

SEGMENTASI AWAN PADA CITRA SATELIT MULTISPEKTRAL MENGUNAKAN CONVOLUTIONAL NEURAL NETWORKS

Bagus Setyawan Wijaya^{*1}, Rinaldi Munir², Nugraha Priya Utama³

^{1,2,3}Institut Teknologi Bandung, Bandung, ¹Badan Pusat Statistik, Jakarta
Email: ¹33222031@std.stei.itb.ac.id, ²rinaldi@staff.stei.itb.ac.id, ³utama@staff.stei.itb.ac.id
^{*}Penulis Korespondensi

(Naskah masuk: 9 September 2024, diterima untuk diterbitkan: 29 Oktober 2025)

Abstrak

Citra satelit multispektral adalah jenis citra yang diambil oleh satelit penginderaan jauh yang menangkap informasi dari berbagai rentang spektrum elektromagnetik. Citra satelit multispektral memiliki peran yang sangat penting karena kemampuannya untuk memberikan informasi untuk area yang luas secara berkala. Akan tetapi, salah satu permasalahan utama dari citra satelit multispektral adalah kontaminasi awan. Tutupan awan pada area yang luas menyebabkan informasi yang ada pada citra satelit menjadi bias. Oleh karena itu, segmentasi awan yang akurat pada citra satelit multispektral menjadi sangat penting. Penelitian ini berfokus untuk mengembangkan model segmentasi awan berbasis Convolutional Neural Networks (CNN) dengan kinerja yang baik. Penelitian diawali dengan proses pembuatan dataset citra satelit multispektral Sentinel-2 Level-2A. Algoritma s2cloudless digunakan untuk membentuk label dengan 4 kelas, yaitu: *shadow*, *clear*, *cirrus*, dan *cloud*. Selanjutnya, model segmentasi awan berbasis CNN dikembangkan berdasarkan beberapa model segmentasi semantik yang ada. Model tersebut dilatih dan dievaluasi pada 11.240 citra yang telah dibuat sebelumnya. Melalui *ablation study*, diperoleh model segmentasi awan terbaik yaitu Deeplabv3+ dengan backbone ResNet18. Arsitektur tersebut memberikan kinerja yang sangat menjanjikan dengan nilai F1-score, pixel accuracy, dan mIoU sebesar 0.922, 0.923, dan 0.733 secara berurutan. Dengan demikian penelitian terkait citra satelit diharapkan menjadi lebih akurat dalam melakukan klasifikasi atau prediksi objek yang ada di permukaan bumi.

Kata kunci: *segmentasi awan, citra satelit, sentinel-2, deep learning, convolutional neural networks, CNN*

CLOUD SEGMENTATION IN MULTISPECTRAL SATELLITE IMAGERY USING CONVOLUTIONAL NEURAL NETWORKS

Abstract

Multispectral satellite imagery is a type of imagery captured by remote sensing satellites that record data from various ranges of the electromagnetic spectrum. Its importance lies in its ability to provide information over large areas periodically. However, one of the main challenges with multispectral satellite imagery is cloud contamination. Cloud cover over large regions can bias the information captured in the imagery. Therefore, accurate cloud segmentation in multispectral satellite imagery is crucial. This study focuses on developing a high-performance cloud segmentation model based on Convolutional Neural Networks (CNN). The research began with the creation of a multispectral satellite imagery dataset from Sentinel-2 Level-2A. Labels with four classes—*shadow*, *clear*, *cirrus*, and *cloud*—were generated using the s2cloudless algorithm. Subsequently, a CNN-based cloud segmentation model was developed using several existing semantic segmentation models. The model was trained and evaluated on 11,240 images from the dataset. Through an ablation study, the best cloud segmentation model was identified as Deeplabv3+ with a ResNet18 backbone. This architecture demonstrated a highly promising performance, achieving F1-score, pixel accuracy, and mIoU values of 0.922, 0.923, and 0.733, respectively. As a result, this research is expected to improve the accuracy of satellite imagery classification and object prediction on the Earth's surface.

