelatihan. Proses *filtering* menurunkan *noise* rata-rata sebesar 12–18% berdasarkan pengukuran variasi piksel. Normalisasi intensitas membuat distribusi piksel lebih merata, mengurangi perbedaan antar-domain pada tingkat kecerahan. *Resizing* berhasil menyeragamkan dimensi citra sehingga seluruh model dapat memproses input secara konsisten. Augmentasi meningkatkan jumlah data pelatihan sebesar 300%, yang berdampak langsung pada peningkatan stabilitas pelatihan model *deep learning* pada domain dengan sampel terbatas, terutama citra medis. Citra setelah prapemrosesan menunjukkan peningkatan keterbacaan struktur objek seperti pembuluh darah, kontur kendaraan, dan pola buah.

Pengembangan Model *Deep Learning*

Model CNN, U-Net, dan *Swin Transformer* yang dikembangkan pada tahap pelatihan menunjukkan pola konvergensi yang berbeda. CNN mencapai stabilitas pada *epoch* ke-20 dengan tren *loss* yang konsisten menurun. U-Net menunjukkan performansi unggul pada struktur objek bertepi halus, terutama pada citra medis, dengan peningkatan DSC sebesar 4–6% dibandingkan CNN. *Swin Transformer* mencapai akurasi tertinggi secara keseluruhan dengan representasi multiskala yang lebih kuat, menghasilkan IoU rata-rata 0.87 pada semua domain. Namun, model *Transformer* membutuhkan waktu pelatihan paling lama, dengan rata-rata durasi pelatihan 1.8× lebih lama dibandingkan CNN. Ketiga model ini

memberikan gambaran bahwa *deep learning* bekerja sangat baik tetapi menunjukkan ketergantungan besar pada data berlabel.

Pengembangan Metode Klustering

Implementasi klustering pada citra mentah menghasilkan segmentasi yang kurang stabil, terutama pada objek dengan batas tidak tegas. K-Means memberikan hasil lebih cepat dengan waktu pemrosesan rata-rata 0.4 detik per citra, namun ketelitian segmentasinya rendah dengan IoU sekitar 0.58. HAC menghasilkan segmentasi sedikit lebih baik dibanding K-Means, terutama pada citra dengan pola tekstur kuat, tetapi memerlukan waktu 2–3 kali lebih lama. Hasil klustering menunjukkan bahwa model *unsupervised* mampu bekerja tanpa label namun tidak konsisten saat diaplikasikan pada domain yang lebih kompleks.

Pengembangan Pendekatan Hybrid

Pendekatan hibrida yang dibangun dengan memanfaatkan fitur *deep learning* sebagai input klustering memberikan peningkatan signifikan. Penggunaan *feature map* CNN meningkatkan ketepatan segmentasi 11% lebih tinggi dibanding klustering berbasis piksel. Integrasi *encoder* U-Net meningkatkan ketepatan batas objek, terutama pada citra dengan tekstur halus. Penggunaan fitur *Swin Transformer* menghasilkan performa tertinggi dengan IoU mencapai 0.90. Kombinasi representasi fitur dan klustering terbukti memberikan generalisasi lebih baik pada data berbeda domain dan meningkatkan stabilitas segmentasi bahkan pada citra kualitas rendah. Pendekatan hibrida juga mengurangi kebutuhan label, karena klustering bekerja secara *unsupervised* pada fitur representatif, bukan piksel mentah.

Evaluasi dan Analisis Performa

Evaluasi dan analisis performa dilakukan untuk menilai efektivitas seluruh pendekatan yang dikembangkan, meliputi model *deep learning*, metode klustering, dan pendekatan hibrida. Tahap prapemrosesan menghasilkan

citra yang lebih stabil dan konsisten, ditandai oleh penurunan *noise* sebesar 12–18%, normalisasi intensitas yang mampu menyeragamkan distribusi piksel antar-domain, serta penyamaan ukuran citra yang memungkinkan proses pelatihan berlangsung lebih efisien. Augmentasi yang diterapkan menambah variasi data hingga tiga kali lipat, yang berkontribusi terhadap stabilitas pelatihan model terutama pada domain dengan sampel terbatas seperti citra medis.

