

Segmentasi Semantik Berbasis *Deeplabv3+* Untuk Pemantauan Pencemaran Sampah di Perairan Sungai

DOI: <http://dx.doi.org/10.35889/jutisi.v14i2.2962>

Creative Commons License 4.0 (CC BY – NC)

Putu Adi Widyantara^{1*}, Ni Wayan Marti², Putu Hendra Suputra³

Teknik Informatika, Universitas Pendidikan Ganesha, Bali, Indonesia

*e-mail Corresponding Author. adiwiidd20@gmail.com

Abstract

Rivers have an important role for living things, including humans. The current condition of the river is worrying, river pollution results in poor water quality. This research develops two semantic segmentation models with DeepLabv3+ for optimal river condition monitoring. The dataset acquired with UAVs amounted to 95 images that have gone through data cleaning and manually annotated with binary values, then classified into garbage, and river categories. Both categories of models were trained separately using DeepLabv3+ Architecture. Based on the evaluation results, the best performance of the garbage model Dice Coefficient Loss obtained and IoU 68.89%. While the best performance of the river category model with Jaccard Loss achieved an IoU of 99.9%. Providing a garbage segmentation map that focuses on river waters, the binary segmentation results of each model are parallel integrated using an AND logic operation approach, garbage outside the river pixels is eliminated. Thus, displaying a segmentation map that focuses on garbage in river waters.

Keywords: Semantic segmentation; DeepLabv3+; River pollution; UAV imagery

Abstrak

Sungai mempunyai peran yang penting bagi makhluk hidup salah satunya manusia. Kondisi sungai saat ini mengkhawatirkan, pencemaran sungai mengakibatkan kualitas air menjadi buruk. Penelitian ini mengembangkan dua model segmentasi semantik dengan *DeepLabv3+* untuk pemantauan kondisi sungai dengan optimal. *Dataset* diakuisisi dengan UAV berjumlah 95 citra telah melalui pembersihan data dan dianotasi manual dengan nilai biner, kemudian diklasifikasikan ke dalam kategori sampah, dan sungai. Kedua kategori model dilatih secara terpisah dengan menggunakan Arsitektur *DeepLabv3+*. Berdasarkan hasil evaluasi, performa terbaik dari model sampah *Dice Coefficient Loss* memperoleh dan IoU 68,89%. Sementara performa terbaik pada model kategori sungai dengan *Jaccard Loss* mencapai IoU 99,9%. Memberikan peta segmentasi sampah yang berfokus pada perairan sungai, hasil segmentasi biner dari setiap model secara paralel diintegrasikan menggunakan pendekatan operasi logika *AND*, sampah diluar piksel sungai dieliminasi. Sehingga menampilkan peta segmentasi yang berfokus pada sampah yang berada di perairan sungai.

Kata kunci: Segmentasi semantik; *DeepLabv3+*; Pencemaran sungai; Citra UAV

1. Pendahuluan

Sungai berperan penting dalam kehidupan makhluk hidup sebagai, jalur irigasi air untuk pengendali banjir, sumber air bersih untuk makhluk hidup seperti manusia, serta sebagai ekosistem biota perairan. Manusia sebagai makhluk hidup sangat bergantung pada sebagai sumber air bersih[1][2]. Ketergantungan pada sumber air bersih membuat kepedulian terhadap kelestrarian kebersihan air sungai menjadi sangat penting. Diperkirakan oleh Organisasi Kesehatan Dunia (WHO) dalam setiap tahunnya sebanyak 2,2 juta orang meninggal, sebagian besar korban adalah anak-anak, akibat penyakit yang berhubungan dengan kurangnya sumber air bersih dan kesehatan yang buruk[3].

Pencemaran sungai di Indonesia cukup tinggi, hanya 2,01% sungai mempunyai mutu sumber air bersih yang baik[4]. Tahun 2022 Indonesia menduduki posisi ke-4 sebagai negara populasi terbesar, mencapai 257 juta jiwa[5]. Kepadatan penduduk menyebabkan volume sampah yang dihasilkan juga sangat banyak. Dalam satu tahun timbulan sampah di Indonesia mencapai 33,54 juta ton, pemerintah mengupayakan untuk mengatasi permasalahan sampah, mampu mengelola dengan baik 59,82% dari timbulan sampah, dan 40,18% tidak terkelola[6]. Dengan ini sampah yang tidak terkelola akan menyebabkan terjadinya pencemaran lingkungan hingga pencemaran sungai. Sungai dijadikan tempat sampah oleh masyarakat sekitar karena pemerintah menyediakan fasilitas yang sedikit[7]. Masyarakat menjadikan sungai sebagai alternatif untuk membuang sampah. Perilaku ini sudah dilakukan secara terus-menerus, membuat peran sungai berubah menjadi media pembuangan sampah sehingga aliran sungai tersumbat oleh sampah yang menumpuk. Bencana banjir sangat merugikan masyarakat karena terganggunya aktivitas pada mata pencaharian[8][9]. Pemantauan rutin menjadi solusi untuk melihat pencemaran sungai[10]. Pemantauan seperti inspeksi manual, terbatas dalam cakupan wilayah dan efisiensi sehingga sulit dalam memberikan gambaran dari distribusi sampah.