Keywords: *cloud segmentation, satellite imagery, sentinel-2, deep learning, convolutional neural networks, CNN*

1. PENDAHULUAN

Penginderaan jauh citra satelit telah banyak diimplementasikan pada berbagai bidang. Pada

bidang pertanian, citra satelit digunakan sebagai sumber data untuk melakukan beberapa tugas seperti mengidentifikasi fase pertumbuhan (Thorp dan Drajat, 2021) dan memprediksi hasil panen (Jeong

dkk., 2022). Saat ini, beberapa data citra satelit penginderaan jauh dengan resolusi spasial medium dapat diakses secara publik melalui *Google Earth Engine* (GEE) (Gorelick dkk., 2017). Penggunaan citra satelit mempunyai daya tarik tersendiri karena mampu memantau area yang luas dan area yang sulit untuk dijangkau secara fisik.

Salah satu tantangan utama dalam mengekstraksi informasi dari citra satelit berbasis sensor optik adalah kontaminasi awan. Terdapat berbagai jenis awan berdasarkan jaraknya dari ekuator. Sebanyak 60 persen permukaan bumi tertutup oleh awan setiap tahunnya (Wang dkk., 1999) dan tutupan awan paling masif biasanya terjadi di sekitar garis ekuator seperti Indonesia. Untuk area di Kabupaten Indramayu, pada tahun 2019-2020 rata-rata tutupan awan mencapai 53,95 persen (Wijaya, Munir, dan Utama, 2023). Awan dan bayangannya yang menutupi area yang luas akan menyebabkan pengamatan permukaan bumi menjadi bias karena tidak menampilkan keadaan sebenarnya yang ada di permukaan. Oleh karena itu, segmentasi awan yang akurat merupakan langkah penting dalam prapemrosesan citra satelit.

Segmentasi awan adalah proses identifikasi dan pemisahan piksel yang dikategorikan sebagai awan dari piksel lainnya pada suatu citra satelit. Proses ini sangat penting untuk memastikan bahwa data citra satelit benar-benar merepresentasikan keadaan permukaan bumi. Beberapa penelitian pada domain ini telah dilakukan, tetapi terdapat kendala yang dihadapi seperti variasi kondisi awan, tekstur, dan kesamaan spektral dengan objek lain pada citra. Seperti awan yang tipis, jenis ini lebih sulit untuk dideteksi pada citra multispektral secara visual karena karakteristiknya yang transparan (Richter dkk., 2011).

Dalam beberapa tahun terakhir, pendekatan *deep learning* telah menunjukkan kinerja yang menjanjikan dalam berbagai tugas pengolahan citra seperti segmentasi objek (Shelhamer dkk., 2016). Dengan kemampuan untuk mempelajari fitur yang kompleks secara otomatis, metode *deep learning* berpotensi untuk mengatasi keterbatasan dari teknik segmentasi awan konvensional. Arsitektur *deep learning* berbasis *Convolutional Neural Networks* (CNN) telah terbukti sangat efektif dalam tugas segmentasi citra karena kemampuannya untuk secara otomatis mengekstraksi fitur-fitur kompleks dari dataset. Pada beberapa penelitian, CNN berhasil mengenali berbagai karakteristik awan dan secara efektif melakukan segmentasi awan (Hu dkk., 2021; Li dan Wang, 2024).


Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model segmentasi awan pada citra satelit multispektral dengan kinerja yang baik. Penelitian diawali dengan melakukan akuisisi data citra satelit dari GEE. Setelah itu, beberapa kombinasi dari model segmentasi semantik berbasis CNN dan *backbone* sebagai encoder akan digunakan dan dilihat

kinerjanya melalui *ablation study*. Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi dalam meningkatkan kualitas data citra satelit dan mendukung berbagai aplikasi yang membutuhkan analisis citra satelit yang akurat.

