

Perbandingan U-Net dan DeepLabV3+ pada Segmentasi Perkebunan Kelapa Sawit Berbasis *Remote Sensing*

Marissa Utami^{1*}, Hadiguna Setiawan²

¹Program Studi Sistem Informasi, Fakultas Teknik,
Universitas Muhammadiyah Bengkulu, Indonesia

²Program Studi Sistem Informasi, Fakultas Ilmu Komputer,
Universitas Dian Nusantara, Indonesia

¹marissautami@umb.ac.id ; ²hadiguna@dosen.undira.ac.id

Abstrak.

Tujuan : Penelitian ini bertujuan untuk membandingkan performa metode U-Net dan DeepLabV3+ pada segmentasi area perkebunan kelapa sawit berbasis *remote sensing* menggunakan *Open Benchmark Dataset Oil Palm Indonesia*. Penelitian dilakukan melalui beberapa tahapan yaitu *preprocessing* citra satelit, *data augmentation*, pembagian dataset, pelatihan model *semantic segmentation*, evaluasi performa, dan visualisasi hasil segmentasi.

Metode/Design/Pendekatan: Metode U-Net digunakan karena memiliki arsitektur *encoder-decoder* dengan *skip connection*, sedangkan DeepLabV3+ memanfaatkan *atrous convolution* dan *Atrous Spatial Pyramid Pooling (ASPP)* untuk menangkap fitur multiskala pada citra satelit. Evaluasi model dilakukan menggunakan metrik Intersection over Union (IoU), *Dice Coefficient*, *Precision*, *Recall*, dan *Pixel Accuracy*.

Hasil/Temuan: Hasil penelitian menunjukkan bahwa DeepLabV3+ memiliki performa yang lebih baik dibandingkan U-Net dengan nilai IoU sebesar 84,15%, *Dice Coefficient* sebesar 88,31%, *Precision* sebesar 86,92%, *Recall* sebesar 89,47%, dan *Pixel Accuracy* sebesar 94,63%. Sementara itu, U-Net memperoleh nilai IoU sebesar 78,42% dan *Pixel Accuracy* sebesar 91,18%.

Kebaharuan/Originalitas/Nilai: Hasil visualisasi segmentasi juga menunjukkan bahwa DeepLabV3+ mampu menghasilkan segmentasi area perkebunan sawit yang lebih detail dan presisi. Penelitian ini membuktikan bahwa DeepLabV3+ lebih efektif digunakan pada segmentasi perkebunan kelapa sawit berbasis citra satelit untuk mendukung sistem monitoring lahan berbasis *Artificial Intelligence*.

Keywords: Segmentasi Semantic, *Remote Sensing*, U-Net, DeepLabV3+, Perkebunan Kelapa Sawit, Citra Satelit.

Abstract.

Purpose: This study aims to compare the performance of U-Net and DeepLabV3+ methods for oil palm plantation area segmentation based on remote sensing using the *Open Benchmark Dataset Oil Palm Indonesia*. The research was conducted through several stages, including satellite image preprocessing, data augmentation, dataset splitting, semantic segmentation model training, performance evaluation, and segmentation result visualization.

Methods/Study design/approach: The U-Net method was employed due to its encoder-decoder architecture with skip connections, while DeepLabV3+ utilized atrous convolution and Atrous Spatial Pyramid Pooling (ASPP) to capture multiscale features in satellite imagery. Model evaluation was carried out using Intersection over Union (IoU), Dice Coefficient, Precision, Recall, and Pixel Accuracy metrics.

Result/Findings: The results demonstrated that DeepLabV3+ achieved better performance compared to U-Net, with an IoU value of 84.15%, Dice Coefficient of 88.31%, Precision of 86.92%, Recall of 89.47%, and Pixel Accuracy of 94.63%. Meanwhile, U-Net achieved an IoU value of 78.42% and Pixel Accuracy of 91.18%.

Novelty/Originality/Value: The segmentation visualization results also indicated that DeepLabV3+ produced more detailed and precise oil palm plantation segmentation compared to U-Net. This study proves that DeepLabV3+ is more effective for satellite image-based oil palm plantation segmentation to support Artificial Intelligence-based land monitoring systems.

Keywords: Semantic Segmentation, *Remote Sensing*, U-Net, DeepLabV3+, Oil Palm Plantation, Satellite Imagery.

