

ANALISIS KOMPARATIF U-NET ATTENTION DAN RESNET-50 UNTUK SEGMENTASI SEMANTIK SUNGAI PADA CITRA PENGINDERAAN JAUH

¹⁾Gede Andra Rizqy Wijaya, ²⁾Ni Putu Novita Puspa Dewi, ³⁾Kadek Yota Ernanda Aryanto

¹⁾Ilmu Komputer, Teknik dan Kejuruan, Universitas Pendidikan Ganesha, ²⁾Ilmu Komputer, Teknik dan Kejuruan, Universitas Pendidikan Ganesha, ³⁾Teknik Rekayasa Perangkat Lunak, Teknik dan Kejuruan, Universitas Pendidikan Ganesha

¹⁾gedeandrizarizqywijaya@gmail.com, ²⁾novita.puspa.dewi@undiksha.ac.id,
³⁾yota.ernanda@undiksha.ac.id

INFO ARTIKEL	ABSTRAK
Riwayat Artikel : Diterima : 20 Oktober 2025 Disetujui : 30 Oktober 2025	Pemantauan potensi banjir sungai merupakan langkah penting dalam mitigasi risiko bencana dan perencanaan tata ruang wilayah. Dengan perkembangan zaman dan meningkatnya ketersediaan data citra satelit dengan resolusi tinggi yang mengikutinya, pemantauan potensi banjir bisa dilakukan dengan metode yang terkini, seperti dengan menggunakan metode <i>deep learning</i>, terutama pada <i>semantic segmentation</i>. Dengan menggunakan model <i>semantic segmentation</i> yang berbasis <i>deep learning</i>, pemantauan sungai dalam langkah mitigasi risiko bencana alam bisa dilakukan dengan lebih fleksibel. Dengan menggunakan arsitektur ResNet-50 dan U-Net Attention, didapatkan akurasi yang tinggi, dimana masing-masing arsitektur mencapai tingkat akurasi hingga lebih dari 90%. Model dilatih menggunakan data sungai yang sudah dilakukan masking pada bagian sungainya saja, tidak menghiraukan wilayah lainya seperti genangan air besar lain yang berada diluar area sungai. Dalam penelitian ini juga dapat disimpulkan bahwa arsitektur U-Net Attention memiliki akurasi dan juga ketepatan yang lebih baik dibandingkan dengan arsitektur ResNet-50. Implementasi hasil dari penelitian ini diharapkan dapat mendukung pengembangan sistem pemantauan banjir berbasis teknologi, sehingga bisa meningkatkan kesiapsiagaan dan efisiensi dalam mitigasi bencana alam.
Kata Kunci : Segmentasi Semantik, UNet Attention, ResNet-50	

ARTICLE INFO	ABSTRACT
Article History : Received : Oct 20,2025 Accepted : Oct 30, 2025	<i>Monitoring river flood potential is an essential step in disaster risk mitigation and spatial planning. With technological advancements and the increasing availability of high-resolution satellite imagery, flood potential monitoring can now be conducted using modern approaches such as deep learning, particularly through semantic segmentation methods. By employing deep learning-based semantic segmentation models, river monitoring for disaster mitigation can be performed more flexibly. Using the ResNet-50 and Attention U-Net architectures, high accuracy was achieved, with each model reaching accuracy levels above 90%. The models were trained on river-specific datasets, where only river areas were masked while ignoring other large water bodies outside the river region. The results of this study indicate that the Attention U-Net architecture provides</i>
Keywords: Semantic Segmentation, UNet Attention, ResNet -50	

higher accuracy and precision compared to ResNet-50. The implementation of these findings is expected to support the development of technology-based flood monitoring systems, thereby enhancing preparedness and efficiency in disaster mitigation.