Mengatasi keterbatasan teknik tradisional, penelitian ini mengajukan pendekatan 2 model segmentasi semantik berbasis *DeepLabv3+* yang melakukan segmentasi sampah dan sungai secara paralel atau independen, kemudian diintegrasikan melalui operasi logika AND (*AND logic*) untuk melakukan eliminasi dari hasil segmentasi sampah yang berada di luar perairan sungai. Pemisahan tugas ini lebih andal, seperti pada penelitian[11] yang menggunakan 2 model untuk menghasilkan peta segmentasi yang lebih baik dengan latar belakang yang cukup kompleks. Dan mengatasi kesalahan prediksi seperti yang terjadi pada penelitian[12]. Dalam pemantauan sampah menggunakan citra yang diambil menggunakan *Unmanned Aerial Vehicle* (UAV). UAV membantu melihat persebaran sampah dengan cakupan yang luas, menampilkan secara visual berkualitas tinggi dan bisa dilakukan analisis[13][14]. *DeepLabv3+* mampu mengelola citra yang memuat persebaran bentuk distribusi sampah, dengan fitur *encoder*, *decoder*, dan *Atrous Spatial Pyramid Pooling* yang mampu dalam menangkap informasi multi-skala dari bentuk sampah dan sungai, serta *DeepLabv3+* terbukti tangguh dari arsitektur lain dalam tugas segmentasi semantik sampah dan sungai[15][16].

Penelitian ini bertujuan untuk mengembangkan dua model segmentasi semantik berbasis *DeepLabv3+* yang berfokus segmentasi sungai dan sampah, dalam memetakan persebaran sampah di perairan sungai dari citra yang diperoleh menggunakan UAV. Penelitian ini memberikan manfaat dari pendekatan 2 model ini diharapkan mendukung dalam peningkatan efektifitas pemantauan kondisi sungai. Sistem memberikan kontribusi pada pencegahan lebih dini pada bencana banjir dan memetakan area yang terdapat pencemaran pada sungai secara efisien dan efektif sehingga berkontribusi juga pada pelestarian sumber air bersih.

2. Tinjauan Pustaka

Penelitian terdahulu membuktikan arsitektur *DeepLabv3+* tangguh dalam kasus segmentasi citra. Pada penelitian dengan judul "*ZeroWaste Dataset: Towards Deformable Object Segmentation in Cluttered Scenes*", menguji *DeepLabv3+*, *ReCo*, *CCT*, *PuzzleCAM* dan *EPS* untuk segmentasi dalam kasus pemilahan sampah limbah pabrik dari *dataset* yang dibuat secara mandiri melalui *converter belt* yang dipasang pada mesin pengelolaan sampah. Penelitian tersebut menunjukkan *DeepLabv3+* tangguh dalam memberikan peta segmentasi berdasarkan kelas sampah yang dipilah dari citra yang tumpang tindih dengan accuracy 91.13% dan nilai *Mean IoU* mencapai 52.13%[17].

Penelitian lain, mengangkat segmentasi perairan sungai yang berjudul "*Deep Learning Semantic Segmentation for Water Level Estimation Using Surveillance Camera*". Penelitian ini menguji *DeepLabv3+*, *Segnet* untuk segmentasi perairan sungai untuk mengukur ketinggian air dari sungai melalui kamera CCTV. Hasil yang diberikan menunjukkan kemampuan *DeepLabv3+* dalam kasus segmentasi perairan dibanding *Segnet*, dengan mendapat nilai akurasi sebesar 96.05% dan *IoU* mencapai 94.12%[18].

Penelitian selanjutnya, penelitian yang berjudul "*An Approach for Plant Leaf Image Segmentation Based on YOLOV8 and the Improved DEEPLABV3+*" menggunakan 2 model yang memiliki tugas individu, model YOLO digunakan untuk memfokuskan objek dan menghilangkan objek lain yang mengganggu kemudian model segmentasi dengan *DeepLabv3+* untuk melakukan segmentasi, penelitian ini mengangkat deteksi daun tanaman dengan segmentasi semantik. *DeepLabv3+* sangat tangguh membedakan objek daun dengan *background* mencapai performa


sangat baik dengan nilai mIoU 88.1%. Dengan metode kombinasi model mempermudah model segmentasi memisahkan objek dari gangguan *background* yang kompleks[11].

Pada penelitian terakhir, yang mengangkat permasalahan pencemaran sungai pada penelitian yang berjudul "*Trash Detection on Water Channels*". Penelitian ini mengembangkan sistem deteksi sampah menggunakan segmentasi semantik multi kelas dengan menguji *SegNet* dan *U-Net*, hasil evaluasi menunjukkan performa *Segnet* lebih baik dari *Unet*, dengan *accuracy* 88%. Dari hasil peta segmentasi, menunjukkan kesulitan dalam mendeteksi sampah yang mirip dengan latar belakang dan terdapat kesalahan prediksi sampah di luar dari badan sunga[12].

Berdasarkan dari penelitian terdahulu, menunjukkan ketangguhan dari arsitektur *DeepLabv3+* dalam kasus segmentasi sampah dan air yang sebagian besar menggunakan model tunggal dalam tugas segmentasi semantik. Penelitian[12] menggunakan model tunggal dalam tugas segmentasi semantik multikelas, namun menghasilkan kesalahan pada segmentasi sampah di luar area sungai yang seharusnya sampah di area sungai menjadi fokus utama. Penelitian[11] menggunakan pendekatan kombinasi dari 2 model, seperti model deteksi dan segmentasi yang membantu memberikan fokus pada objek dari tugas segmentasi. Penelitian mengadopsi dari penelitian terdahulu dengan menggunakan Arsitektur *DeepLabv3+* dalam mengembangkan pendekatan 2 model segmentasi biner, masing-masing model dilatih secara independen untuk tugas segmentasi sampah dan segmentasi sungai. Kedua model bekerja secara paralel dalam memberikan hasil prediksi berupa peta segmentasi biner, yang kemudian diintegrasikan melalui operasi logika *AND* (*AND logic*), sehingga membantu memetakan sampah yang berfokus pada area sungai. Dengan pendekatan ini memberikan solusi terhadap kesalahan prediksi sampah di luar sungai dari pendekatan model tunggal dalam tugas segmentasi multikelas.