2. WILAYAH PENELITIAN DAN DATASET

2.1. Wilayah Penelitian


Penelitian dilakukan di 2 wilayah di provinsi Jawa Barat yaitu di Kabupaten Indramayu yang mewakili wilayah dataran dan Kabupaten Garut yang mewakili wilayah lereng. Secara geografis, Kabupaten Indramayu terletak antara 6°15' - 6°40' Lintang Selatan dan 107°52' - 108°36' Bujur Timur dengan luas wilayah 2.099,42 km². Secara topografi, sebagian besar wilayah Kabupaten Indramayu adalah dataran atau daerah landai dengan kemiringan tanahnya rata-rata 0-2% yang mencapai 96,03% dari total luas wilayahnya. Ketinggian wilayah Kabupaten Indramayu berada antara 0-34 meter di atas permukaan laut (BPS Indramayu, 2023). Sedangkan Kabupaten Garut secara geografis terletak antara 6°56' - 7°45' Lintang Selatan dan 107°25' - 108°7' Bujur Timur dengan luas wilayah 3.074,07 km². Secara topografi, wilayah Kabupaten Garut sebelah utara terdiri dari dataran tinggi dan pegunungan, sedangkan bagian selatan sebagian besar permukaan tanahnya memiliki kemiringan yang relatif curam. Wilayah Kabupaten Garut mempunyai kemiringan lereng yang bervariasi antara 0-40% dengan tingkat kemiringan dibawah 3% hanya sekitar 9,47% dari total wilayahnya. Ketinggian wilayah Kabupaten Garut berada antara 0-1.300 meter di atas permukaan laut. (BPS Garut, 2023). Grid dibentuk berdasarkan batas wilayah administrasi yang ada. Grid dibentuk dengan ukuran 512x512 piksel. Berdasarkan grid tersebut, akuisisi data citra satelit Sentinel-2 dilakukan. Tujuan dari pembentukan grid adalah untuk mengatasi batasan maksimal piksel yang dapat diproses untuk setiap eksekusi dari GEE. Selain itu, grid tersebut merupakan objek analisis yang menjadi input dari model segmentasi semantik sehingga diperlukan ukuran yang konsisten. Adapun ilustrasi dari batas wilayah dan grid yang dibentuk dapat dilihat pada Gambar 1.



Gambar 1. Ilustrasi grid di Kabupaten Indramayu

2.2. Dataset


Dataset dibentuk dengan melakukan akuisisi citra satelit Sentinel-2 dari GEE. Image collection yang digunakan adalah Harmonized Sentinel-2 Multispectral Instrument (MSI) Level-2A yang telah melalui proses koreksi geometris, radiometrik, dan atmosferik. Proses akuisisi dilakukan melalui ekosistem Google yaitu Google Colab menggunakan Python untuk berinteraksi dengan GEE melalui API. Data citra satelit yang telah diproses oleh GEE kemudian disimpan di Google Drive untuk selanjutnya diunduh di penyimpanan lokal. Adapun ilustrasi arsitektur yang digunakan untuk melakukan akuisisi data citra satelit adalah seperti pada Gambar 2 berikut.



Gambar 2. Arsitektur akuisisi data citra satelit (Wijaya, Munir, dan Utama, 2023)

Label segmentasi diperoleh dengan memanfaatkan algoritma *s2cloudless*. *S2cloudless* merupakan algoritma deteksi awan otomatis berdasarkan algoritma *gradient boosting* yang dikembangkan oleh Sinergise dan dipublikasikan dengan lisensi MIT (Zupanc, 2017). *S2cloudless* dapat menangani citra satelit Sentinel-2 Level-1C *Top-of-Atmosfer* dan Sentinel-2 Level-2A *Surface Reflectance* dengan cukup baik. Keberadaan awan diidentifikasi dari kumpulan data probabilitas awan, sedangkan bayangan awan ditentukan oleh persimpangan antara proyeksi awan dan piksel NIR dengan reflektansi rendah. Penelitian ini melakukan penyesuaian terhadap algoritma yang ada dengan tujuan untuk menambahkan satu kelas baru yaitu *cirrus*, sehingga terdapat 4 kelas yaitu: *shadow*, *clear*, *cirrus*, dan *cloud*. *Shadow* adalah bayangan awan yang menghalangi permukaan bumi, sering kali menyulitkan analisis karena warnanya yang gelap menyerupai fitur lain. *Clear* mencakup area cerah tanpa gangguan awan, memungkinkan pengamatan permukaan bumi dengan jelas. *Cirrus* adalah awan tipis di lapisan atmosfer tinggi, yang meskipun transparan, dapat mempengaruhi pengukuran citra satelit. *Cloud* atau awan tebal, mencakup awan yang lebih padat dan signifikan menutupi permukaan bumi, sehingga sulit ditembus sensor satelit. Penambahan kelas *cirrus* bertujuan agar model yang dilatih mampu mengenali keberadaan awan tipis, karena awan tipis merupakan jenis awan yang paling susah untuk dihilangkan (Li dkk., 2021; Li dkk., 2022).