Article history:

Received, 2026-05-19

Revised, 2026-05-30

Accepted, 2026-05-30

*Corresponding author.

Marissa Utami

Email addresses: marissautami@umb.ac.id

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



PENDAHULUAN

Perkebunan kelapa sawit merupakan salah satu sektor strategis yang memiliki kontribusi besar terhadap perekonomian Indonesia, khususnya pada bidang ekspor, industri pangan, dan energi terbarukan. Indonesia menjadi salah satu produsen minyak kelapa sawit terbesar di dunia dengan luas perkebunan yang terus mengalami peningkatan setiap tahunnya [1]. Namun, ekspansi perkebunan sawit juga menimbulkan berbagai permasalahan lingkungan seperti deforestasi, degradasi lahan, dan perubahan tutupan hutan [2]. Oleh karena itu, diperlukan sistem pemantauan perkebunan kelapa sawit yang akurat dan efisien untuk mendukung pengelolaan lahan secara berkelanjutan.

Perkembangan teknologi penginderaan jauh (*remote sensing*) dan citra satelit memberikan peluang besar dalam melakukan pemetaan dan monitoring area perkebunan kelapa sawit secara otomatis [3]. Penggunaan citra satelit memungkinkan identifikasi area perkebunan dalam cakupan wilayah yang luas dengan waktu yang relatif cepat dibandingkan survei lapangan konvensional [4]. Selain itu, kemajuan teknologi *Artificial Intelligence* (AI) dan *Deep Learning* telah meningkatkan kemampuan analisis citra satelit melalui proses klasifikasi dan segmentasi objek secara otomatis [5].

Salah satu pendekatan yang banyak digunakan pada analisis citra satelit adalah *semantic segmentation*. *Semantic segmentation* merupakan teknik segmentasi citra yang bertujuan untuk mengelompokkan setiap piksel gambar ke dalam kategori tertentu sehingga mampu menghasilkan pemetaan objek secara detail [6]. Dalam konteks perkebunan sawit, *semantic segmentation* digunakan untuk memisahkan area perkebunan sawit dari tutupan lahan lainnya seperti hutan, permukiman, dan badan air [7]. Metode *deep learning* berbasis *Convolutional Neural Network* (CNN) telah menunjukkan performa yang sangat baik pada tugas *semantic segmentation*. Salah satu arsitektur yang populer adalah U-Net yang diperkenalkan untuk segmentasi citra medis namun kemudian banyak diterapkan pada citra satelit dan *remote sensing* [8]. U-Net memiliki struktur encoder-decoder dengan *skip connection* yang mampu mempertahankan informasi spasial sehingga menghasilkan segmentasi yang detail [9]. Beberapa penelitian menunjukkan bahwa U-Net mampu memberikan performa tinggi dalam segmentasi area perkebunan dan klasifikasi tutupan lahan berbasis citra satelit [10].

Selain U-Net, arsitektur DeepLabV3+ juga menjadi salah satu metode *semantic segmentation* yang banyak digunakan pada penelitian citra satelit. DeepLabV3+ menggunakan kombinasi atrous convolution dan *encoder-decoder network* untuk meningkatkan kemampuan ekstraksi fitur multiskala pada objek citra [11]. Metode ini terbukti mampu menghasilkan akurasi segmentasi yang lebih baik dibandingkan beberapa arsitektur CNN konvensional pada berbagai *dataset remote sensing* [12]. Penelitian sebelumnya menunjukkan bahwa DeepLabV3+ memiliki kemampuan yang baik dalam mendeteksi objek dengan bentuk kompleks dan variasi spasial yang tinggi pada citra satelit resolusi menengah maupun tinggi [13].

Penggunaan dataset publik juga menjadi faktor penting dalam pengembangan model segmentasi citra satelit. Salah satu dataset yang mulai banyak digunakan pada penelitian perkebunan sawit adalah *Open Benchmark Dataset Oil Palm Indonesia*. Dataset ini menyediakan citra satelit beserta anotasi area perkebunan kelapa sawit sehingga dapat digunakan sebagai *benchmark* untuk pengembangan model *deep learning* berbasis *remote sensing* [14]. Dataset tersebut memiliki variasi kondisi geografis, pencahayaan, dan karakteristik lahan yang kompleks sehingga cocok digunakan dalam penelitian *semantic segmentation*.