3. Metodologi

Penelitian ini menggunakan *Framework Tensorflow* dan mengadopsi arsitektur *DeepLabv3+* sebagai kerangka dalam melatih pendekatan dua model segmentasi semantik dalam mendukung deteksi secara optimal untuk pemantauan sampah di perairan sungai melalui citra yang diakuisisi menggunakan UAV yang bergerak diatas perairan dengan melihat kondisi sungai. Menggunakan perangkat dengan spesifikasi GPU RTX 4060 Ti dengan VRAM 8 GB, *Processor AMD Ryzen 7* serta RAM 32 GB. Tahap pelaksanaan penelitian ini melalui beberapa tahapan, meliputi Mengakuisisi & Anotasi Data, Persiapan Data, Modelling yang menghasilkan kategori model sungai dan sampah, kemudian Evaluasi Model, serta Intergrasi Model untuk mendapatkan objek yang berfokus pada perairan sungai. Tahapan dari penelitian ini ditampilkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

1) Mengakuisisi & Anotasi Data

Dataset diakuisisi secara mandiri dengan merekam kondisi sungai menggunakan UAV. Adapun standarisasi akuisisi yakni, sungai direkam pada kondisi cerah, dengan panjang sungai 2-5 meter, kecepatan 5meter/second dengan ketinggian 100-400centimeter, UAV merekam dengan resolusi 1920x1080, 60FPS dengan arah kamera tegak lurus menghadap sungai (90°).

Hasil rekaman berupa video diekstrak menjadi *frame*, ekstraksi *frame* dari data video adalah cara dalam analisis pada *computer vision* yang efektif untuk mengkonversi data temporal menjadi data yang bisa diproses oleh mesin[19]. Selanjutnya dilakukan pembersihan data untuk mengurangi ketidaksesuaian data[20]. *Frame* diseleksi menjadi berjumlah 95 citra. Citra diberi anotasi berdasarkan 2 kategori yaitu objek sampah dengan *background*, dan sungai dengan *background*. Setiap objek bernilai *True* (1) diberi warna putih dan *background* bernilai *False* (0) diberi warna hitam, sehingga menghasilkan nilai biner pada *ground truth*. *Ground truth* digunakan sebagai kunci jawaban dalam pelatihan model. Citra *ground truth* pada masing-masing kategori dilihat pada gambar


2) Persiapan Data

Tahap Persiapan Data adalah tahapan untuk mempersiapkan data sebelum dilatih, menyeragamkan data agar lebih terstruktur untuk mudah dianalisis[21]. Data diseragamkan menjadi ukuran 256x256 untuk meringankan beban kerja komputasi. Data dinormalisasikan menjadi rentang (1,0), normalisasi data mengurangi ketergantungan dari *gradient* terhadap skala nilai awal pada fase pelatihan[22]. Diterapkan *thresholding* agar citra *ground truth* bernilai biner (1,0). Augmentasi diterapkan untuk menambah variasi dari dataset. Data telah melewati augmentasi, kemudian dibagi menjadi 3 *subset* data dengan pembagian 80% untuk *training*, berjumlah 1976 citra, 20% untuk *validation* dan *testing*, berjumlah 247 citra. Data *training* digunakan untuk melatih model, data *validation* mengecek dan memvalidasi hasil pelatihan. Model dilatih diuji sebagai pengukur performa model menggunakan data *testing*.

3) Modelling

a. DeepLabv3+

DeepLabv3+ merupakan kerangka dari masing-masing model yang bangun. Terdiri dari 2 bagian, Bagian *Encoder* yang terdapat beberapa lapisan seperti *Backbone* yang berfungsi untuk ekstraksi fitur, kemudian *atrous convolution* untuk menangkap multi-skala pada citra. Bekerja pada setiap konvolusi dimana pada konvolusi terdapat *rate* untuk melewati beberapa piksel. Menggunakan *avarge pooling* untuk mengumpulkan informasi secara global, bukan hanya satu fitur yang menonjol. Sementara bagian *Decoder* terdapat beberapa lapisan untuk mengembalikan resolusi setelah proses ekstraksi fitur, dimana ekstraksi fitur dari backbone dan *atrous convolution* digabungkan hingga menghasilkan *output* berupa peta segmentasi dengan lokalisasi yang bagus dengan konteks global dalam citra[15]. Adapun dari arsitektur *DeepLabv3+* divisualisasikan pada Gambar 2.



Gambar 2. Arsitektur *DeepLabv3+*

b. Loss Function

Dalam *deep learning* terdapat parameter seperti *Loss Function*, berfungsi untuk mengetahui kesalahan antara nilai prediksi dengan nilai yang sebenarnya. Meminimalkan nilai kesalahan sehingga model terus diperbaiki untuk membangun prediksi yang akurat. Semakin rendah loss semakin bagus performa model dalam keberhasilan menangkap pola-pola citra.

Binary Cross Entropy (BCE) Loss, menghitung probabilitas antara hasil nilai prediksi dengan nilai sebenarnya. Perhitungan loss function tersebut di tampilkan melalui persamaan (1).

$$L_{BCE} = \frac{1}{n} \sum_{i=1}^n L(Y_i, \hat{p}_i) \quad (1)$$

Focal Loss dirancang untuk mengatasi ketidakseimbangan kelas, bekerja dengan menambahkan bobot pada kelas minoritas, sehingga permasalahan pada *dataset* yang tidak seimbang. Perhitungan *loss function* tersebut di tampilkan melalui persamaan (2).