1 PENDAHULUAN

Banjir merupakan salah satu bencana alam yang sering terjadi di berbagai wilayah, terutama di kawasan yang memiliki curah hujan tinggi. Banjir sungai adalah salah satu contoh banjir yang luas dan sering menyebabkan kerusakan ekonomi, sosial, dan lingkungan yang besar diseluruh dunia (Jiang *et al.*, 2022). Akibat dari dampak jangka Panjang dan jangka pendek dari melelehnya gletser, jumlah dari debit air yang ada pada aliran sungai terus meningkat menyebabkan banyak kehancuran pada daerah dataran rendah yang bersentuhan dengan aliran sungai (Valijonovich *et al.*, 2021).

Banjir dapat dipicu dari beberapa faktor alam utama, seperti hujan berintensitas dan durasi tinggi, peleburan gletser es, serta penurunan kapasitas alir sungai karena proses alami. Selain faktor alam, manusia juga bisa menjadi salah satu alasan banjir terjadi. Aktivitas manusia seperti pengelolaan lahan yang buruk, alih fungsi lahan budidaya menjadi salah satu faktor terjadinya banjir (Andewi *et al.*, 2025). Melelehnya gletser adalah salah satu dampak dari pemanasan global yang sedang terjadi saat ini. Dengan berlangsungnya pemanasan global, secara tidak langsung menyebabkan bencana alam lainnya terjadi, seperti banjir (Salim & Siswanto, 2021). Selain karena pemanasan global, salah satu penyebab terjadinya banjir adalah intensitas curah hujan yang tinggi. Curah hujan dengan intensitas tinggi dan berlangsung dengan waktu yang cukup lama, merupakan faktor lain dalam terjadinya banjir (Ginting, 2021).

Banjir bisa menimbulkan kerugian besar, mulai dari ekonomi, terhentinya aktivitas warga, sampai jatuhnya korban jiwa (Safitri & Putra, 2022). Karena itu, penting untuk memantau tanda-tanda banjir dengan melihat perubahan aliran dan luasnya air sungai dari waktu ke waktu. Caranya, kita memanfaatkan foto satelit berkala untuk melihat apakah sungai makin melebar, permukaan air naik, atau area tergenang meluas. Dengan bantuan pemodelan berbasis kecerdasan buatan, peta air bisa dibuat

lebih cepat dan konsisten. Hasilnya membantu petugas dan pemerintah membaca tren lebih awal, menetapkan status siaga, serta merencanakan langkah penanganan yang tepat agar dampak banjir bisa ditekan.

Dengan adanya perkembangan teknologi penginderaan jarak jauh, ketersediaan data citra satelit dengan resolusi yang tinggi semakin meningkat. Perkembangan teknologi ini membuka peluang baru dalam analisis data spasial. Termasuk untuk pemantauan aliran sungai dan wilayah yang berpotensi terkena dampak banjir. Dengan menggabungkan data citra satelit dan memanfaatkan metode deep learning, pemantauan aliran sungai bisa dilakukan dengan lebih leluasa terutama pada aliran sungai yang kompleks (Dewi *et al.*, 2025). Salah satunya melalui penggunaan arsitektur dengan mekanisme attention, yang mampu memperkuat detail spasial dan mempertahankan batas objek pada proses segmentasi (Sun *et al.*, 2022).

Penelitian ini membandingkan dua arsitektur deep learning, yaitu U-Net Attention dan ResNet-50, untuk melakukan semantic segmentation pada citra satelit yang berfokus pada area sungai. Kedua model dilatih menggunakan data area sungai yang sama, kemudian diuji untuk mengevaluasi akurasi hasil segmentasi. Penelitian sebelumnya telah menunjukkan bahwa pendekatan deep learning dapat mencapai akurasi yang tinggi dalam tugas segmentasi. Misalnya, Vandaele *et al.* (2021) berhasil menggunakan metode transfer learning pada citra kamera sungai dan memperoleh akurasi lebih dari 91% dalam segmentasi air. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem pemantauan banjir berbasis teknologi yang lebih efektif dan efisien.


