

ESTIMASI LUAS AREA TANAMAN TEH BERBASIS PENDEKATAN SEGMENTASI GAMBAR MENGGUNAKAN METODE DEEPLABV3+

ESTIMATION OF TEA PLANTATION AREA BASED ON IMAGE SEGMENTATION APPROACH USING DEEPLABV3+ METHOD

Firman Ade Prasetyo¹, I.G. Prasetya Dwi Wibawa², Suryo Adhi Wibowo³

^{1,2,3}Prodi S1 Teknik Elektro, Fakultas Teknik Elektro, Universitas Telkom
¹fmanadeprasetyo@student.telkomuniversity.ac.id, ²prasdwiwawa@telkomuniversity.ac.id,
³suryoadhiwibowo@telkomuniversity.ac.id

Abstrak

Saat ini Indonesia merupakan salah satu negara penghasil teh terbesar di seluruh dunia dan memiliki lahan pertanian teh sekitar 103 ribu hektar. Saat ini, Luas lahan yang dimiliki oleh para petani teh kecil lebih besar dari milik big estate, tetapi produktivitas teh yang dihasilkan lebih besar big estate daripada yang dihasilkan petani teh kecil. Hal tersebut dikarenakan para petani teh masih menghitung populasi tanaman teh secara manual sehingga membutuhkan banyak waktu dan kemungkinan terjadinya kesalahan perhitungan sehingga menyebabkan populasi teh yang tertanam di kebun teh milik petani sangat sedikit dan para petani kurang mengetahui langkah yang baik untuk memelihara kebun teh mereka sehingga mempengaruhi tingkat produktivitas teh yang dihasilkan. Dalam Tugas Akhir ini, pada parameter mIoU, didapatkan mIoU terbesar adalah 79.98% pada 300.000 step training, pada parameter akurasi didapatkan akurasi sebesar 80%, pada parameter presisi didapatkan nilai presisi terbaik 0.61% pada data uji kedua dan terbesar 6.33% pada data uji ketiga, dan pada parameter waktu, didapatkan waktu rata-rata 15.85 detik pada gambar dengan dimensi 512 G 320 dan 20.71 detik pada gambar dengan dimensi 3840 G 2160

Kata kunci: Image Processing, Semantic Segmentation, Deep Learning, DeepLabV3+, Spatial Pyramid Pooling, Encoder-Decoder Networks.

Abstract

At this time, Indonesia is one of the biggest tea producers in the world and has around 103 thousand hectares of tea plantation. Currently, the area of tea plantation owned by smallholders is greater than big estates, but the productivity owned by big estates is greater than smallholders. That is because the smallholders still calculate the tea population manually, so it requires a lot of time and the possibility of miscalculation that causes the tea at smallholders tea plantation is very small and the farmers do not know the best steps to maintain their tea plantations so that it affects the level of productivity of the tea produced. . In this final project, in the mIoU parameter, the highest mIoU is 79.98% at 300.000 step training, In the accuracy parameter, an accuracy of 80%, in the precision parameter the best precision value is obtained 0.61% in the second test data and the highest is 6.33% in the third test data, in time parameter an average time of images with 512 G 320 is 15.85 seconds and 20.71 seconds in the image with 3840 G 2160.

Keywords: Image Processing, Semantic Segmentation, Deep Learning, DeepLabV3+, Spatial Pyramid Pooling, Encoder-Decoder Networks.

1. Pendahuluan

Saat ini produktivitas teh selalu menurun setiap tahunnya [1], khususnya yang diolah oleh para petani kecil. Salah satu permasalahannya adalah karena kurang efektifnya cara merawat lahan teh berdasarkan luas area teh yang ada. Syarat populasi yang baik adalah ketika luas area tanaman teh diatas 80% maka hanya perlu merawat lahan teh tersebut, ketika diantara 60% dan 80% maka petani perlu dilakukan pengisian terhadap lahan yang kosong, dan ketika dibawah 60% maka petani perlu menanam ulang lahan teh tersebut. Dengan menjaga luas area tanaman teh, maka dapat meningkatkan produktivitas teh dan petani dapat memperkirakan panen teh kedepannya. Selain itu, perhitungan populasi yang manual oleh petani teh juga merupakan salah satu permasalahan yang ada. Dengan perhitungan manual maka membutuhkan banyak waktu dan juga sering terjadi kesalahan perhitungan yang dilakukan oleh para petani teh. Segmentasi gambar merupakan salah satu cara untuk melakukan estimasi luas area terhadap tanaman teh, oleh karena itu dibutuhkan sebuah sistem yang dapat melakukan estimasi secara cepat dan akurat. Segmentasi gambar adalah proses untuk memisahkan bagian inti gambar (foreground) dan latar belakang (background). Terdapat banyak metode yang dapat digunakan untuk melakukan segmentasi semantik segmentasi, yaitu Fully Convolutional Network (FCN), ParseNet, Convolutional and Deconvolutional Networks (DCN), Pyramid Scene Parsing Network (PSPNet), DeepLabV3+ dll. Pada hasil percobaan pada segmentation