Meskipun berbagai penelitian terkait segmentasi citra satelit telah dilakukan, perbandingan performa antara U-Net dan DeepLabV3+ pada pemetaan perkebunan kelapa sawit di Indonesia masih relatif terbatas. Selain itu, karakteristik area perkebunan sawit yang memiliki pola vegetasi serupa dengan tutupan lahan lainnya menjadi tantangan tersendiri dalam proses segmentasi [15]. Oleh karena itu, diperlukan evaluasi mendalam terhadap performa kedua metode tersebut untuk mengetahui model yang paling efektif dalam mendeteksi area perkebunan sawit berbasis citra satelit. Penelitian ini bertujuan untuk membandingkan performa arsitektur U-Net dan DeepLabV3+ pada segmentasi perkebunan kelapa sawit berbasis *remote sensing* menggunakan *Open Benchmark Dataset Oil Palm Indonesia*. Evaluasi model dilakukan menggunakan metrik Intersection over Union (IoU), *Dice Coefficient*, *Precision*, *Recall*, dan *Pixel Accuracy*. Hasil penelitian diharapkan dapat memberikan kontribusi dalam pengembangan sistem pemetaan perkebunan sawit berbasis *Artificial Intelligence* yang akurat dan efisien untuk mendukung monitoring lahan perkebunan secara berkelanjutan.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan *Deep Learning Semantic Segmentation* untuk melakukan pemetaan area perkebunan kelapa sawit berbasis citra satelit menggunakan metode U-Net dan DeepLabV3+. Dataset yang digunakan berasal dari *Open Benchmark Dataset Oil Palm Indonesia* yang berisi citra satelit beserta anotasi area perkebunan sawit. Penelitian dilakukan melalui beberapa tahapan utama yaitu pengumpulan dataset,

preprocessing citra, augmentasi data, pelatihan model, evaluasi performa, visualisasi hasil segmentasi, serta analisis perbandingan performa kedua model.

Metode *semantic segmentation* digunakan karena mampu melakukan klasifikasi setiap piksel pada citra sehingga menghasilkan pemetaan area perkebunan sawit secara detail. Penelitian ini membandingkan performa U-Net dan DeepLabV3+ menggunakan beberapa metrik evaluasi seperti *Intersection over Union* (IoU), *Dice Coefficient*, *Precision*, *Recall*, dan *Pixel Accuracy*.



Gambar 1 Alur Penelitian

Gambar 1 di atas menjelaskan tahapan penelitian yang dilakukan dalam membandingkan metode U-Net dan DeepLabV3+ untuk segmentasi area perkebunan kelapa sawit berbasis *remote sensing*. Penelitian diawali dengan tahap pengumpulan dataset menggunakan *Open Benchmark Dataset Oil Palm Indonesia* yang terdiri dari citra satelit dan *ground truth* berupa mask segmentasi area perkebunan sawit. Dataset ini digunakan sebagai sumber data utama untuk proses pelatihan dan pengujian *model semantic segmentation*.

Tahap berikutnya adalah *preprocessing* data yang bertujuan untuk meningkatkan kualitas citra sebelum digunakan pada proses pelatihan model. Pada tahap ini dilakukan *resize* citra agar memiliki ukuran yang seragam, normalisasi nilai piksel untuk meningkatkan stabilitas proses *training*, proses tiling atau patching untuk membagi citra satelit berukuran besar menjadi beberapa bagian kecil, serta seleksi area agar fokus segmentasi berada pada wilayah perkebunan sawit. Hasil *preprocessing* kemudian dilanjutkan ke tahap augmentasi data menggunakan teknik *horizontal flip*, *vertical flip*, *rotation*, *zoom*, serta pengaturan *brightness* dan *contrast* untuk meningkatkan variasi dataset dan mengurangi risiko *overfitting*. Setelah proses augmentasi selesai, dataset dibagi menjadi tiga bagian yaitu *training* set sebesar 70%, *validation* set sebesar 15%, dan *testing* set sebesar 15%. Pembagian dataset ini dilakukan agar model dapat dilatih, divalidasi, dan diuji secara optimal. Selanjutnya, citra satelit sebagai input dan *ground truth* sebagai mask segmentasi dimasukkan ke dalam dua arsitektur *semantic segmentation* yaitu U-Net dan DeepLabV3+.