Dataset yang dibuat dari citra satelit Sentinel-2 ini terdiri dari 11.240 pasang data (citra dan label) dengan format GeoTIFF dengan resolusi 512x512 piksel. Dataset mencakup tujuh kanal spektral termasuk biru, hijau, merah, inframerah dekat (NIR), dua kanal red edge, dan inframerah gelombang pendek (SWIR). Total volume data sekitar 45,9 GB yang dibagi menjadi set pelatihan (9.122 citra), validasi (1.013 citra), dan pengujian (1.105 citra). Sampel dari pasangan citra dan label dari dataset dapat dilihat pada Gambar 3. Dataset ini termasuk dalam kategori dataset yang tidak seimbang dengan proporsi kelas *cloud*, *cirrus*, *clear* dan *shadow* adalah 47,4%, 9,2%, 37,8%, dan 5,6% secara berurutan.




Gambar 3. Pasangan antara image dan label dari dataset

3. TINJAUAN PUSTAKA

3.1. Model Segmentasi Semantik Umum

Model segmentasi semantik merupakan model *deep learning* yang bekerja pada level piksel. Model melakukan klasifikasi terhadap setiap piksel yang ada kedalam kelas tertentu. Beberapa model segmentasi semantik berbasis CNN diantaranya yaitu *Feature Pyramid Network* (FPN) (Lin dkk., 2016), *Pyramid Scene Parsing Network* (PSPNet) (Zhao dkk., 2016), *DeepLabv3+* (Chen dkk., 2018), dan *Light-Weight Refinement Atrous Spatial Pyramid Pooling* (LRASPP) (Howard dkk., 2019), yang arsitekturnya seperti yang ditunjukkan pada Gambar 4. Masing-masing model memiliki karakteristik dan keunggulan


tersendiri. FPN dan Deeplabv3+ dikenal dengan kemampuannya dalam menangkap konteks spasial dari berbagai skala, sedangkan LRASPP menonjol dengan desainnya yang ringan dan efisien.



Gambar 4. Model segmentasi semantik sebagai baseline: (a) FPN (Lin dkk., 2016), (b) PSPNet (Zhao dkk., 2016), (c) Deeplabv3+ (Chen dkk., 2018), (d) LRASPP (Howard dkk., 2019).

Gambar 5 menunjukkan beberapa arsitektur *backbone* yang dapat digunakan pada model segmentasi semantik sebagai *encoder* untuk melakukan ekstraksi fitur. Beberapa jenis *backbone* yang cukup populer adalah ResNet (He dkk., 2015), RegNet (Radosavovic dkk., 2020), dan EfficientNet (Tan dan Le, 2019). ResNet menggunakan pendekatan *residual learning* dan agregasi terarah memberikan dasar yang kuat untuk pelatihan jaringan yang dalam dan representasi fitur yang lebih baik. RegNet berfokus pada efisiensi skala dengan menawarkan keseimbangan optimal antara performa dan efisiensi komputasi. EfficientNet dikenal karena efisiensi komputasi yang tinggi dan menawarkan

peningkatan performa melalui scaling yang seimbang.




Gambar 5. *Backbone* sebagai *encoder*: (a) ResNet (He dkk., 2015), (b) RegNet (Radosavovic dkk., 2020), (c) EfficientNet (Tan dan Le, 2019).

3.2. Model Segmentasi Awan

Pendekatan paling sederhana untuk segmentasi awan melibatkan metode berbasis aturan dan ambang batas indeks spektral (Qiu dkk., 2019). Tetapi, metode ini mengalami kendala karena sulit untuk membedakan nilai spektral yang mirip dan adanya kompleksitas awan. Metode *deep learning* telah digunakan pada beberapa penelitian untuk melakukan segmentasi. Arsitektur seperti CNN klasik banyak digunakan karena sederhana dan efektif dalam menangkap konteks spasial (Li et al. 2022). Sementara itu, pendekatan berbasis Transformer telah diperkenalkan untuk deteksi awan karena kemampuannya untuk menangkap hubungan spasial global dalam citra (Tan et al. 2024). Arsitektur gabungan yang mengintegrasikan CNN dengan Transformer telah dieksplorasi untuk memanfaatkan kelebihan keduanya (Tan et al. 2023). Beberapa mekanisme attention juga telah diimplementasikan dengan tujuan agar model lebih fokus pada area yang penting dalam citra multispektral, sehingga meningkatkan akurasi deteksi awan di hadapan karakteristik spektral yang kompleks (Zhang et al. 2021).