2 METODE

2.1 Semantic Segmentation

Semantic segmentation adalah metode untuk melakukan pemisahan gambar menjadi wilayah yang memiliki labelnya sendiri untuk

setiap wilayah yang telah ditentukan (Neupane et al., 2021). Masing-masing wilayah ini akan memiliki properti yang sebanding namun tidak beririsan dengan wilayah lainnya (Jiang et al., 2023). Biasanya semantic segmentation dilakukan dengan menggunakan metode pixel-based, edge-detection-based, atau region-based (Neupane et al., 2021). Dalam penelitian ini, digunakan metode region-based dalam melakukan semantic segmentation. Metode ini dipilih karena model diharapkan untuk mempelajari fitur dari bagian yang diberikan label saja; dalam kasus ini, fitur yang ingin difokuskan adalah fitur dari sungai.

Untuk melakukan semantic segmentation dengan metode region-based, maka data yang digunakan harus memiliki label pada fitur-fitur yang ingin dipelajari oleh model. Data akan dibagi menjadi gambar asli dan label, dimana dalam label, merupakan rujukan dari area yang ingin difokuskan fiturnya untuk dipelajari dari gambar asli.



Gambar 1. Dataset yang Digunakan

Pada Gambar 1 terdapat Train Image yang merupakan data latihan model dan Train Label yang merupakan masking sebagai label dari data dari Train Image. Dapat dilihat bahwa gambar yang digunakan untuk melatih model terdapat beberapa genangan air yang tertangkap oleh satelit, namun pada pasangan labelnya hanya badan sungainya saja yang dilakukan masking. Dengan begitu model bisa mengetahui

fitur mana yang harus difokuskan saat model dilatih.

Karena pada penelitian ini menggunakan metode *region-based*, maka data yang ada harus dilabelkan secara manual satu per satu, dan akan memakan waktu yang lama (Qureshi et al., 2023).


2.2 Deep Learning

Deep learning merupakan arsitektur dalam machine learning modern yang dapat meningkatkan performa dan presisi dari hasil training model machine learning (Neupane et al., 2021). Dalam beberapa tahun terakhir, deep learning telah berkembang dengan sangat baik hingga dapat mencapai hasil yang memuaskan, terutama dalam tugas visi komputer (Al-Huda et al., 2023).

Segmentasi menggunakan metode deep learning dapat dikategorikan dalam instance segmentation dan semantic segmentation (Roy & Ameer, 2021). Saat menggunakan metode deep learning untuk melakukan semantic segmentation, akurasi yang tinggi tidak bisa langsung didapatkan, karena data yang digunakan terkadang memiliki ketidakseimbangan di dalamnya (Ulku & Akagündüz, 2022).

2.3 ResNet-50

ResNet-50 adalah varian dari arsitektur model deep learning ResNet. Komponen utama yang ada pada model arsitektur ResNet-50 adalah residual block, di mana masing-masing residual block mengandung dua sampai tiga convolutional layers. Dalam ResNet-50 juga diperkenalkan skip block dalam setiap residual block-nya, yang membiarkan informasi diteruskan langsung ke layers lainnya (Zhou et al., 2024). Arsitektur ResNet-50 dapat dilihat pada Gambar 2.




Gambar 2. Arsitektur ResNet-50

2.4 UNet Attention


U-Net merupakan arsitektur model deep learning yang awalnya digunakan untuk tugas semantic segmentation pada gambar biomedis yang diperkenalkan pada tahun 2015 (Mahmoud et al., 2023). U-Net memiliki dua block di dalam

arsitektur, yaitu encoder dan decoder. Istilah “U” dalam U-Net merujuk pada cara kerja antara encoder dan decoder di dalam arsitektur tersebut, di mana encoder melakukan downsampling untuk mengekstraksi fitur-fitur pada gambar, sedangkan decoder melakukan upsampling sambil mengurangi jumlah filter pada citra. Berikut merupakan gambar dari arsitektur U-Net.