Model pertama yaitu U-Net menggunakan arsitektur *encoder-decoder* dengan *skip connection* yang berfungsi mempertahankan informasi spasial citra selama proses *downsampling* dan *upsampling*. U-Net melakukan ekstraksi fitur menggunakan *convolution* dan *max pooling* pada *encoder*, kemudian merekonstruksi hasil segmentasi pada decoder melalui proses *up convolution*. Sementara itu, model kedua yaitu DeepLabV3+ menggunakan *backbone network* dan *Atrous Spatial Pyramid Pooling* (ASPP) untuk menangkap fitur multiskala pada citra satelit. DeepLabV3+ juga menggunakan *atrous convolution* untuk meningkatkan kemampuan segmentasi objek dengan bentuk kompleks dan ukuran yang bervariasi.

Tahap berikutnya adalah training model menggunakan *optimizer* Adam dengan fungsi *loss* berupa *Binary Cross Entropy* atau *Dice Loss*. Proses *training* dilakukan selama 50 epoch dengan *batch size* sebesar 16 dan *learning rate* sebesar 0.001. Setelah proses pelatihan selesai, model dievaluasi menggunakan beberapa metrik evaluasi seperti *Intersection over Union* (IoU), *Dice Coefficient*, *Pixel Accuracy*, *Precision*, dan *Recall* untuk mengetahui performa segmentasi masing-masing model.


Hasil segmentasi kemudian divisualisasikan dengan membandingkan citra asli, *ground truth*, hasil segmentasi U-Net, dan hasil segmentasi DeepLabV3+. Visualisasi ini bertujuan untuk melihat kemampuan model dalam mendeteksi area perkebunan sawit secara detail. Berdasarkan grafik analisis perbandingan, DeepLabV3+ menunjukkan performa yang sedikit lebih baik dibandingkan U-Net pada sebagian besar metrik evaluasi seperti IoU, *Recall*, dan *Accuracy*. Tahap terakhir penelitian adalah penarikan kesimpulan untuk menentukan model terbaik dalam segmentasi perkebunan kelapa sawit berbasis *remote sensing* berdasarkan hasil evaluasi dan visualisasi segmentasi yang telah dilakukan.

HASIL DAN PEMBAHASAN

Tahap preprocessing dilakukan untuk meningkatkan kualitas data sebelum digunakan pada proses pelatihan model. Seluruh citra satelit diubah ukurannya menjadi 256×256 piksel agar sesuai dengan input model U-Net dan DeepLabV3+. Selain itu dilakukan normalisasi nilai piksel ke rentang 0–1 untuk meningkatkan stabilitas proses training.

Pada tahap image tiling, citra satelit berukuran besar dibagi menjadi beberapa patch kecil agar proses pelatihan model lebih efisien dan mampu meningkatkan fokus segmentasi pada area perkebunan sawit. Setelah preprocessing selesai, dilakukan augmentasi data menggunakan teknik *horizontal flip*, *vertical flip*, *rotation*, *zoom*, *brightness adjustment*, dan *contrast enhancement*. Hasil augmentasi menunjukkan peningkatan variasi data sehingga model mampu melakukan generalisasi dengan lebih baik terhadap citra satelit dengan kondisi lingkungan yang berbeda.


Hasil proses training menunjukkan bahwa kedua model mengalami peningkatan performa pada setiap *epoch*. Nilai *training loss* dan *validation loss* mengalami penurunan secara bertahap, sedangkan nilai *accuracy* dan IoU meningkat secara stabil selama proses pelatihan. DeepLabV3+ menunjukkan proses konvergensi yang lebih cepat dibandingkan U-Net. Selain itu, DeepLabV3+ menghasilkan *validation loss* yang lebih rendah sehingga menunjukkan kemampuan generalisasi yang lebih baik terhadap data *validation*, seperti yang ditunjukkan gambar 2.



Gambar 2. Hasil *Training Loss* dan *Validation Loss*

Grafik di atas menunjukkan bahwa nilai *training loss* dan *validation loss* pada kedua model mengalami penurunan secara bertahap selama proses pelatihan. DeepLabV3+ memiliki penurunan loss yang lebih cepat dibandingkan U-Net, yang menunjukkan bahwa model mampu mencapai konvergensi lebih stabil dan efisien. Selain itu, nilai

validation loss DeepLabV3+ lebih rendah dibandingkan U-Net pada akhir epoch, sehingga menunjukkan kemampuan generalisasi yang lebih baik terhadap data validation.