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (2)$$

Kemudian *Jaccard Index Loss*, menggunakan metrik *Jaccard* untuk menghitung berdasarkan nilai tumpang tindih antara piksel prediksi dengan *ground truth* Perhitungan *loss function* tersebut di tampilkan melalui persamaan (3).

$$L_{jaccard} = 1 - \frac{(P \cap R)}{(P \cup R)} \quad (3)$$

Loss function yang terakhir adalah *Dice Coefficient Loss*, mengukur kesamaan dari area yang dihasilkan oleh prediksi dengan *ground truth* Perhitungan *loss function* tersebut di tampilkan melalui persamaan (4).

$$L_{DSC} = 1 - (1 + \beta^2) \frac{P \cdot R}{\beta^2 (P + R)} \quad (4)$$

c. Training Model

Pelatihan model dilatih dengan terpisah dan pengaturan *hyperparameter* serupa. Pelatihan menggunakan *epoch* 100, dan menerapkan *Callback Early stopping* untuk memberhentikan pelatihan selama tidak ada penurunan nilai validation loss, selama pelatihan diterapkan *ReduceLROnPlateau* untuk menurunkan *learning rate* guna memperlambat pelatihan model hingga mencapai *learning rate* minimum 1e-6. Dalam proses pelatihan *dataset* dilatih dengan *batch size* sebesar 8, *Optimizer* menggunakan *Adam*, yang mampu memperbarui bobot secara otomatis dan mempercepat konvergensi pelatihan, dengan fungsi aktivasi yaitu *sigmoid* untuk mendapatkan probabilitas kelas bernilai biner. Adapun *loss function* yang diuji adalah *Binary Cross Entropy (BCE)*, *Focal Loss*, *Dice Coefficient*, dan *Jaccard Index (IoU)*. Dengan menguji 4 *loss function* pada model 2 pendekatan kategori model, sehingga hasil model yang dilatih berjumlah 8 model segmentasi, yang dijabarkan pada Tabel 1. Setiap model akan diuji dengan menerapkan *dropout* untuk memperbaiki permasalahan *overfitting* selama pelatihan

Tabel 1 Inisialisasi Model Segmentasi

Kategori Model	Loss Function	Dropout
Sungai	<i>Binary Cross Entropy</i>	<i>Tanpa</i>
Sungai	<i>Dice Coefficient</i>	<i>Tanpa</i>
Sungai	<i>Jaccard Index</i>	<i>Tanpa</i>
Sungai	<i>Focal</i>	<i>Tanpa</i>
Sampah	<i>Binary Cross Entropy</i>	<i>Tanpa</i>
Sampah	<i>Dice Coefficient</i>	<i>Tanpa</i>
Sampah	<i>Jaccard Index</i>	<i>Tanpa</i>
Sampah	<i>Focal</i>	<i>Tanpa</i>
Sungai	<i>Binary Cross Entropy</i>	<i>Regularization Dropout</i>
Sungai	<i>Dice Coefficient</i>	<i>Regularization Dropout</i>
Sungai	<i>Jaccard Index</i>	<i>Regularization Dropout</i>
Sungai	<i>Focal</i>	<i>Regularization Dropout</i>
Sampah	<i>Binary Cross Entropy</i>	<i>Regularization Dropout</i>
Sampah	<i>Dice Coefficient</i>	<i>Regularization Dropout</i>
Sampah	<i>Jaccard Index</i>	<i>Regularization Dropout</i>
Sampah	<i>Focal</i>	<i>Regularization Dropout</i>

4) Evaluasi

Model yang telah dilatih secara terpisah dengan pengaturan *hyperparameter* yang serupa, model diukur performanya. Evaluasi model menggunakan beberapa metrik evaluasi dihitung melalui matriks kebingungan untuk melaluan analisis terhadap performa model[23]. *Pixel Accuracy*, mengukur performa model dalam proses klasifikasi piksel dari model berdasarkan referensi *ground truth*. Perhitungan *Pixel Accuracy* ditampilkan pada persamaan (5).

$$Pixel\ Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

Intersection over Union (IoU) umumnya digunakan pada kasus segmentasi citra, metrik ini digunakan untuk mengukur tumpang tindih piksel prediksi dengan *ground truth*. Perhitungan dari metrik IoU ditampilkan pada persamaan (6).

$$IoU = \frac{TP}{TP + FP + FN} \quad (6)$$

Selain menggunakan IoU, metrik *F1-Score* digunakan untuk mengukur rata-rata nilai *precision* dan *recall*. Perhitungan dari metrik *F1-Score* ditampilkan pada persamaan (7).

$$F1Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (7)$$


5) Integrasi Model

Proses integrasi model untuk mendapatkan visualisasi peta segmentasi sampah yang berfokus pada perairan sungai. Masing-masing model segmentasi berdasarkan dari kategori tugasnya, bekerja secara paralel menghasilkan peta segmentasi biner, kelas objek (*foreground*) bernilai *True* (1) dan *background* bernilai *False* (0). Untuk mendapatkan hasil segmentasi yang berfokus pada sampah di perairan sungai, *output* 2 model diintegrasikan dengan operasi logika *AND* pada piksel-piksel hasil segmentasi 2 model.

4. Hasil dan Pembahasan

4.1. Hasil


Penelitian ini mengakuisisi *dataset* secara mandiri dengan UAV bergerak di atas perairan sungai sambil melakukan perekaman terhadap kondisi sungai. Lokasi yang digunakan adalah 3 sungai, dari 3 sungai masing-masing menghasilkan 2 video dari 3 sungai sehingga mendapatkan 6 video. Video tersebut diekstraksi menjadi *frame* yang kemudian diseleksi, sehingga *frame* berjumlah 95 citra. *Frame* diberi anotasi secara manual berdasarkan dengan kategori model yang dibangun yaitu, kategori model sungai-nonsungai untuk mendeteksi objek sungai dan memisahkannya dengan nonsungai (*background*). Kemudian kategori model yang kedua adalah model sampah-nonsampah, difokuskan untuk mendeteksi sampah dan memisahkan dengan piksel nonsampah. Adapun hasil dari anotasi ditampilkan pada Gambar 3.



Gambar 3 Hasil Anotasi Citra


Dataset diseragamkan ukurannya dengan *resize* 256x256, dan *threshold* bernilai 127, jika nilai piksel dibawah dari nilai 127 maka akan dikategorikan sebagai *background*, namun jika diatas dari nilai *threshold* maka dikategorikan sebagai *foreground* (objek). Augmentasi diterapkan untuk menambah variasi data. Adapun penerapan augmentasi pada dataset ditampilkan pada Gambar 4, yang menampilkan citra *original* (a), penambahan variasi data seperti rotasi (b), *flip*

(c), zoom (d), saturation (e), gaussian noise (f), brightness (g), blur (h). Dataset yang telah melalui proses augmentasi berjumlah sebanyak 2470 citra. Penambahan variasi ini membantu model belajar terhadap data dengan berbagai skenario pada dunia nyata.