challenge FCN mendapatkan tingkat akurasi 62.2% [2], ParseNet 69.8% [3], DCN 72.5% [4], PSPNet 85.5% [5], dan DeepLabV3+ 89% [6]. Berdasarkan hasil tingkat akurasi, DeepLabV3+ dipilih karena memiliki tingkat akurasi yang paling baik pada segmentation challenge.

Model	2012 PASCAL VOC (mIoU)	PASCAL-Context (mIoU)	2016 COCO (AP)	2016 COCO (AR)	2017 COCO (AP)	Cityscapes (mIoU)
FCN	62.2	X	X	X	X	X
ParseNet	69.8	40.4	X	X	X	X
Conv & Deconv	72.5	X	X	X	X	X
FPN	X	X	X	48.1	X	X
PSPNet	85.4	X	X	X	X	80.2
Mask R-CNN	X	X	37.1	X	41.8	X
DeepLab	79.7	46.7	X	X	X	70.4
DeepLabv3	85.9	X	X	X	X	81.3
DeepLabv3+	89.0	X	X	X	X	82.1
PANet	X	X	42.0	X	46.7	X
EnpNet	85.9	52.8	X	X	X	X

Gambar 1.1 Metode Segmentasi

DeepLabV3+ merupakan salah satu metode semantic image segmentation yang menggunakan penggabungan dua arsitektur neural network, yaitu Spatial Pyramid Pooling dan Encoder-Decoder networks. DeepLabV3+ memiliki tingkat akurasi yang lebih baik dibandingkan DeepLabV3+ tetapi memiliki arsitektur yang lebih rumit dikarenakan ditambahkannya Encoder-Decoder Networks pada arsitekturnya [6]. Penerapan metode tersebut bertujuan untuk meningkatkan kualitas keluaran sistem.

Tugas akhir ini akan membuat sebuah sistem yang dapat melakukan estimasi luas area tanaman teh menggunakan metode DeepLabV3+ untuk mendapatkan hasil yang lebih akurat, kemudian hasil yang telah didapat akan secara otomatis terunggah ke cloud dan terhubung langsung dengan aplikasi android. Lalu, Studi kasus yang diambil adalah dapat mempermudah dan mempercepat proses perhitungan luas area tanaman teh serta menerapkan konsep real-time update agar informasi dapat langsung disalurkan. Dengan ini diharapkan tugas akhir ini dapat digunakan sebagai referensi di penelitian selanjutnya. Dalam pengaplikasiannya pengguna dapat menggunakan drone untuk mengambil gambar kebun teh lalu mengirimkannya ke operator sehingga petani lapangan tidak perlu melakukan perhitungan secara manual. Rancangan untuk sistem segmentasi objek menggunakan dataset perkebunan teh yang diambil di Pusat Penelitian Teh dan Kina (PPTK) Gambung dengan ketinggian 30 meter.

2. Konsep Dasar

A. Prinsip Kerja Konsep

Tahap pertama adalah pengambilan variable input, input yang diolah berupa gambar sebuah kebun teh yang diambil dari ketinggian 30 meter menggunakan drone. Pada bagian ini, sistem akan membagi gambar menjadi dua, yaitu data yang digunakan untuk melatih sistem(data latih), gambar yang digunakan untuk memvalidasi sistem(data validasi) serta menguji sistem(data uji). Tahap kedua adalah training model. Dataset kemudian digunakan untuk melatih dan menguji sistem untuk menghasilkan model segmentasi populasi berdasarkan bentuk dan polanya menggunakan metode DeepLabV3+. Tahap ketiga adalah perhitungan luas tanaman teh. Sistem yang dianggap terlatih akan digunakan untuk melakukan estimasi luas lahan berdasarkan masukan berupa gambar dan output berupa estimasi luas tanaman teh. Tahap keempat adalah proses real-time update, dimana hasil dari proses sebelumnya akan di upload ke cloud dan terhubung oleh aplikasi berbasis android, sehingga hasil keluaran sistem dapat dilihat pada aplikasi.