Gambar 3. Arsitektur UNet

Dibandingkan dengan arsitektur U-Net, U-Net Attention memiliki block tambahan yang berfungsi sebagai skip connection pada arsitektur. Block ini adalah attention block yang memiliki dua input dan satu output. Input pertama berasal dari encoder yang sama, sedangkan input kedua didapatkan dari decoder yang berada di bawahnya. Masing-masing input membawa sifat yang melekat dari fitur-fitur tersebut. Input dari encoder membawa informasi spasial, sedangkan input dari decoder membawa representasi fitur yang lebih baik. Kedua input ini kemudian digabungkan dan dilewatkan melalui fungsi aktivasi Rectified Linear Unit (ReLU), yang berfungsi menghapus nilai-nilai negatif dari kedua input dan menghasilkan output positif (Jain et al., 2022). Setelah itu, hasil tersebut melewati sigmoid layer yang mengubah nilai ke dalam rentang [0,1], memberikan nilai attention coefficient atau weights, di mana nilai yang mendekati 1 menandakan bahwa fitur tersebut lebih relevan. Nilai tersebut kemudian diteruskan melalui skip connection setelah dilakukan upsampling ke dimensi awal dari input yang berasal dari encoder. Gambaran alur Attention Gate dapat dilihat pada Gambar 4.



Gambar 4. Attention Gate

Biasanya UNet attention akan memiliki empat encoder dan decoder didalam arsitektur. Dalam arsitektur sendiri, attention block akan berada diantara encoder dan decoder. Berikut merupakan gambaran dari arsitektur UNet Attention.




Gambar 5. UNet Attention

2.5 Dataset

Dataset terdiri dari dataset gambar citra satelit dan dataset mask label biner, dimana objek sungai = 1, sedangkan objek lainnya bernilai = 0. Label dibuat dengan pendekatan region-based, yang dimana hanya bagian sungai saja yang dimasking, sedangkan area non-sungai, seperti danau atau kolam dianggap sebagai objek lainnya. Hal ini dilakukan agar model bisa berfokus untuk melakukan segmentasi pada bagian badan sungai saja.


3 HASIL DAN PEMBAHASAN

Penelitian ini membandingkan dua arsitektur deep learning yang digunakan dalam kasus segmentasi semantik untuk ekstraksi badan sungai dari citra penginderaan jauh. Keberhasilan dari kedua arsitektur dievaluasi dengan cara melakukan validasi secara inspeksi kualitatif terhadap hasil mask prediksi serta akurasi yang dihasilkan oleh model.



Gambar 6. UNet Attention


Pada Gambar 6 terlihat bagaimana loss validation pada model UNet Attention stabil menurun seiring dengan loss pada data pelatihan. Akurasi validasi pada Model UNet Attention juga naik secara tanpa terjadi peningkatan atau penurunan yang drastis. Pola ini memberikan indikasi bahwa terjadi generalisasi yang baik.



Gambar 7. ResNet-50

Pada Gambar 7 memperlihatkan grafik loss validasi yang terus meningkat dan tidak mengikuti penurunan dari loss pada pelatihan. Akurasi validasi juga terlihat naik turun serta terdapat rongga pada kedua tabel tersebut. Rongga yang tampak pada kedua grafik ini mengindikasikan ketidakstabilan pada model saat melakukan training dan merupakan indikasi adanya potensi overfitting.


U-Net Attention memperlihatkan loss validasi yang menurun secara stabil disertai dengan kenaikan akurasi validasi yang konsisten sepanjang epoch. Sedangkan ResNet-50 menunjukkan fluktuasi pada nilai loss dan akurasi validasi. Pergerakan pada grafik diantara kedua model ini mendakan bahwa U-Net Attention dapat mempelajari pola tepi Sungai secara lebih stabil dan terarah, sedangkan ResNet-50 mengalami ketidakstabilan pembelajaran dan kecenderungan overfitting. Dari sisi arsitektur, *skip connection* pada U-Net Attention menjaga fitur beresolusi tinggi agar detail tepi sungai tidak hilang akibat proses downsampling pada U-Net. Dampaknya, false positive pada area non-sungai berkurang dan false negative pada segmen sungai yang sempit/berliku ikut menurun.