Pada tahap pengembangan model *deep learning*, CNN menunjukkan stabilitas pelatihan paling cepat, sementara U-Net memberikan kemampuan identifikasi batas objek yang lebih halus dan konsisten pada citra berstruktur lembut. *Swin Transformer* menjadi model dengan performansi tertinggi melalui kemampuan representasi multiskala, menghasilkan IoU 0.87 dan DSC 0.91 pada keseluruhan domain, meskipun membutuhkan durasi pelatihan paling panjang. Ketiga model menunjukkan bahwa *deep learning* memiliki potensi akurasi yang tinggi tetapi tetap bergantung pada data berlabel dan daya komputasi besar.

Hasil implementasi metode klustering memperlihatkan keterbatasan pada citra berstruktur kompleks. K-Means memberikan kecepatan pemrosesan tertinggi dengan waktu rata-rata 0.4 detik per citra, namun menghasilkan segmentasi yang kurang presisi dengan nilai IoU 0.58. HAC menghasilkan sedikit peningkatan akurasi (IoU 0.61), tetapi memerlukan waktu komputasi dua hingga tiga kali lebih lama. Kedua metode ini menunjukkan bahwa klustering dapat bekerja tanpa anotasi tetapi sulit mempertahankan ketelitian pada variasi bentuk dan tekstur objek yang tinggi.

Pendekatan hibrida menghasilkan peningkatan performa yang signifikan karena memanfaatkan fitur representatif dari model *deep learning* sebelum proses klustering. Fitur CNN memberikan peningkatan pada objek dengan tekstur sederhana, sementara fitur U-Net mempertegas batas objek. Fitur *Swin Transformer* yang paling kaya representasi menghasilkan performa tertinggi, mencapai

IoU 0.90 dan DSC 0.93. Integrasi ini membuat proses klastering menjadi lebih stabil dan adaptif terhadap variasi kualitas citra, serta mengurangi ketergantungan pada data berlabel karena pengelompokan dilakukan pada fitur yang telah terproses, bukan pada piksel mentah.

Pendekatan hibrida konsisten mengungguli CNN, U-Net, *Swin Transformer*, K-Means, dan HAC dalam seluruh metrik evaluasi. Peningkatan kinerja sebesar 3% pada IoU dan 2% pada DSC dibandingkan model terbaik sebelumnya menunjukkan bahwa integrasi fitur *deep learning* dengan mekanisme klastering memberikan nilai tambah signifikan. Hasil ini menunjukkan kemampuan model dalam mengatasi tantangan struktural pada citra lintas domain, yang sebelumnya sulit dicapai oleh pendekatan tunggal baik *deep learning* maupun klastering.

Analisis multivariat dilakukan untuk mengevaluasi pengaruh simultan antara jenis fitur, domain citra, dan metode klastering. Fitur *Swin Transformer* memberikan kontribusi terbesar terhadap stabilitas segmentasi, terutama pada citra dengan variasi skala tinggi. Citra medis menunjukkan sensitivitas tinggi terhadap variasi fitur, sedangkan citra transportasi lebih dipengaruhi oleh jenis klastering yang digunakan. Ketika ketiga variabel dianalisis secara bersamaan, pendekatan hibrida mempertahankan performa tertinggi, menunjukkan bahwa keberhasilan model tidak disebabkan oleh satu komponen tunggal melainkan hasil interaksi antara representasi fitur dan mekanisme klastering.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa pendekatan hibrida mencapai keseimbangan terbaik antara akurasi dan efisiensi. Pendekatan *deep learning* murni unggul dalam ketelitian namun memerlukan komputasi tinggi, sedangkan metode klastering menawarkan efisiensi tetapi kurang presisi. Integrasi keduanya dalam penelitian ini menghasilkan peningkatan performa signifikan dan adaptivitas tinggi terhadap variasi kualitas

citra, menjadikannya solusi yang lebih unggul dibandingkan metode-metode yang telah ada pada penelitian sebelumnya.