Gambar 4. Augmentasi Data

Data dibagi menjadi 3 subset, 80% data *training* berjumlah 1976, 20% data *validation* dan *testing*, masing-masing berjumlah 247 citra. Pelatihan model menggunakan kerangka Arsitektur DeepLabv3+, dua model segmentasi dilatih secara terpisah dengan *hyperparameter* serupa, *epoch* 100, *batch size* 8, *learning rate* 1e-4, *Optimizer Adam*, menggunakan *Callback Early Stopping* dengan *patience* 10, dan menggunakan *ReduceLROnPlateau* dengan nilai minimum 1e-6 dengan *patience* 5. Serta melakukan pengujian pada *loss function*, *Binary Cross Entropy* (BCE), *Focal*, *Dice Coefficient*, dan *Jaccard Index Loss*. Dari hasil training pada masing-masing model ditunjukkan pada Gambar 5 dan 6. Hasil training pada model segmentasi sungai dengan pengujian penggunaan berbagai *loss function* dan *Regularization Dropout*, dengan metrik *Accuracy*, *F1-Score* dan *IoU*. Dari grafik tersebut penerapan *Regularization Dropout* memperlambat konvergensi pada *Loss Function Focal Loss* hingga *epoch* 64. dan memperbaiki gap data *train* dan *validation*.



Gambar 5. Grafik *Training Model Segmentasi Sungai* tanpa dan dengan *Regularization Dropout*

Sementara pada model segmentasi sampah dengan pengujian penggunaan berbagai *loss function* dan *Regularization Dropout*, dengan metrik *Accuracy (Pixel Accuracy)*, *F1-Score* dan *IoU*. Dari grafik tersebut hasil *training* menunjukkan penerapan *Regularization Dropout* memperlambat konvergensi pada *Loss Function Focal Loss*, hingga *epoch* 100 sedangkan pada BCE hanya diperlambat sedikit.



Gambar 6. Grafik *Training Model Segmentasi Sampah* tanpa dan dengan *Regularization Dropout*

Mengukur performa model menggunakan metrik evaluasi *Accuracy*, *F1-Score* dan *IoU* yang dimuat pada Tabel 2. Model diuji pada data uji yang berjumlah 247 citra, menghasilkan model segmentasi sungai pada *Loss Function Jaccard Loss* dengan *Regularization Dropout* memperoleh performa terbaik di semua metrik dengan *Pixel Accuracy* 99.93%, *F1-Score* 99.95%, dan *IoU* 99.9%.

Tabel 2 Evaluasi Performa Model Segmentasi Sungai


<i>Loss Function</i>	<i>Pixel Accuracy</i>	<i>F1-Score</i>	<i>IoU</i>	<i>Waktu prediksi /detik</i>
<i>Binary Cross Entropy</i>	0.9990	0.9992	0.9985	0.0127
<i>Focal</i>	0.9983	0.9988	0.9976	0.0126
<i>Dice Coefficient</i>	0.9971	0.9980	0.9961	0.0127
<i>Jaccard Index</i>	0.9992	0.9994	0.9989	0.0128
<i>Binary Cross Entropy Regularization Dropout</i>	0.9988	0.9992	0.9984	0.0126
<i>Focal Loss Regularization Dropout</i>	0.9985	0.9989	0.9978	0.0126
<i>Dice Coefficient Regularization Dropout</i>	0.9990	0.9993	0.9986	0.0127
<i>Jaccard Index Regularization Dropout</i>	0.9993	0.9995	0.9990	0.0127

Sementara, pada model segmentasi sampah, hasil metrik evaluasi pada pengujian *loss function* dan penerapan *dropout* ditampilkan pada Tabel 3. *Dice Coefficient Loss* mendapatkan performa terbaik dari metrik *Pixel Accuracy* sebesar 98.68% dan *IoU* mencapai 69.89%. Model tanpa *Regularization Dropout* lebih baik pada model segmentasi sampah. Pada penerapan dropout selama pelatihan *neuron* yang dieliminasi secara acak penyebab penurunan performa karena mengganggu model selama proses mengenali pola penting secara konsisten pada data dengan *foreground* yang minoritas

Tabel 3 Evaluasi Performa Model Segmentasi Sampah


<i>Loss Function</i>	<i>Pixel Accuracy</i>	<i>F1-Score</i>	<i>IoU</i>	<i>Waktu prediksi /detik</i>
<i>Binary Cross Entropy</i>	0.9858	0.7835	0.6807	0.0128
<i>Focal</i>	0.9830	0.6966	0.5895	0.0135
<i>Dice Coefficient</i>	0.9868	0.7938	0.6989	0.0129
<i>Jaccard Index</i>	0.9867	0.7913	0.6963	0.0139
<i>Binary Cross Entropy Regularization Dropout</i>	0.9861	0.7852	0.6822	0.0132
<i>Focal Loss Regularization Dropout</i>	0.9831	0.7022	0.5956	0.0139
<i>Dice Coefficient Regularization Dropout</i>	0.9868	0.7939	0.6951	0.0131
<i>Jaccard Index Regularization Dropout</i>	0.9868	0.7948	0.6959	0.0133