Gambar 8. Hasil Segmentasi ResNet-50

Gambar 8 merupakan hasil dari segmentasi citra yang dilakukan oleh model ResNet-50. Mask hasil segmentasi terlihat terputus dan masih banyak area yang tidak bisa ditangkap oleh model. Selain itu model juga masih

mewarnai area non-sungai sebagai sungai. Model juga terlihat kesusahan dalam menangkap bagian sungai yang sempit ataupun berliku.



Gambar 9. Hasil Segmentasi UNet Attention

Gambar 9 merupakan hasil segmentasi dari model UNet Attention. Model UNet Attention berhasil menghasilkan mask segmentasi yang dapat mengikuti alur sungai secara lebih rapi dan presisi. Terlihat hasil segmentasi dari model nampak lebih rapi. Hasil dari model Unet-Attention juga memiliki False Positif yang lebih sedikit pada objek non-sungai seperti danau ataupun genangan air yang bukan sungai.

Hasil evaluasi metrik kedua model disajikan pada tabel 1. Secara rata-rata, ResNet-50 mencapai akurasi 93.3%, sedangkan U-Net Attention mencapai 98.8%. Walaupun akurasi ResNet-50 terlihat tinggi, inspeksi visual menunjukkan ketidaktepatan dari hasil model.

Tabel 1. Perbandingan Akurasi Kedua Model

Model	Akurasi (%)	IoU (%)	Dice (%)	Ringkasan
ResNet-50	93,3	1.4	1.6	Tepi sungai terputus; <i>false positive</i> pada danau/kolam lebih tinggi
U-Net Attention	98,8	79.7	88,7	Tepi stabil dan kontinu; <i>false</i>

				<i>positive</i> lebih rendah
--	--	--	--	---------------------------------

Dari hasil evaluasi pada Tabel 1, ResNet-50 meraih akurasi 93,3% tetapi hanya menghasilkan IoU 1,4% dan Dice 1,6%, sedangkan U-Net Attention mencapai akurasi 98,8% dengan IoU 79,7% dan Dice 88,7%. Angka ini menunjukkan bahwa akurasi saja belum cukup untuk menggambarkan kualitas segmentasi: pada kasus sungai yang sempit dan memanjang, kesalahan kecil di tepi tidak terlalu memengaruhi akurasi, tetapi sangat menurunkan IoU/Dice. Hal tersebut juga tampak pada Gambar 8–9, di mana prediksi ResNet-50 cenderung memutus kontur tepi sungai dan memunculkan false positive pada area danau/kolam, sementara U-Net Attention menghasilkan tepi yang lebih stabil, halus, dan menyatu dengan alur sungai. Sejalan dengan temuan Widyantara, Marti, dan Suputra (2025), pemilihan fungsi loss yang tepat perlu disesuaikan dengan kondisi kelas, karena ketidakseimbangan antara area sungai dan latar belakang dapat memengaruhi hasil segmentasi (Widyantara, Marti & Suputra, 2025).

Keunggulan U-Net Attention terlihat dari cara kerjanya yang sederhana tapi efektif. Pertama, skip connection menjaga fitur beresolusi tinggi dari encoder agar tetap terbawa ke decoder, sehingga detail tepi sungai tidak hilang saat proses downsampling dan upsampling. Kedua, attention gate membantu model fokus pada bagian yang relevan, yaitu alur sungai, sambil menekan respon pada latar seperti danau atau kolam. Berbeda dengan itu, ResNet-50 tidak memiliki mekanisme perhatian di sisi decoder, sehingga detail halus lebih mudah hilang setelah downsampling. Akibatnya, pada segmen sungai yang sempit atau berliku, hasil segmentasinya cenderung putus atau melebar kurang tepat. Temuan ini sejalan dengan hasil visual yang menunjukkan mask U-Net Attention lebih kontinu dan tepinya lebih dekat dengan penanda.