4. METODE PENELITIAN



Gambar 6. Metode Penelitian

Gambar 6 menunjukkan metode penelitian yang dilakukan. Penelitian diawali dengan akuisisi data citra satelit multispektral Sentinel-2 dari GEE dan membuat label awan sebagai ground-truth menggunakan s2cloudless. Setelah dataset terbentuk, dipilih beberapa model segmentasi semantik untuk digunakan sebagai baseline. Beberapa model segmentasi semantik seperti FPN, PSPNet, DeepLabv3+, dan LRASPP dipilih sebagai baseline pada penelitian ini. Model-model tersebut akan dievaluasi kinerjanya menggunakan beberapa metrik. Metrik yang digunakan untuk mengukur kinerja model segmentasi awan adalah *F1-score*, *pixel accuracy*, dan *Mean Intersection over Union (mIoU)*. *F1-score* mengkombinasikan *precision* dan *recall* yang penting untuk dataset yang tidak seimbang. *Pixel accuracy* mengukur persentase piksel yang diklasifikasikan dengan benar terhadap keseluruhan piksel. *mIoU* mengevaluasi tumpang tindih segmen secara lebih menyeluruh. *Precision* merujuk pada proporsi piksel yang benar-benar terklasifikasi sebagai kelas tertentu (misalnya, awan) dari semua piksel yang diprediksi sebagai kelas tersebut, dengan *precision* tinggi menunjukkan prediksi yang akurat. *Recall* mengukur proporsi piksel yang benar-benar termasuk dalam kelas awan dan berhasil dideteksi dengan benar, di mana *recall* tinggi menunjukkan kemampuan model mendeteksi sebagian besar piksel yang seharusnya masuk dalam kelas tersebut. *Precision* dan *recall* dihitung menggunakan *confusion matrix* seperti pada Gambar 7, dengan *precision* diperoleh dari rasio *true positives* (TP) terhadap jumlah dari *true positives* dan *false positives* (FP), sedangkan *recall* diperoleh dari rasio *true positives* terhadap jumlah dari *true positives* dan *false negatives* (FN).

		Predicted Values	
		Positive	Negative
Actual Values	Positive	True Positive (TP)	True Negative (FN)
	Negative	False Positive (FP)	False Negative (FN)

Gambar 7. Confusion matrix

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1_score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (3)$$

$$Pixel\ Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (4)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (5)$$

$$mIoU = \frac{1}{n} \sum_{i=1}^n (IoU)_n \quad (6)$$

Penentuan *hyperparameter* yang tepat sangat penting agar model dapat mencapai kinerja optimal. Pengaturan *hyperparameter* dilakukan pada *optimizer* (*learning rate*, *weight decay*), *scheduler* (*eta min*), *batch size*, dan *loss function*. *Loss function* yang digunakan adalah *Dice-Cross-Entropy-Loss* (Galdran dkk., 2022) yang merupakan kombinasi dari *Dice Loss* dan *Cross-Entropy Loss*. *Dice Loss* cukup efektif dalam memaksimalkan tumpang tindih antara prediksi dan label, sementara *Cross Entropy Loss* memberikan penalti besar untuk prediksi yang salah, khususnya pada kelas minoritas. Optimasi model dilakukan menggunakan AdamW (Loshchilov dan Hutter, 2017) dengan *learning rate* awal sebesar 1e-3 dan *weight decay* sebesar 1e-4. AdamW merupakan varian dari Adam dengan menambahkan *weight decay* langsung pada parameter model yang membantu mencegah *overfitting* dengan menjaga agar bobot model tidak terlalu besar. *Scheduler* yang digunakan adalah *CosineAnnealingWarmRestarts* (Loshchilov dan Hutter, 2016) yang mengatur *learning rate* dengan pola annealing kosinus yang direset secara berkala, sehingga memungkinkan model untuk keluar dari minimum lokal dan menemukan minimum global selama pelatihan. Adapun ukuran *batch* yang digunakan adalah 8 dengan akumulasi gradien hingga 4 iterasi yang secara efektif meningkatkan ukuran *batch* menjadi 32.