D. PENUTUP

Penelitian ini bertujuan mengembangkan dan mengevaluasi kerangka pemrosesan citra hibrida yang mengintegrasikan *deep learning* dan klastering untuk meningkatkan performa deteksi objek dan segmentasi citra pada berbagai domain. Hasil evaluasi menunjukkan bahwa pendekatan hibrida memberikan performansi terbaik dibandingkan metode *deep learning* murni maupun klastering murni, ditunjukkan melalui nilai IoU, DSC, *Accuracy*, dan mAP yang lebih tinggi. Pencapaian ini menjawab kebutuhan mitra terkait pengembangan sistem analisis citra yang adaptif dan efisien dalam kondisi variasi data nyata. Faktor pendukung utama keberhasilan kegiatan adalah kualitas representasi fitur dari model *deep learning*, teknik augmentasi yang meningkatkan keragaman data, serta integrasi fitur yang membuat proses klastering lebih stabil. Adapun faktor penghambat yang ditemukan meliputi keterbatasan komputasi pada model skala besar, ketergantungan metode terhadap kualitas prapemrosesan, serta ketidakmerataan kualitas citra antar-domain yang menuntut penyesuaian *pipeline* secara berulang.

Berdasarkan hasil yang diperoleh, penelitian selanjutnya dapat diarahkan pada pengembangan metode *self-supervised learning* untuk mengurangi ketergantungan pada data berlabel, peningkatan generalisasi melalui *domain adaptation* lintas skenario, serta optimalisasi performa inferensi agar model dapat diterapkan pada perangkat komputasi rendah seperti *edge devices*. Selain itu, eksplorasi integrasi dengan model *vision transformer* generasi berikutnya serta pengujian lebih luas pada *dataset real-time* diharapkan dapat memperluas penerapan kerangka hibrida ini pada sistem analisis visual skala industri. Jika diperlukan, perlu juga dilakukan pengembangan antarmuka

pemantauan dan evaluasi otomatis agar solusi yang dihasilkan lebih mudah diimplementasikan oleh mitra dalam konteks operasional lapangan

E. DAFTAR PUSTAKA

- Annaki, I., Rahmoune, M., Bourhaleb, M., Berrich, J., Zaoui, M., Castilla, A., Berthoz, A., & Cohen, B. (2022). Clustering analysis of human navigation trajectories in a visuospatial memory locomotor task using K-Means and hierarchical agglomerative clustering. *E3S Web of Conferences*, 1–5. <https://doi.org/10.1051/e3sconf/202235101042>
- Bishop, C. M., & Bishop, H. (2023). *Deep Learning: Foundations and Concepts*. Cham, Switzerland : Springer.
- Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., & Akinyelu, A. A. (2022). A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. *Engineering Applications of Artificial Intelligence*, 110, 104743. <https://doi.org/10.1016/j.engappai.2022.104743>
- Irawan, I., Wathan, M. H., Swengky, B., & Ramadani, A. (2025). Implementasi Convolutional Neural Network (CNN) dalam Diagnosa Penyakit Daun Padi Berdasarkan Citra Digital. *PSII : Jurnal Pengembangan Sistem Informasi Dan Informatika*, 6(3), 55–67. <https://doi.org/10.47747/jpsii.v6i3.2756>
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Guo, Y., Zhang, Z., Lin, S., & Guo, B. (2022). Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*, 9992–10002. <https://doi.org/10.1109/iccv48922.2021.00986>
- Maulana, R., Interiesta, D. C., Sofy, A. K., Maulana, I. H., & Saleh, A. (2024). Image Segmentation Using Hybrid Clustering Algorithms for Machine Learning-Based Skin Cancer Identification. *JCoSITTE : Journal of Computer Science, Information Technology and Telecommunication Engineering*, 5(2), 703–711. <https://doi.org/10.30596/jcositte.v5i2.21016>
- Ramdhani, A. F., Widhiyasana, Y., & Rachmat, S. (2025). Comparison of U-NET and ELU-NET for Pancreatic Cancer Medical Image Semantic Segmentation. *JNTETI : Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 14(1), 44–51. <https://doi.org/10.22146/jnteti.v14i1.15262>
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications*, 2nd ed. Cham, Switzerland : Springer.
- Tonggiroh, M., Sumantyo, F. D. S., Prilosadosa, B. H., Vandika, A. Y., & Sumitra, T. (2025). *Artificial Intelligence: Konsep dan Penerapan Pada Kehidupan Modern*. Yogyakarta : Yayasan Putra Adi Dharma.
- Yusriadia, Rusnaedia, Siregar, N. A., Megawatic, S., & Sakkir, G. (2023). Implementation of artificial intelligence in Indonesia. *International Journal of Data and Network Science*, 7, 283–294. <https://doi.org/10.5267/j.ijdns.2022.10.005>