B. Perhitungan Luas Area Tanaman Teh

Proses perhitungan luas tanaman teh masih dilakukan secara manual oleh petani teh, perhitungan didasarkan pada jumlah lahan kosong dan jumlah lahan yang berisi tanaman teh. Dengan proses perhitungan yang manual maka kemungkinan terjadi kesalahan kalkulasi cukup besar[1]. Oleh karena itu dibuat rumus yang dapat diimplementasikan pada sistem menggunakan

$$\% = \frac{(C+?)}{< \cdot =} \cdot 100 \quad (1)$$

C. Segmentasi Gambar

Segmentasi gambar merupakan proses untuk memisahkan sebuah gambar digital menjadi beberapa bagian. Tujuan Dari segmentasi ini adalah untuk memudahkan atau mengubah representasi sebuah image menjadi sesuatu yang lebih bermanfaat dan lebih mudah untuk dianalisis. Pada umumnya segmentasi menggunakan persamaan

$$f(G, H) = \begin{cases} 1, & 5(G, H) \leq \gamma \\ 0, & 5(G, H) \geq \gamma \end{cases} \quad (2)$$

Dimana γ adalah nilai threshold yang digunakan untuk melakukan segmentasi. Dari persamaan diatas akan menghasilkan output gambar dengan ruang warna black and white seperti pada Gambar 2.2.



Gambar 2. 2 Segmentasi

D. DeepLabV3+

DeepLabV3+ merupakan sebuah metode yang digunakan untuk melakukan semantic segmentation. Metode DeepLabV3+ merupakan metode yang dikembangkan oleh Google dan merupakan pengembangan dari DeepLabV3 yang menghasilkan tingkat akurasi yang lebih baik [6]. Metode DeepLabV3+ menggunakan asitektur Encoder-Decoder. Pada proses encoder menggunakan DeepLabV3, dimana pada DeepLabV3 menggunakan Atrous Spatial Pyramid Pooling (ASPP) untuk mengekstraksi fitur yang dikomputasi oleh Deep Convolutional Neural Networks (DCNN) dan pada bagian decoder menggunakan Xception untuk memulihkan informasi yang nantinya akan digunakan pada proses segmentasi.

E. Encoder Decoder Architecture

Encoder-decoder networks merupakan sebuah arsitektur yang telah banyak diimplementasikan pada bidang computer vision [7], diantaranya untuk estimasi gerak manusia, deteksi objek, dan *semantic segmentation*. Pada umumnya pada bagian encoder berisi suatu proses yang digunakan untuk mengurangi features map dan mendapatkan semantic information, sedangkan pada bagian decoder digunakan untuk proses mengembalikan informasi spasial.

F. Atrous Separable Convolution

Atrous Convolution merupakan sebuah cara yang dapat digunakan untuk mengontrol resolusi dari sebuah fitur yang akan dikomputasi pada deep convolutional neural networks (DCNN) dan menyesuaikan bidang filter untuk mendapatkan informasinya. *Atrous Separable Convolution* merupakan sebuah penggabungan antara *atrous convolution* dengan *pointwise convolution*. Parameter yang digunakan adalah *rate*, apabila digunakan nilai *rate* dua, maka akan terbentuk sebuah kernel dengan ukuran 5x5. Jenis konvolusi ini cocok digunakan pada segmentasi real-time karena menggunakan bidang pandang yang lebih luas tetapi dengan beban komputasi yang sama. Gambar 2.4 merupakan ilustrasi dari atrous separable convolution.

G. Atrous Spatial Pyramid Pooling (ASPP)

Atrous Spatial Pyramid Pooling merupakan penerapan beberapa *atrous convolution* yang dilakukan secara paralel dengan nilai *rate* yang berbeda-beda, tujuannya adalah untuk mengambil informasi kontekstual pada beberapa skala yang berbeda-beda. Konsep dari ASPP meniru konsep *Spatial Pyramid Pooling* (SPP) pada PSPNet, dimana pada PSPNet dilakukan operasi *pooling* pada skala *grid* yang berbeda-beda.