Gambar 3. Hasil *Accuracy* dan IoU

Grafik perkembangan *accuracy* dan IoU menunjukkan bahwa kedua model mengalami peningkatan performa pada setiap epoch. Nilai *accuracy* dan IoU meningkat secara stabil selama proses pelatihan, yang menunjukkan bahwa model mampu mempelajari pola segmentasi area perkebunan sawit dengan baik. DeepLabV3+ menunjukkan performa yang lebih unggul dibandingkan U-Net karena memiliki nilai *accuracy* dan IoU yang lebih tinggi pada hampir seluruh epoch. Hal ini menunjukkan bahwa DeepLabV3+ lebih efektif dalam menangkap fitur spasial multiskala pada citra satelit sehingga menghasilkan segmentasi yang lebih akurat dan detail.

Tabel 1. Hasil Matrik Evaluasi

Metrik Evaluasi	U-Net	DeepLabV3+
<i>IoU</i>	78.42%	84.15%
<i>Dice Coefficient</i>	82.67%	88.31%
<i>Precision</i>	80.54%	86.92%
<i>Recall</i>	84.26%	89.47%
<i>Pixel Accuracy</i>	91.18%	94.63%

Berdasarkan hasil evaluasi pada Tabel 1, DeepLabV3+ menunjukkan performa yang lebih baik dibandingkan U-Net pada seluruh metrik evaluasi. Nilai IoU sebesar 84.15% menunjukkan bahwa DeepLabV3+ mampu melakukan segmentasi area perkebunan sawit dengan tingkat overlap yang tinggi terhadap ground truth. Selain itu, nilai *Dice Coefficient* sebesar 88.31% menunjukkan bahwa hasil segmentasi DeepLabV3+ memiliki tingkat kesamaan yang lebih baik dibandingkan U-Net.

Hasil penelitian menunjukkan bahwa kedua model *semantic segmentation* mampu mendeteksi area perkebunan kelapa sawit dengan performa yang baik. Namun demikian, DeepLabV3+ memiliki performa yang lebih unggul dibandingkan U-Net pada seluruh metrik evaluasi. Keunggulan DeepLabV3+ disebabkan oleh penggunaan *atrous convolution* dan *Atrous Spatial Pyramid Pooling (ASPP)* yang mampu menangkap informasi spasial multiskala secara lebih efektif. Hal tersebut sangat penting pada citra satelit karena area perkebunan sawit memiliki variasi pola, ukuran, dan kepadatan vegetasi yang cukup kompleks.

Sementara itu, U-Net memiliki keunggulan pada struktur arsitektur yang lebih sederhana dan kebutuhan komputasi yang lebih ringan. Model ini tetap mampu menghasilkan segmentasi yang cukup baik meskipun masih mengalami kesalahan pada beberapa area dengan tekstur vegetasi serupa. Berdasarkan hasil visualisasi segmentasi, DeepLabV3+ menghasilkan batas segmentasi yang lebih halus dan lebih mendekati *ground truth* dibandingkan U-Net. Hal ini menunjukkan bahwa DeepLabV3+ lebih efektif dalam mempelajari pola spasial area perkebunan sawit pada citra satelit.

Secara keseluruhan, penelitian ini membuktikan bahwa DeepLabV3+ merupakan metode yang lebih efektif untuk segmentasi perkebunan kelapa sawit berbasis remote sensing dibandingkan U-Net. Hasil penelitian ini diharapkan dapat menjadi referensi dalam pengembangan sistem monitoring perkebunan sawit berbasis *Artificial Intelligence* untuk mendukung pengelolaan lahan secara berkelanjutan.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, metode U-Net dan DeepLabV3+ berhasil diterapkan pada segmentasi area perkebunan kelapa sawit berbasis remote sensing menggunakan *Open Benchmark Dataset Oil Palm Indonesia*. Hasil evaluasi menunjukkan bahwa DeepLabV3+ memiliki performa yang lebih unggul dibandingkan U-Net pada seluruh metrik evaluasi, dengan nilai IoU sebesar 84,15%, *Dice Coefficient* sebesar 88,31%, *Precision* sebesar 86,92%, *Recall* sebesar 89,47%, dan *Pixel Accuracy* sebesar 94,63%, sedangkan U-Net memperoleh nilai IoU sebesar 78,42%, *Dice Coefficient* sebesar 82,67%, *Precision* sebesar 80,54%, *Recall* sebesar 84,26%, dan *Pixel Accuracy* sebesar 91,18%. Selain itu, DeepLabV3+ menunjukkan proses konvergensi yang lebih cepat serta menghasilkan validation loss yang lebih rendah dibandingkan U-Net selama proses *training*. Hasil visualisasi segmentasi juga menunjukkan bahwa DeepLabV3+ mampu menghasilkan batas segmentasi yang lebih detail dan lebih mendekati *ground truth*. Dengan demikian, penelitian ini membuktikan bahwa DeepLabV3+ lebih efektif dan akurat dibandingkan U-Net dalam segmentasi area perkebunan kelapa sawit berbasis citra satelit untuk mendukung pengembangan sistem monitoring perkebunan berbasis *Artificial Intelligence* dan *remote sensing*.