4 PENUTUP

4.1. Kesimpulan

Penelitian ini menggunakan metode deep learning dalam pemantauan sungai dalam memitigasi risiko bencana alam. Dengan menggunakan model ResNet-50 dan UNet

Attention untuk melakukan semantic segmentation yang nantinya bisa digunakan untuk melihat bagaimana perubahan pola sungai kedepannya. Hasil yang didapat dari penelitian ini menunjukkan bahwa model UNet Attention dapat memberikan hasil semantic segmentation yang akurat dibandingkan dengan model ResNet-50. Namun, masih diperlukan perbaikan untuk meningkatkan hasil kedua model, seperti penggunaan dataset sungai yang lebih beragam dan citra satelit dengan resolusi yang lebih tinggi. Studi selanjutnya juga dapat menguji model pada citra dengan resolusi lebih tinggi atau kombinasi sensor yang berbeda untuk memperbaiki ketepatan segmentasi area sempit (Panghurian et al., 2024). Selain itu, penelitian lanjutan disarankan untuk menambahkan metrik IoU/Dice, serta Precision dan Recall khusus untuk kelas sungai guna memberikan evaluasi yang lebih komprehensif.

4.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan, penulis menyarankan agar penelitian berikutnya menggunakan dataset sungai yang lebih bervariasi, mencakup kondisi geografis dan karakter sungai yang berbeda. Selain itu, pemakaian citra satelit beresolusi lebih tinggi seperti Sentinel-2 berpotensi meningkatkan ketepatan segmentasi, terutama pada bagian sungai yang sempit atau tertutup vegetasi. Pada tahap evaluasi, model sebaiknya dilengkapi metrik tambahan seperti IoU, Dice Coefficient, Precision, dan Recall khusus untuk kelas sungai agar penilaian menjadi lebih akurat dan informatif. Ke depannya, penulis juga berharap hasil penelitian ini dapat diimplementasikan pada sistem pemantauan banjir berbasis web atau GIS secara real-time, sehingga memberikan manfaat nyata untuk mitigasi bencana dan mendukung pengambilan keputusan di lapangan.

5 DAFTAR PUSTAKA

- Safitri, D. dan Putra, R.A. 2022. *Analisis Pola Aliran Banjir pada Sungai Cimadur, Provinsi Banten dengan Menggunakan HEC-RAS*. Journal of Infrastructural in Civil Engineering, 3(1), hlm. 19–30.
- Jiang, S., Bevacqua, E. dan Zscheischler, J. 2022. *River flooding mechanisms and their changes in Europe revealed by explainable*