H. Xception

Xception (Extreme Inception) merupakan arsitektur *Deep Convolutional Neural Networks* (DCNN) yang menggunakan *Depthwise Separable Convolutions*. *Xception* merupakan arsitektur hasil pengembangan dari Inception-V3 dengan *Depthwise Separable Convolutions* yang telah dimodifikasi dengan mengubah urutan konvolusinya seperti pada gambar II-8. *Xception* memiliki tiga *flow* yaitu *Entry flow*, *Middle Flow*, dan *Exit flow* dimana masing-masing *flow* memiliki peranan yang berbeda. *Entry flow* digunakan untuk melakukan ekstraksi *feature* dan juga melakukan reduksi dimensi pada citra input, *Middle flow* digunakan untuk melakukan *enhancing* terhadap *feature map*, dan *Exit flow* untuk proses flattening serta terdapat *Fully Connected Network*. Gambar 2.6 merupakan ilustrasi dari arsitektur *Xception*.

I. Dataset

Dataset yang digunakan adalah sebuah gambar kebun teh dengan jumlah 400 gambar yang diambil menggunakan *drone* dengan ketinggian 30 meter dan di waktu pagi hari dengan cuaca cerah. Gambar kebun teh diambil dari Pusat Penelitian Teh dan Kina (PPTK) Gambung. *Dataset* yang berjumlah 2800 gambar akan dibagi dengan perbandingan 8:2 [8], sehingga didapatkan 2240 gambar untuk data latih dan 560 untuk data validasi, data latih yang telah dilabeli akan digunakan untuk melatih sistem agar dapat mengenali pola penyebaran tanaman teh, sedangkan data validasi akan memvalidasikan kecerdasan sistem yang sebelumnya telah dilatih.