Model terbaik di setiap kategori dipercaya dalam tugas nya masing-masing untuk memberikan peta hasil segmentasi. Menampilkan peta segmentasi semantik dari objek sampah khusus di perairan sungai, dengan menggunakan luaran atau hasil segmentasi dari 2 model diintegrasikan untuk menghasilkan 1 peta segmentasi. Adapun proses ini divisualisasikan pada Gambar 7. Proses integrasi dimulai Ketika masing-masing model diberi *output* citra yang serupa, dan kedua model bekerja secara paralel memberikan hasil peta segmentasi, model sungai memberikan hasil segmentasi biner, objek sungai berwarna putih, dan nonsungai hitam, sementara model sampah segmentasi biner dengan objek sampah berwarna putih, dan hitam untuk nonsampah. Diberikan pembaruan identitas untuk mempermudah analisis, model sungai warna biru diberi untuk mengganti warna putih pada kelas objek sungai, begitu juga pada model sampah warna putih diganti menjadi warna merah untuk merepresentasikan objek sampah. Hasil dari 2 peta segmentasi dilakukan interseksi melalui operasi logika *AND*, dimana piksel sampah di luar dari piksel sungai dieliminasi, namun piksel sampah yang berada di piksel sungai dipertahankan. Kelas true atau objek dari masing-masing model dipertahankan karena sama-sama bernilai 1, namun jika terdapat kelas yang berbeda misal objek dan *background* dari hasil masing-masing model maka akan dieliminasi. Sehingga menghasilkan *output* segmentasi objek sampah yang berada di perairan sungai. Penerapan ini membantu dalam mengatasi kesalahan prediksi sampah di luar dari piksel sungai atau *False Positive*, namun hasil prediksi sampah akan sangat bergantung dari peta segmentasi sungai.



Gambar 7. Proses Interseksi

Dari proses interseksi yang ditampilkan pada Gambar 7. Hasil peta segmentasi ditampilkan pada Gambar 8, terdapat citra original yang muat sungai dan tepi sungai, serta objek sampah tersebar di area perairan dan tepi sungai, kemudian hasil biner dari prediksi sampah dan prediksi sungai, serta menampilkan hasil interseksi melalui operasi logika and pada hasil segmentasi 2 model yang bekerja secara *parallel*. Dari hasil tersebut membantu dalam memberikan fokus pada sampah yang berada di perairan sungai untuk mengatasi pencemaran air sungai.



Gambar 8. Hasil Peta Segmentasi Interseksi

4.2. Pembahasan

Berdasarkan dari evaluasi performa model, didapat bahwa pada model kategori sungai, *Jaccard Loss Dropout (Regularization Dropout)* mendapatkan performa terbaik dengan IoU sebesar 99,9%. Menunjukkan *Jaccard Loss* mampu dalam mendeteksi perairan sungai pada citra yang didominasi oleh kelas sungai (*foreground*). *Jaccard Index Loss* mampu dan memberikan performa yang bagus dalam mengatasi kelas yang tidak seimbang pada dataset, yang didominasi oleh kelas *foreground* atau objek [24]. Pengujian dengan *Regularization Dropout* menunjukkan bahwa penerapan *Regularization Dropout* membantu dalam memperbaiki performa dimana eliminasi neuron selama pelatihan justru memperkuat model dalam belajar pada dataset dengan *foreground* yang lebih dominan.

Sementara pada model kategori sampah model dengan *Dice Coefficient Loss* memberikan performa terbaik dalam mengenali objek sampah, dengan IoU mencapai 69.89%. *Loss Function Dice Coefficient* mampu dalam mengatasi dataset yang tidak seimbang, dengan objek sampah yang minoritas. Biasa digunakan pada citra medis yang bekerja dengan mengoptimalkan nilai antara *overlap* dengan *ground truth*, yang mampu menangani dataset yang tidak seimbang didominasi *background* dibanding *foreground*[25]. Penerapan *Regularization Dropout* justru memperburuk dengan hasil yang lebih kecil dibanding tanpa *Regularization Dropout* yakni sebesar 69.51%. *Neuron* yang dieliminasi secara acak penyebab penurunan performa karena mengganggu model selama proses mengenali pola penting secara konsisten pada data dengan *foreground* yang minoritas[26].

Berdasarkan metrik evaluasi dari masing-masing model, performa dari model segmentasi sampah memberikan akurasi 98.68% dan IoU mencapai 69.89%. hasil yang diberikan cukup tinggi dengan hasil yang mampu mengenali sampah yang berada di perairan maupun di tepi sungai. Sedangkan pada penelitian yang berjudul “ZeroWaste Dataset: Towards Deformable Object Segmentation in Cluttered Scenes” mencapai IoU sebesar 52.13%.

Sementara pada model segmentasi sungai memberikan performa yang sangat tinggi dengan *Accuracy* 99.96, dan IoU sebesar 99.90% dengan nilai ini mampu memisahkan antara perairan sungai dengan tepi sungai dengan sangat akurat. Sedangkan pada penelitian terdahulu yang berjudul “Deep Learning Semantic Segmentation for Water Level Estimation Using Surveillance Camera” 96.05% dan IoU mencapai 94.12%.

Penelitian ini berhasil dalam mengembangkan pendekatan 2 model yang masing-masing dilatih dengan Arsitektur *Deeplabv3+* untuk melakukan segmentasi sampah di perairan sungai. Kedua model dilatih secara terpisah dengan tugas segmentasi semantik biner, sehingga membuat model bekerja secara individu dan fokus pada masing-masing tugas. Pendekatan ini secara visual mampu membantu dalam memperbaiki kesalahan prediksi objek sampah di luar perairan sungai dengan eliminasi piksel yang tidak tumpang tindih antara piksel sungai dan piksel sampah, sehingga membantu memperbaiki kelemahan dari pendekatan model tunggal dalam tugas segmentasi multikelas yang dialami pada penelitian[12]. Dari keberhasilan dalam mengurangi segmentasi sampah di luar perairan sungai dengan eliminasi piksel melalui operasi *AND*, yang sejalan dengan penelitian[11], 2 model yang membantu meningkatkan hasil segmentasi dengan fokus objek karena deteksi objek yang dilakukan untuk menghindari latar belakang yang kompleks. Integrasi dua model biner andal dalam memberikan *output* multikelas yang lebih baik. Pendekatan integrasi 2 model memberikan hasil yang bagus untuk memberikan fokus, penelitian ini berperan dalam pengembangan metode segmentasi semantik yang lebih andal dalam mengurangi kesalahan prediksi dengan memberikan fokus pada area segmentasi. Berkontribusi pada *computer vision* dalam pengembangan model segmentasi semantik yang lebih andal untuk mendukung dalam peningkatan efektifitas pemantauan persebaran sampah yang lebih akurat dan lebih fokus pada area yang diinginkan seperti perairan sungai, penelitian ini juga memberikan kontribusi pada pencegahan lebih dini pada bencana banjir dan melihat area yang terdapat pencemaran pada sungai secara efisien dan efektif.