Lingkungan pelatihan yang digunakan untuk melatih model ini menggabungkan komponen *hardware* dan *software* terkini. Pelatihan dilakukan menggunakan prosesor AMD Ryzen 5 8500G yang didukung oleh RAM berkapasitas 64 GB. Akselerasi grafis menggunakan GPU NVIDIA GeForce RTX 4060 dengan memori 8 GB dan 3.072 *cuda core*. Pelatihan dilakukan menggunakan Python versi 3.11.9 yang dipadukan dengan framework *deep learning* PyTorch versi 2.3.1+cu121. Adapun versi CUDA yang digunakan adalah 12.1.66 dan versi cuDNN yang digunakan adalah 9.2.

5. HASIL DAN PEMBAHASAN



5.1. Hasil Ablation Study

Tahap pertama dari *ablation study* ini adalah melakukan pelatihan beberapa baseline model. Model yang digunakan sebagai baseline yaitu: FPN, PSPNet, Deeplabv3+, dan LRASPP. Tabel 1 menunjukkan hasil dari baseline model. Berdasarkan data yang ada, model Deeplabv3+ menunjukkan kinerja yang terbaik dengan *F1-score* 0,91, *pixel accuracy* 9,17 dan *mIoU* 0,664. Sebaliknya, model PSPNet dan FPN

menunjukkan performa yang lebih rendah dengan *F1-score* masing-masing sebesar 0,835 dan 0,836, serta *mIoU* sebesar 0,497 dan 0,567. Dengan jumlah parameter yang lebih sedikit, kedua model ini cenderung kurang efisien dalam tugas segmentasi awan dibandingkan dengan Deeplabv3+. Visualisasi hasil segmentasi dari baseline model dapat dilihat pada Gambar 8.

Tabel 1. Kinerja dari model baseline

Model	#Params (juta)	F1-score ↑	Pixel Acc ↑	mIoU ↑
FPN	26,2	0,836	0,915	0,567
PSPNet	46,5	0,835	0,850	0,497
Deeplabv3+	67,9	0,917	0,917	0,664
LRASPP	4,3	0,746	0,902	0,391





Gambar 8. Visualisasi hasil segmentasi model baseline

Setelah Deeplabv3+ teridentifikasi sebagai model dengan kinerja yang terbaik, selanjutnya dilakukan pelatihan kembali dengan mengintegrasikan beberapa *backbone* ke model Deeplabv3+. Tujuan dari implementasi *backbone* adalah untuk melihat pengaruhnya terhadap kinerja model Deeplabv3+. Hasil eksperimen menunjukkan bahwa kombinasi Deeplabv3+ dengan *backbone* ResNet18 memberikan hasil terbaik dengan nilai *F1-score* 0,925, *pixel accuracy* 0,924, dan *mIoU* 0,710. Hasil ini menunjukkan bahwa kombinasi Deeplabv3+ dengan ResNet18 merupakan arsitektur yang cukup efektif dan efisien untuk segmentasi awan pada citra Sentinel-2. Perbandingan kinerja model Deeplabv3+ dengan *backbone* ResNet, Regnet, dan EfficientNet dapat dilihat pada Tabel 2. Adapun Gambar 9 menunjukkan visualisasi hasil segmentasi dari setiap model.

Tabel 2. Kinerja model Deeplabv3+ dengan beberapa *backbone*

Backbone	#Params (juta)	F1-score ↑	Pixel Acc ↑	mIoU ↑
Deeplabv3+				
+ ResNet18	28,8	0,921	0,923	0,728
+ ResNet50	67,9	0,914	0,917	0,664
+ RegNet_Y800MF	13,0	0,911	0,920	0,679
+ EfficientNet-B0	16,4	0,908	0,915	0,651






Gambar 9. Visualisasi hasil segmentasi Deeplabv3+ dengan beberapa *backbone*

DeepLabv3+ dengan backbone ResNet-18 lebih unggul dari sisi kinerja pada tugas segmentasi awan karena keseimbangan yang optimal antara kompleksitas dan efisiensi. ResNet-18 memiliki arsitektur yang lebih dangkal dibandingkan ResNet-50 atau backbone lainnya, tetapi mampu menangkap fitur-fitur seperti tekstur dan tepi yang penting untuk mendeteksi awan tanpa kehilangan detail spasial. Kompleksitasnya yang lebih rendah menghasilkan generalisasi yang lebih baik dan mengurangi risiko overfitting pada dataset yang terbatas. Selain itu, kombinasi ResNet-18 dengan *atrous convolution* dari DeepLabv3+ memperluas *receptive field* secara efisien tanpa meningkatkan jumlah parameter secara berlebihan, sehingga menjadikannya lebih cepat dalam pelatihan dan inferensi dibandingkan backbone yang lebih besar.