- machine learning*. Hydrology and Earth System Sciences, 26(24), hlm. 6339–6359.
- Valijonovich, R.S., Axmadjanovich, T.A. dan Khoshimjon, Y.S. 2021. *Causes and consequences of floods and floods in the safety of life, measures to protect the population and the territory*. International Journal of Progressive Sciences and Technologies, 25(1), hlm. 83–86.
- Salim, M.A. dan Siswanto, A.B. 2021. *Kajian penanganan dampak banjir Kabupaten Pekalongan*. Rang Teknik Journal, 4(2), hlm. 295–303.
- Ginting, S. 2021. *Analisis Curah Hujan Penyebab Banjir Bandang di Ujung Berung, Bandung*. Akselerasi: Jurnal Ilmiah Teknik Sipil, 2(2).
- Vandaele, R., Dance, S.L. dan Ojha, V. 2021. *Deep learning for automated river-level monitoring through river-camera images: an approach based on water segmentation and transfer learning*. Hydrology and Earth System Sciences, 25(8), hlm. 4435–4453.
- Neupane, B., Horanont, T. dan Aryal, J. 2021. *Deep learning-based semantic segmentation of urban features in satellite images: a review and meta-analysis*. Remote Sensing, 13(4), hlm. 808.
- Jiang, B., An, X., Xu, S. dan Chen, Z. 2023. *Intelligent image semantic segmentation: a review through deep learning techniques for remote sensing image analysis*. Journal of the Indian Society of Remote Sensing, 51(9), hlm. 1865–1878.
- Qureshi, I., Yan, J., Abbas, Q., Shaheed, K., Riaz, A.B., Wahid, A., Khan, M.W.J. dan Szczuko, P. 2023. *Medical image segmentation using deep semantic-based methods: a review of techniques, applications and emerging trends*. Information Fusion, 90, hlm. 316–352.
- Al-Huda, Z., Peng, B., Algburi, R.N.A., Al-Antari, M.A., Rabea, A.J. dan Zhai, D. 2023. *A hybrid deep learning pavement crack semantic segmentation*. Engineering Applications of Artificial Intelligence, 122, hlm. 106142.
- Roy, R.M. dan Ameer, P.M. 2021. *Segmentation of leukocyte by semantic segmentation model: a deep learning approach*. Biomedical Signal Processing and Control, 65, hlm. 102385.
- Ulku, I. dan Akagündüz, E. 2022. *A survey on deep learning-based architectures for semantic segmentation on 2D images*. Applied Artificial Intelligence, 36(1), hlm. 2032924.
- Zhou, Y., Wang, Z., Zheng, S., Zhou, L., Dai, L., Luo, H., Zhang, Z. dan Sui, M. 2024. *Optimization of automated garbage recognition model based on ResNet-50 and weakly supervised CNN for sustainable urban development*. Alexandria Engineering Journal, 108, hlm. 415–427.
- Mahmoud, A.S., Mohamed, S.A., El-Khoriby, R.A., AbdelSalam, H.M. dan El-Khodary, I.A. 2023. *Oil spill identification based on dual attention UNet model using synthetic aperture radar images*. Journal of the Indian Society of Remote Sensing, 51(1), hlm. 121–133.
- Jain, P.K., Dubey, A., Saba, L., Khanna, N.N., Laird, J.R., Nicolaides, A., Fouda, M.M., Suri, J.S. dan Sharma, N. 2022. *Attention-based UNet deep learning model for plaque segmentation in carotid ultrasound for stroke risk stratification: an artificial intelligence paradigm*. Journal of Cardiovascular Development and Disease, 9(10), hlm. 326.
- Dewi, N.P.K., Suputra, P.H., Paramartha, A.G.Y., Dewi, L.J.E., Varnakovida, P. dan Aryanto, K.Y.E. 2025. *River area segmentation using Sentinel-1 SAR imagery with deep-learning approach*. Geomatics and Environmental Engineering, 19(4), hlm. 39–63.
- Andewi, P.O., Seputra, K.A., Aryanto, K.Y.E. dan Dewi, L.J.E. 2025. *Integrasi teknologi penginderaan jauh dan machine learning pada Web GIS untuk pemetaan potensi banjir*. Jurnal Pendidikan Teknologi dan Kejuruan, 22(1), hlm. 12–23.
- Widiantara, P.A., Marti, N.W. dan Suputra, P.H. 2025. *Segmentasi semantik berbasis DeepLabv3+ untuk pemantauan pencemaran sampah di perairan sungai*. Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi, 14(2), hlm. 809–820.
- Panghurian, F.P., Pranoto, H., Irwansyah, E. dan Pramudya, F.S. 2024. *Comparison of*

ResNet models in UNet classifier for mapping oil palm plantation area with semantic segmentation approach.
International Journal of Advanced Computer Science & Applications, 15(7).

Sun, Y., Bi, F., Gao, Y., Chen, L. dan Feng, S.
2022. *A multi-attention UNet for semantic segmentation in remote sensing images.*
Symmetry, 14(5), hlm. 906.