Gambar 2. 3 Gambar Kebun Teh

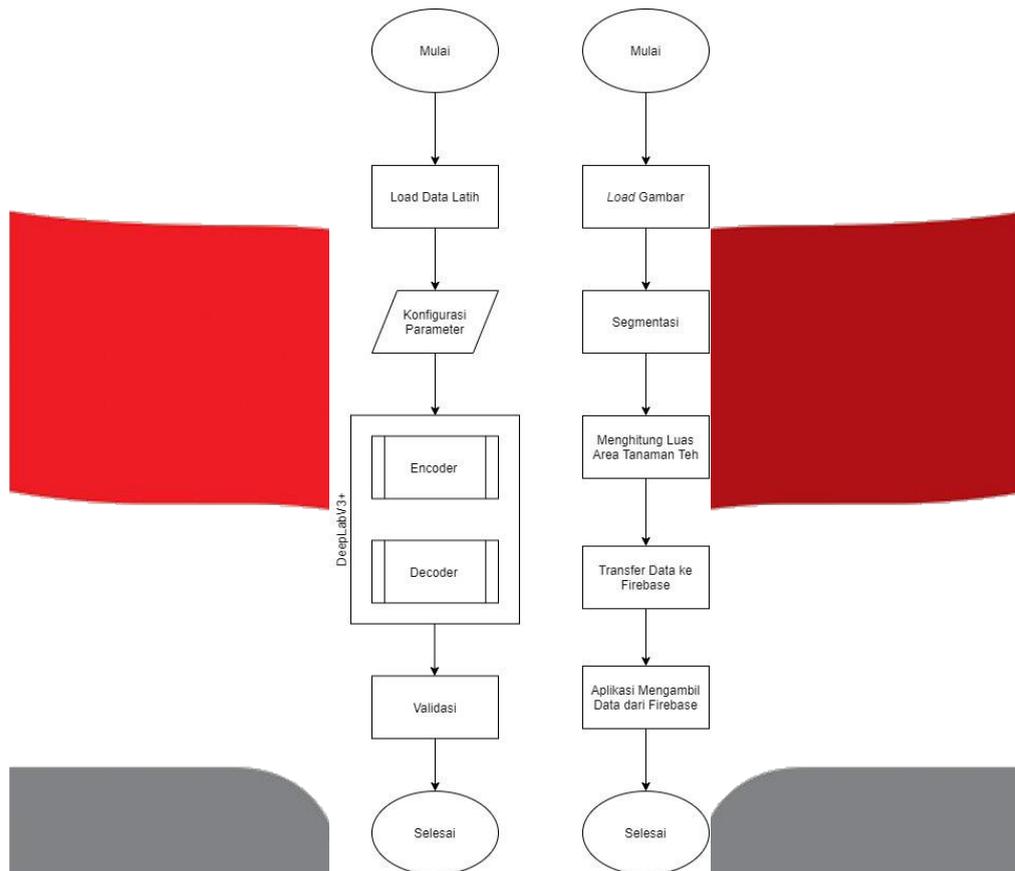
3. Model Sistem

A. Desain Sistem

Dalam tugas akhir ini dilakukan perancangan dan pengujian arsitektur dari sistem segmentasi semantik dengan data input berupa citra. Skema dari tugas akhir ini menggunakan metode DeepLabV3+ dengan *network Xception*. Secara umum tugas akhir ini memiliki skema seperti yang dijelaskan pada Gambar 3.4.

Proses pertama adalah load dataset. Load dataset merupakan proses dimana sistem mengambil dataset dari direktori. Dataset yang digunakan merupakan sebuah citra kebun teh yang diambil dari ketinggian 30 meter yang akan digunakan sebagai masukan dan juga sebagai validasi pada sistem. Dataset akan terbagi menjadi dua jenis, yaitu data latih dan data validasi. Data latih akan digunakan untuk melatih sistem dengan metode DeepLabV3+ dengan *network Xception*, sedangkan data validasi akan digunakan untuk memvalidasi kepiintaran sistem yang sebelumnya sudah dilatih.

Proses kedua adalah konfigurasi parameter, pada tugas akhir kali ini menggunakan beberapa konfigurasi yang digunakan seperti batch size, step training, decoder output stride, dan atrous rates. Pada tugas akhir ini batch size



Gambar 3. 4 Diagram Alur Sistem

yang digunakan adalah 2, step training 300K, dan karena tugas akhir ini menerapkan model xception, maka atrous rates yang digunakan adalah 6, 12, 18 dan decoder output stride yang digunakan adalah 4.

Proses ketiga adalah Encoder, pada bagian encoder, metode DeepLabV3+ menerapkan metode versi sebelumnya, yaitu DeepLabV3. Pada DeepLabV3 untuk melakukan ekstraksi fitur menggunakan atrous convolution dengan skala yang berbeda-beda agar mendapatkan multi-scale contextial information. Nilai stride yang digunakan pada proses konvolusi adalah 16 atau 8 agar mendapatkan nilai ekstraksi yang lebih detail dan dengan nilai rate 2 dan 4.

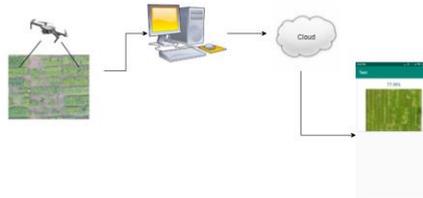
Proses keempat adalah Decoder, proses decoder yang diterakan merupakan decoder sederhana namun efektif. Fitur dari encoder terlebih dahulu dilakukan proses upsample dengan faktor 4 dan kemudian digabungkan dengan low-level features dari network backbone yang memiliki resolusi spasial yang sama. Pada low-level features dilakukan proses konvolusi 1x1 untuk mengurangi banyaknya nilai piksel (256 atau 512). Setelah proses penggabungan, dilakukan proses konvolusi dengan matriks 3x3 untuk memperbaiki fitur.

Proses kelima adalah segmentasi, segmentasi bekerja untuk mempermudah proses kalkulasi area tanaman. Dengan model yang telah dilatih, gambar yang di input akan terbagi menjadi dua kelas, yaitu class teh dan class background. Setelah proses segmentasi dilakukan, sistem kan melakukan kalkulasi area tanaman teh terhadap gambar hasil proses segmentasi tersebut.

Proses keenam adalah Realtime update, Proses real-time update pada sistem yang akan dirancang merupakan sebuah proses dimana hasil dari keluaran sistem berupa gambar, aksi dan juga estimasi luas tanaman teh akan secara otomatis dikirim ke aplikasi yang telah dirancang. Cloud server yang digunakan merupakan Firebase, Firebase digunakan untuk menampung data sementara yang dikirim dari komputer. Setelah data hasil keluaran telah ditampung, maka akan diintegrasikan dengan aplikasi yang dirancang menggunakan Android Studio dengan menggunakan key dan link yang terdapat pada Firebase.