5. Simpulan

Penelitian ini berhasil mengembangkan pendekatan 2 model segmentasi semantik biner, yang masing-masing model memberikan performa yang baik dalam menghasilkan peta segmentasi berdasarkan kategori model. Dilatih menggunakan citra yang berjumlah 2470 citra hasil augmentasi untuk menambah variasi. Model segmentasi sungai memberikan performa dengan IoU sebesar 99.9% dan *Accuracy* sebesar 99.93% pada *Jaccard Loss* dan dengan *Regularization Dropout*. Sementara pada model segmentasi sampah mencapai nilai IoU 69.89%

dan *Accuracy* 98.69% pada *Dice Coefficient Loss* dan tanpa *Regularization Dropout*. Menunjukkan penggunaan *loss function* dan *Regularization Dropout* bergantung dari variasi *dataset* dan dominasi kelas *foreground* maupun *background*. Integrasi model membuat *output* model biner (sampah/sungai & *background*) menjadi multi kelas (sampah, sungai & *background*). Hasil integrasi dari 2 model memberikan area fokus pada sampah di perairan sungai dengan mengeliminasi piksel sampah di luar perairan sungai. Pendekatan ini membantu dalam menangani kelemahan pendekatan model tunggal untuk tugas segmentasi multikelas dalam memetakan kesalahan prediksi seperti segmentasi sampah di luar area sungai.

Daftar Referensi

- [1] M. S. Harefa, S. Hidayat, K. Sisca, O. Luahambowo, R. Siregar, dan W. Asmara, "Analisis Pemanfaatan Air Sungai Bagi Kehidupan Masyarakat dari Aliran Air Terjun Sipiso Piso di Kecamatan Merek Kabupaten Karo," *Jurnal Ilmu Sosial*, vol. 5, no. 5, pp. 26-37, 2024, doi: 10.6578/triwikrama.v5i5.6855.
- [2] H. Antara dkk., "English Title: Relationship between Humans and River Areas 'Human Impacts on Cisdane River Water, West Java-Banten,'" *Ethics and Law Journal: Business and Notary (ELJBN)*, vol. 2, no. 1, pp. 2988–1293, 2024, [Daring]. Tersedia pada: <http://journals.ldpb.org/index.php/eljbn>
- [3] Sukmawati, M. Anwar, dan Paharuddin, "Perilaku Masyarakat dalam Memanfaatkan Air Sungai Sebagai Air MCK Community Behavior in Using River Water as Toilet Water," *KEPO: Jurnal Keperawatan Profesional*, vol. 3, no. 1, pp. 88–95, 2022, doi: 10.36590/v3i1.299.
- [4] F. Sugiester S, Y. W. Firmansyah, W. Widiyantoro, M. F. Fuadi, Y. Afrina, dan A. Hardiyanto, "Dampak Pencemaran Sungai di Indonesia Terhadap Gangguan Kesehatan : Literature Review," *Jurnal Riset Kesehatan Poltekkes Depkes Bandung*, vol. 13, no. 1, pp. 120–133, Agu 2021, doi: 10.34011/juriskesbdg.v13i1.1829.
- [5] World Bank, "World Development Indicators: Population 2022," 2023. Diakses: 11 Februari 2025. [Daring]. Tersedia pada: <http://data.worldbank.org/data-catalog/world-development-indicators>
- [6] SIPSN, "Capaian Kinerja Pengelolaan Sampah." Diakses: 22 Maret 2025. [Daring]. Tersedia pada: <https://sipsn.menlhk.go.id/sipsn/>
- [7] A. Nggilu, N. Raffi Arrazaq, dan T. Thayban, "Dampak Pembuangan Sampah di Sungai Terhadap Lingkungan dan Masyarakat Desa Karya Baru," *Jurnal Normalita*, vol. 10, no. 3, pp. 196–202, Sep 2022, Diakses: 28 Juni 2025. [Daring]. Tersedia pada: <https://ejurnal.pps.ung.ac.id/index.php/JN/article/view/1795>
- [8] P. Ony Andewi, K. Agus Seputra, K. Yota Ernanda Aryanto, L. Joni Erawati Dewi, dan F. Teknik dan Kejuruan, "Integrasi Teknologi Penginderaan Jauh Dan Machine Learning pada Web Gis untuk Pemetaan Potensi Banjir," *Jurnal Pendidikan Teknologi dan Kejuruan*, vol. 22, no. 1, pp. 12–23, Jan 2025, doi: <https://doi.org/10.23887/jptkuniksha.v22i1.87455>.
- [9] A. Taryana, M. Rifa, E. Mahmudi, dan H. Bekt, "Analisis Kesiapsiagaan Bencana Banjir di Jakarta," *Jurnal Administrasi Negara*, Februari, vol. 13, no. 2, pp. 302–311, 2022, Diakses: 28 Juni 2025. [Daring]. Tersedia pada: <https://jurnal.unpad.ac.id/jane/article/view/37997/16902>
- [10] M. Gazali dan A. Widada, "Analisis Kualitas Dan Perumusan Strategi Pengendalian Pencemaran Air Sungai Bangkahulu Bengkulu," *Journal of Nursing and Public Health*, vol. 9, no. 1, pp. 54–60, 2021, Diakses: 28 Juni 2025. [Daring]. Tersedia pada: <https://jurnal.unived.ac.id/index.php/jnph/article/view/1441>
- [11] T. Yang, S. Zhou, A. Xu, J. Ye, dan J. Yin, "An Approach for Plant Leaf Image Segmentation Based on YOLOV8 and the Improved DEEPLABV3+," *Plants*, vol. 12, pp. 3438, Sep 2023, doi: 10.3390/plants12193438.
- [12] M. Tharani, A. W. Amin, F. Rasool, M. Maaz, M. Taj, dan A. Muhammad, "Trash Detection on Water Channels," dalam *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer Science and Business Media Deutschland GmbH, 2021, pp. 379–389. doi: 10.1007/978-3-030-92185-9_31.
- [13] M. Azizul Hakim, H. Emawati, dan D. Mujahiddin, "Pemanfaatan Pesawat Tanpa Awak Untuk Pemetaan dan Identifikasi Penutupan Lahan Pada Kawasan Hutan Pendidikan Unmul," *AGRIFOR*, vol. 20, pp. 47-58, Mar 2021, doi: 10.31293/agrifor.v20i1.4900.