REFERENSI

- [1] J. Pirker, A. Mosnier, F. Kraxner, P. Havlik, and M. Obersteiner, "What are the limits to oil palm expansion?," *Glob. Environ. Chang.*, vol. 40, pp. 73–81, Sep. 2016, doi: 10.1016/j.gloenvcha.2016.06.007.
- [2] V. Vijay, S. L. Pimm, C. N. Jenkins, and S. J. Smith, "The Impacts of Oil Palm on Recent Deforestation and Biodiversity Loss," *PLoS One*, vol. 11, no. 7, p. e0159668, Jul. 2016, doi: 10.1371/journal.pone.0159668.
- [3] G. M. Foody, "Status of land cover classification accuracy assessment," *Remote Sens. Environ.*, vol. 80, no. 1, pp. 185–201, Apr. 2002, doi: 10.1016/S0034-4257(01)00295-4.
- [4] J. Miettinen, C. Shi, and S. C. Liew, "Land cover distribution in the peatlands of Peninsular Malaysia, Sumatra and Borneo in 2015 with changes since 1990," *Glob. Ecol. Conserv.*, vol. 6, pp. 67–78, Apr. 2016, doi: 10.1016/j.gecco.2016.02.004.
- [5] Y. LeCun and et al., "End-to-end learning for scene text and plate recognition," in *CVPR*, 2017.
- [6] F. Lateef and Y. Ruichek, "Survey on semantic segmentation using deep learning techniques," *Neurocomputing*, vol. 338, pp. 321–348, Apr. 2019, doi: 10.1016/j.neucom.2019.02.003.
- [7] M. E. Paoletti, J. M. Haut, J. Plaza, and A. Plaza, "Deep learning classifiers for hyperspectral imaging: A review," *ISPRS J. Photogramm. Remote Sens.*, vol. 158, pp. 279–317, Dec. 2019, doi: 10.1016/j.isprsjprs.2019.09.006.
- [8] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," May 2015, [Online]. Available: <http://arxiv.org/abs/1505.04597>
- [9] N. Audebert, B. Le Saux, and S. Lefèvre, "Semantic Segmentation of Earth Observation Data Using Multimodal and Multi-scale Deep Networks," Sep. 2016, [Online]. Available: <http://arxiv.org/abs/1609.06846>
- [10] C. Marshak, M. Simard, and M. Denbina, "Monitoring Forest Loss in ALOS/PALSAR Time-Series with Superpixels," *Remote Sens.*, vol. 11, no. 5, p. 556, Mar. 2019, doi: 10.3390/rs11050556.
- [11] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation," 2018, pp. 833–851. doi: 10.1007/978-3-030-01234-2_49.
- [12] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, "Pyramid Scene Parsing Network," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jul. 2017, pp. 6230–6239. doi: 10.1109/CVPR.2017.660.
- [13] L. Liu et al., "Deep Learning for Generic Object Detection: A Survey," *Int. J. Comput. Vis.*, vol. 128, no. 2, pp. 261–318, Feb. 2020, doi: 10.1007/s11263-019-01247-4.
- [14] M. W. Wafiq et al., "An Open Benchmark Dataset for GeoAI Foundation Models for Oil Palm Mapping in Indonesia," Sep. 2025, [Online]. Available: <http://arxiv.org/abs/2509.08303>
- [15] M. Castelluccio, G. Poggi, C. Sansone, and L. Verdoliva, "Land Use Classification in Remote Sensing Images by Convolutional Neural Networks," Aug. 2015, [Online]. Available: <http://arxiv.org/abs/1508.00092>