B. Perancangan Perangkat

Pembuatan tugas akhir ini, digunakan beberapa perangkat yaitu *drone* dan komputer / laptop. *Drone* berfungsi untuk pengambilan citra input yang nantinya akan diproses oleh sistem. Komputer / laptop digunakan untuk merancang sistem secara keseluruhan, khususnya *training* data dan keluarannya ditampilkan melalui aplikasi android. Alur dari perancangan perangkat dapat dilihat pada Gambar 3.9. Drone:(a) Camera 4K Resolution.



Gambar 3.5 Perancangan Perangkat

Komputer:(a) Processor: Core i7 7700U @3.60 – 4.20GHz, (b) RAM: 16GB DDR4, (c) SSD: 250GB + 128GB SSD, (d) GPU: GTX 1060 6GB. Smartphone:(a) OS: v6.0(Marshmallow), (b) Chipset: Qualcomm MSM6996 Snapdragon 820, (c) CPU: Dual-core 1.8Ghz Kryo.

4. Pengujian dan Analisa

A. Analisis mIoU



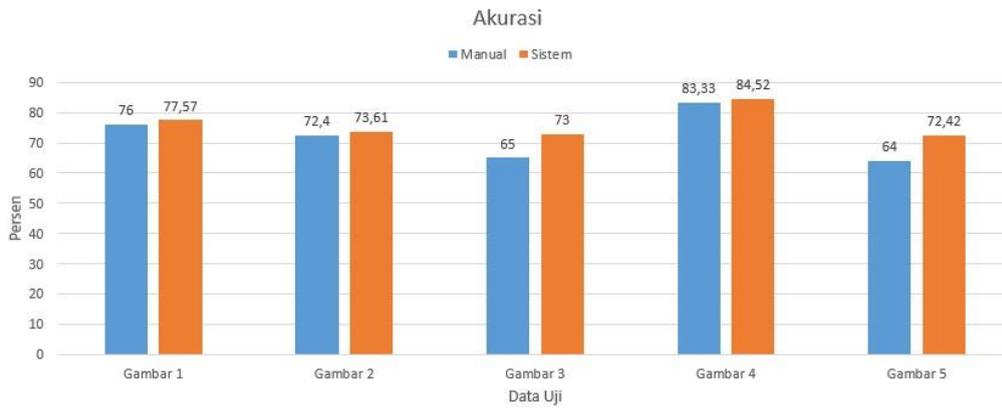
Gambar 4.6 Perbandingan performansi mIoU pada *step training*

Gambar 4.6 merupakan grafik mIoU setiap 20.000 step training. MiOu merupakan nilai rata-rata dari perbandingan antara piksel overlap dan piksel total pada ground truth dan gambar hasil prediksi. Model yang memiliki mIoU diatas 75% memiliki hasil prediksi yang sudah merepresentasikan sebuah objek yang di prediksi, semakin tinggi nilai mIoU yang dihasilkan oleh sebuah model, maka hasil dari model tersebut akan semakin mendekati ground truth-nya.

Pada grafik diatas, didapatkan nilai mIoU sebesar 79.98% pada 300.000 step training dengan dilakukan analisis mIoU setiap 20.000 step training. Berdasarkan grafik, pada step 20.000 sampai 160.000 step didapatkan nilai rata-rata kenaikan mIoU sebesar 0.77%, sedangkan pada step 160.000 menuju step 300.000 terjadi perlambatan, sehingga hanya memiliki rata-rata kenaikan mIoU sebesar 0.55%. Perlambatan tersebut dipengaruhi oleh semakin sedikit-nya nilai weight yang diperbarui karena semakin mendekati model optimum yang dapat dihasilkan oleh proses training. Selain itu, rata-rata kenaikan mIoU keseluruhan dari sistem tergolong tinggi, yaitu 0.66% setiap 20.000 step. Hal tersebut dikarenakan karena sistem hanya memiliki dua class, yaitu class background dan class teh, sehingga pada perhitungan mIoU, sistem hanya menghitung rata-rata Intersection over Union(IoU) dari dua class, dan juga sebaliknya, semakin banyak class yang dimiliki maka semakin lama waktu yang diperlukan untuk proses training.