5.2. Fine-Tuning

Pada tahap ini dilakukan *fine-tuning*, yaitu pengaturan *hyperparameter*. Adapun yang disesuaikan antara lain *batch size*, *learning rate*, *weight decay*, dan *eta min*. Penyesuaian dilakukan terhadap *batch size* yang sebelumnya berukuran 32 diubah menjadi 64, *learning rate* dari $1e-3$ menjadi $5e-4$, *weight decay* dari $1e-4$ menjadi $5e-5$, dan *eta min* dari $1e-6$ menjadi $1e-7$. Kinerja terbaik yang dicapai oleh model Deeplabv3+ dengan *backbone* ResNet18 setelah dilakukan *fine tuning* adalah *F1-score* sebesar 0,922, *pixel accuracy* sebesar 0,923, dan *mIoU* sebesar 0,733. Adapun grafik loss dengan 100 epoch adalah seperti pada Gambar 10.



Gambar 10. Grafik train loss dan validation loss per epoch

6. KESIMPULAN

Pada penelitian ini telah dibuat dataset citra satelit multispektral untuk tugas segmentasi awan memanfaatkan citra Sentinel-2 dan algoritma *s2cloudless*. Beberapa model segmentasi awan berbasis CNN telah dikembangkan dan dilatih menggunakan dataset tersebut. Berdasarkan *ablation study*, model Deeplabv3+ dengan *backbone* ResNet18 menghasilkan kinerja terbaik dengan nilai *F1-score* 0,922 dan *pixel accuracy* 0,923. Meski demikian, dengan nilai *mIoU* 0,733 mengindikasikan bahwa ada ruang perbaikan lebih lanjut dalam segi segmentasi spasial, terutama dalam memprediksi area yang lebih sulit atau tumpang tindih antar kelas seperti *cirrus* dengan *cloud*. Untuk penelitian mendatang, dapat dikaji lebih mendalam terkait model yang mampu secara efektif membedakan berbagai bentuk, pola, ukuran, dan intensitas awan sehingga mampu melakukan segmentasi dengan lebih baik lagi.

DAFTAR PUSTAKA

- BPS GARUT, 2024. Kabupaten Garut Dalam Angka Tahun 2023. Garut: Badan Pusat Statistik.
- BPS INDRAMAYU, 2024. Kabupaten Indramayu Dalam Angka Tahun 2023. Indramayu: Badan Pusat Statistik.
- CHEN, L.C., ZHU, Y., PAPANDREOU, G., SCHROFF, F., dan ADAM, H., 2018. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. In Proceedings of the European conference on computer vision (ECCV) (pp. 801-818).
- GALDRAN, A., CARNEIRO, G., dan BALLESTER, M.Á.G., 2022. On The Optimal Combination of Cross-Entropy and Soft Dice Losses for Lesion Segmentation with Out-of-Distribution Robustness. In Diabetic Foot Ulcers Grand Challenge (pp. 40-51). Cham: Springer International Publishing.
- GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D., dan MOORE, R., 2017. Google Earth Engine: Planetary-scale Geospatial Analysis for