- [14] I. M. G. Sunarya, I Wayan Treman, dan Putu Zasya Eka Satya Nugraha, "Classification of Rice Growth Stage on UAV Image Based on Convolutional Neural Network Method," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 12, no. 1, pp. 146–155, Mei 2023, doi: 10.23887/janapati.v12i1.60959.
- [15] Y. and P. G. and S. F. and A. H. Chen Liang-Chieh and Zhu, "Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation," dalam *Computer Vision – ECCV 2018*, M. and S. C. and W. Y. Ferrari Vittorio and Hebert, Ed., Cham: Springer International Publishing, 2018, pp. 833–851.
- [16] A. Ali, S. Acharjee, Md. M. Sk., S. Z. Alharthi, S. S. Chaudhuri, dan A. Akhunzada, "DWSD: Dense waste segmentation dataset," *Data Brief*, vol. 59, p. 111340, 2025, doi: <https://doi.org/10.1016/j.dib.2025.111340>.
- [17] D. Bashkistrova *dkk.*, "ZeroWaste Dataset: Towards Deformable Object Segmentation in Cluttered Scenes," dalam *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 21115–21125. doi: 10.1109/CVPR52688.2022.02047.
- [18] N. A. Muhadi, A. F. Abdullah, S. K. Bejo, M. R. Mahadi, dan A. Mijic, "Deep Learning Semantic Segmentation for Water Level Estimation Using Surveillance Camera," *Applied Sciences*, vol. 11, no. 20, pp. 112-121, 2021, doi: 10.3390/app11209691.
- [19] M. W. A. Kesiman, I. M. D. Maysanjaya, I. M. A. Pradnyana, I. M. G. Sunarya, dan P. H. Suputra, "Profiling Balinese Dances with Silhouette Sequence Pattern Analysis," dalam *CENIM 2020 - Proceeding: International Conference on Computer Engineering, Network, and Intelligent Multimedia 2020*, Institute of Electrical and Electronics Engineers Inc., Nov 2020, pp. 423–428. doi: 10.1109/CENIM51130.2020.9297893.
- [20] A. A. Paramartha, N. Marti, dan Y. E. Aryanto, "Comparison of classification model and annotation method for Undiksha's official documents," *J Phys Conf Ser*, vol. 1516, p. 012026, Apr 2020, doi: 10.1088/1742-6596/1516/1/012026.
- [21] N. L. P. R. Dewi, I. N. S. W. Wijaya, I. K. Purnamawan, dan N. W. Marti, "Model Classifier Judul Berita Pariwisata Indonesia Berdasarkan Sentimen," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 1, pp. 117–124, Feb 2024, doi: 10.25126/jtiik.20241117617.
- [22] P. H. Suputra, A. D. Sensusiaty, M. D. Artaria, G. J. Verkerke, E. M. Yuniarno, dan I. K. E. Purnama, "Automatic 3D Cranial Landmark Positioning based on Surface Curvature Feature using Machine Learning," *Knowledge Engineering and Data Science*, vol. 5, no. 1, pp. 27-38, Jun 2022, doi: 10.17977/um018v5i12022p27-40.
- [23] I. G. M. W. K. Widiyantara, K. Y. E. Aryanto, dan I. M. G. Sunarya, "Application of the Learning Vector Quantization Algorithm for Classification of Students with the Potential to Drop Out," *Brilliance: Research of Artificial Intelligence*, vol. 3, no. 2, pp. 262–269, Nov 2023, doi: 10.47709/brilliance.v3i2.3155.
- [24] S. Mohajerani dan P. Saeedi, "Cloud and Cloud Shadow Segmentation for Remote Sensing Imagery via Filtered Jaccard Loss Function and Parametric Augmentation," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 14, pp. 4254–4266, Apr 2021, doi: 10.1109/JSTARS.2021.3070786.
- [25] C. H. Sudre, W. Li, T. K. M. Vercauteren, S. Ourselin, dan M. J. Cardoso, "Generalised Dice overlap as a deep learning loss function for highly unbalanced segmentations," *Deep learning in medical image analysis and multimodal learning for clinical decision support: Third International Workshop, DLMIA 2017, and 7th International Workshop, ML-CDS 2017, held in conjunction with MICCAI 2017 Quebec City, QC,...*, vol. 2017, pp. 240–248, 2017, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:21957663>
- [26] P. Z. E. S. Nugraha, I. M. G. Sunarya, dan I. M. D. Maysanjaya, "Binary Semantic Segmentation of Dolphin on UAV Image Using U-Net," dalam *2023 International Seminar on Intelligent Technology and Its Applications: Leveraging Intelligent Systems to Achieve Sustainable Development Goals, ISITIA 2023 - Proceeding*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 728–733. doi: 10.1109/ISITIA59021.2023.10221152.