B. Analisis Akurasi

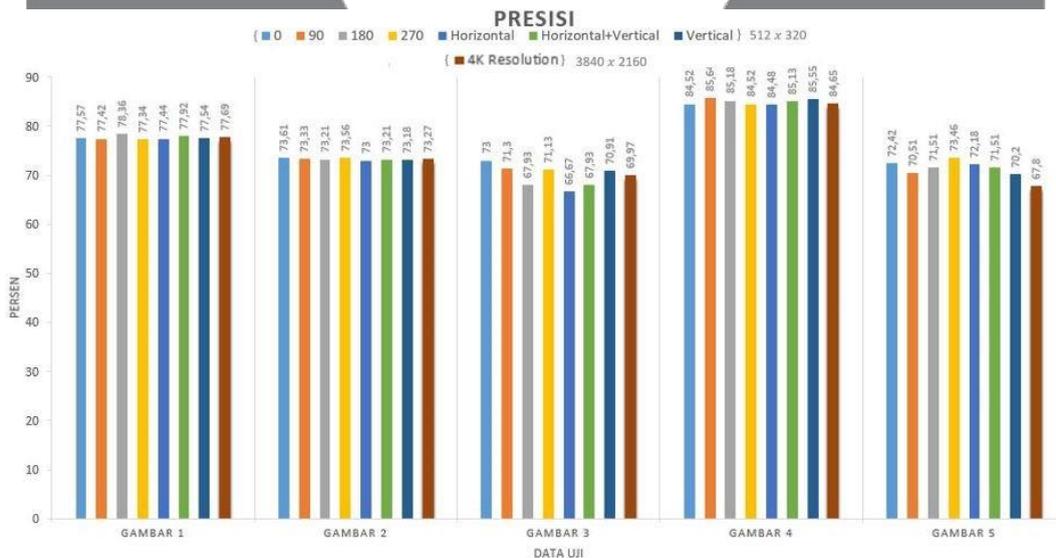
Gambar 4.7 merupakan grafik hasil analisis Pengujian Akurasi. Analisis akurasi digunakan untuk mengukur kebenaran hasil perhitungan luas area tanaman teh. Pada hasil analisis akurasi yang diuji menggunakan lima gambar, didapatkan empat gambar memiliki error di bawah atau sama dengan 8% dan satu gambar memiliki error di atas 8%. Berdasarkan hasil tersebut, didapatkan hasil akurasi pada sistem sebesar 80% dengan *error* terendah sebesar 1.19% pada data uji keempat dan error terbesar sebesar 8.42% pada data uji kelima.



Gambar 4. 7 Perbandingan performansi akurasi pada sampel data uji

C. Analisis Presisi

Pada hasil analisis performansi presisi, didapatkan presisi terendah sebesar 0.61% pada data uji kedua dan presisi tertinggi sebesar 6.33% pada data uji ketiga. Secara keseluruhan, semua data uji memiliki presisi yang baik karena kelima data uji memiliki presisi di bawah 8%, walaupun terdapat beberapa data uji yang memiliki nilai presisi yang cukup tinggi, yaitu data uji ketiga dan data uji kelima. Hal ini menunjukkan bahwa sistem dapat memprediksi populasi tanaman teh tanpa terpengaruh posisi pengambilan gambar. Hasil analisis dapat dilihat pada Gambar 4.8.



Gambar 4. 8 Perbandingan performansi presisi pada sampel data uji

D. Analisis Waktu Running

Pada hasil analisis performansi waktu running menggunakan lima data uji yang berbeda. Waktu running yang dianalisis mencakup waktu yang diperlukan keseluruhan sistem untuk berjalan, mulai dari proses segmentasi gambar kebun teh hingga proses load data yang dilakukan pada aplikasi yang telah dirancang menggunakan konsep asynchronous dan sudah ter-install pada smartphone. Dari hasil analisis, resolusi gambar 4K memiliki waktu yang lebih lama dari semua data uji dengan dimensi 512 G 320 yang telah di augmentasi dengan skema pemutaran 0, 90, 180, dan 270, serta dengan flip vertikal, horizontal, dan vertikal ditambah horizontal. Hal tersebut dipengaruhi oleh semakin tinggi dimensi maka semakin tinggi waktu yang diperlukan, hal ini dikarenakan beban komputasi yang lebih tinggi dan juga ukuran gambar yang semakin besar, hal tersebut mengakibatkan waktu upload yang semakin lama dan membutuhkan data internet yang lebih banyak. Hasil analisis dapat dilihat pada Gambar 4.9.