- Everyone. Remote Sensing of Environment, 202, 18–27.
- HE, K., ZHANG, X., REN, S., dan SUN, J., 2015. Deep Residual Learning for Image Recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- HOWARD, A., SANDLER, M., CHU, G., CHEN, L.C., CHEN, B., TAN, M., WANG, W., ZHU, Y., PANG, R., VASUDEVAN, V., LE, Q.V., dan ADAM, H., 2019. Searching for MobileNetV3. In Proceedings of the IEEE/CVF international conference on computer vision (pp. 1314-1324).
- HU, K., ZHANG, D., dan XIA, M., 2021. CDUNet: Cloud Detection UNet for Remote Sensing Imagery. Remote Sensing, 13(22).
- JEONG, S., KO, J., dan YEOM, J. M., 2022. Predicting Rice Yield at Pixel Scale Through Synthetic Use of Crop and Deep Learning Models with Satellite Data in South and North Korea. Science of the Total Environment, 802.
- LI, J., ZHANG, Y., SHENG, Q., WU, Z., WANG, B., HU, Z., SHEN, G., SCHMITT, M., dan MOLINIER, M., 2022. Thin Cloud Removal Fusing Full Spectral and Spatial Features for Sentinel-2 Imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15, 8759–8775.
- LI, J., WU, Z., HU, Z., LI, Z., WANG, Y., dan MOLINIER, M., 2021. Deep Learning Based Thin Cloud Removal Fusing Vegetation Red Edge and Short-Wave Infrared Spectral Information for Sentinel-2A Imagery. Remote Sensing, 13(1), 1–31.
- LI, J., dan WANG, Q., 2024. CSDFormer: A Cloud and Shadow Detection Method for Landsat Images Based on Transformer. International Journal of Applied Earth Observation and Geoinformation, 129.
- LI, X., YANG, X., LI, X., LU, S., YE, Y., & BAN, Y., 2022. GCDB-UNet: A Novel Robust Cloud Detection Approach for Remote Sensing Images. Knowledge-Based Systems 238: 107890.
- LIN, T.Y., DOLLÁR, P., GIRSHICK, R., HE, K., HARIHARAN, B., dan BELONGIE, S., 2016. Feature Pyramid Networks for Object Detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2117-2125).
- LOSHCHILOV, I., dan HUTTER, F., 2016. SGDR: Stochastic Gradient Descent with Warm Restarts. In International Conference on Learning Representations, ICLR 2017.
- LOSHCHILOV, I., dan HUTTER, F., 2017. Decoupled Weight Decay Regularization. arXiv preprint arXiv:1711.05101 (2017).
- PETTORELLI, N., SCHULTE TOBÜHNE, H., SHAPIRO, A.C., dan GLOVER-KAPFER, P., 2018. Satellite Remote Sensing for Conservation. WWF Conservation Technology Series 1(4). WWF.
- PU, W., WANG, Z., LIU, D., dan ZHANG, Q., 2022. Optical Remote Sensing Image Cloud Detection with Self-Attention and Spatial Pyramid Pooling Fusion. Remote Sensing, 14(17).
- QIU, S., ZHU, Z., dan HE, B., 2019. Fmask 4.0: Improved Cloud and Cloud Shadow Detection in Landsats 4–8 and Sentinel-2 Imagery. Remote Sensing of Environment 231: 111205.
- RADOSAVOVIC, I., KOSARAJU, R.P., GIRSHICK, R., HE, K., dan DOLLÁR, P., 2020. Designing Network Design Spaces. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 10428-10436).
- RICHTER, R., WANG, X., BACHMANN, M., SCHLÄPFER, D., 2011. Correction of Cirrus Effects in Sentinel-2 Type of Imagery. International Journal of Remote Sensing 32, 2931-2941.
- TAN, H., SUN, S., CHENG, T., & SHU, X., 2024. Transformer-Based Cloud Detection Method for High-Resolution Remote Sensing Imagery. Computers, Materials and Continua 80 (1): 661-678.
- TAN, M., dan LE, Q., 2019. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In International Conference on Machine Learning, ICML 2019 (pp. 6105-6114).
- TAN, Y., ZHANG, W., YANG, X., LIU, Q., MI, X., LI, J., YANG, J., & GU, X., 2023. Cloud and Cloud Shadow Detection of GF-1 Images Based on the Swin-UNet Method. Atmosphere 14 (11): 1669.
- THORP, K.R., dan DRAJAT, D., 2021. Deep machine learning with Sentinel satellite data to map paddy rice production stages across West Java, Indonesia. Remote Sensing of Environment, 265.
- WANG, B., ONO, A., MURAMATSU, K., FUJIWARA, N., 1999. Automated Detection and Removal of Clouds and Their Shadows from Landsat TM Images. IEICE Transactions on information and systems, 82(2), pp.453-460.
- WIJAYA, B.S., MUNIR, R., dan UTAMA, N.P., 2023. Curating multimodal satellite imagery for precision agriculture datasets with

- Google Earth Engine. International Conference of Data Science and Official Statistics.
- ZHANG, J., WU, J., WANG, H., WANG, Y., & LI, Y., 2021. Cloud Detection Method using CNN based on Cascaded Feature Attention and Channel Attention. IEEE Transactions on Geoscience and Remote Sensing 60: 1-17.
- ZHAO, H., SHI, J., QI, X., WANG, X., dan JIA, J., 2016. Pyramid Scene Parsing Network. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2881-2890).

Halaman ini sengaja dikosongkan