Gambar 4. 9 Perbandingan performansi waktu pada sampel data uji

5. Kesimpulan

Dalam perancangan sistem segmentasi untuk kalkulasi luas tanaman teh menggunakan metode DeepLabV3+ penulis melakukan percobaan terhadap empat parameter performansi, yaitu step training, akurasi, presisi dan waktu running.

Pada Parameter pertama, yaitu step training menghasilkan nilai 79.98% pada step training 300.000. Pada grafik mIoU, nilai mIoU selalu meningkat setiap 20.000 step training.

Pada Parameter kedua, yaitu akurasi mendapatkan nilai 80% yang diuji dengan lima data uji dengan hasil 4 gambar memiliki error dibawah 8% dan satu gambar diatas 8%. Akurasi pada sistem sangat dipengaruhi oleh kondisi gambar data uji, seperti pencahayaan, dimensi atau resolusi, kondisi tanaman dan tanah, hingga posisi pengambilan gambar. Selain itu, karena sistem yang dirancang merupakan *supervised learning*, maka dengan menambah data latih dapat meningkatkan akurasi sistem.

Pada Parameter ketiga, yaitu presisi. Pengujian presisi menggunakan skema empat derajat pemutaran gambar, yaitu 90°, 180°, dan 270° serta flip secara vertikal, horizontal, dan vertikal ditambah horizontal. Hasil analisis presisi terbaik didapat pada data uji kedua dengan hasil pada pemutaran 0° sebesar 73.61%, 90° sebesar 73.33%, 180° sebesar 73.21% dan 270° sebesar 73.56%, flip vertikal sebesar 70.91%, horizontal 73%, dan horizontal ditambah vertikal sebesar 73.21%. Sedangkan nilai presisi terburuk didapat pada data uji ketiga dengan hasil pemutaran 0° sebesar 73%, 90° sebesar 71.3%, 180° sebesar 67.93%, dan 270° sebesar 71.13%, flip vertikal sebesar 66.67%, horizontal 67.93%, dan horizontal ditambah vertikal sebesar 70.91%. Berdasarkan hasil yang didapat, kelima data tergolong memiliki presisi yang baik. Pada pengujian presisi dengan skema dimensi disimpulkan bahwa tidak ada dimensi yang ideal pada sistem yang dirancang karena pada setiap data uji memiliki dimensi terbaik yang berbeda-beda. Tetapi berdasarkan grafik, semua dimensi memiliki presisi yang baik.

Parameter Keempat, yaitu waktu running pada gambar yang memiliki dimensi 512 G 320 menghasilkan waktu rata-rata sebesar 15.85 detik, sedangkan waktu yang diperlukan untuk data dengan dimensi 3840 G 2160 atau 4K menghasilkan waktu rata-rata 20.71 detik. Berdasarkan waktu yang diperoleh, semakin tinggi dimensi gambar yang dioleh maka waktu yang diperlukan akan semakin lama, hal tersebut dikarenakan beban komputasi yang digunakan semakin besar dan ukuran gambar juga semakin besar, hal ini mempengaruhi kecepatan pada upload.

Pustaka

- [1] Direktorat Jenderal Perkebunan, "Statistik perkebunan indonesia," Jakarta, 2016.
- [2] J. Long, E. Shelhamer, and T. Darrel, "Fully convolutional networks for semantic segmentation," *Berkeley*, 2015.
- [3] W. Liu, A. Rabinovich, and A. C. Berg, "Parsenet: Looking wider to see better," *arXiv*, 2015.
- [4] H. Noh, S. Hong, and B. Han, "Learning deconvolution network for semantic segmentation," *arXiv*, 2015.
- [5] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, "Pyramid scene parsing network," *arXiv*, 2017.

- [6] L. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation," 2018.
- [7] H. Chul Ye and W. Kyoung Sung, "Understanding geometry of encoder-decoder cnns," *International Conference on Machine Learning*, 2019.
- [8] N. El Gayar, *Multiple Classifier Systems*. Cairo: 9th International Workshop, 2010.

