

# EKSTRAKSI JALAN MENGGUNAKAN DEEP LEARNING DENGAN MODEL DEEPLABV3+

Bevan Pramudya W<sup>1</sup>  
Fakultas Teknik Elektro  
Teknik Telekomunikasi  
Bandung, Indonesia

bevanpramudya@student.telkomuniversity.ac.id

Dr. Sofia Naning H, S.T., M. T.<sup>2</sup>  
Fakultas Teknik Elektro  
Teknik Telekomunikasi  
Bandung, Indonesia

sofiananing@telkomuniversity.ac.id

Sussi, S.Si., M.T.<sup>3</sup>  
Fakultas Teknik Elektro  
Teknik Telekomunikasi  
Bandung, Indonesia

sussiss@telkomuniversity.ac.id

**Abstrak** — Penginderaan jarak jauh didefinisikan sebagai ilmu dalam mengumpulkan informasi suatu objek tanpa menyentuh atau berkontak fisik langsung dengan objek tersebut, ekstraksi jalan yang akurat memiliki banyak manfaat dalam aplikasi nyata seperti navigasi, pemantauan lalu lintas, dan perencanaan perkotaan, akan tetapi ekstraksi jalan dari citra penginderaan jarak jauh merupakan tugas yang kompleks dikarenakan fitur-fitur jalan yang kompleks dan interaksi mereka dengan lingkungan sekitarnya, menggunakan metode manual sudah dianggap tidak lagi efisien dari segi waktu dan sumber daya manusia. Metode OBIA dan *Deep Learning* adalah solusi yang menjanjikan melihat penelitian yang sudah dilakukan, pada metode OBIA bersifat semi-otomatis dan *deep learning* bersifat otomatis, pada implementasinya metode *deep learning* akan menggunakan model DeepLabV3+ dengan *encoder ResNet50*, lalu pada pembuatan dataset akan digunakan implementasi OBIA untuk proses anotasi dataset. Hasil pengujian dari model DeepLabV3+ yang dirancang memberikan hasil yang memuaskan menggunakan citra ortofoto pengujian sebanyak 376 sampel untuk model yang dilatih menggunakan anotasi manual dan 100 sampel untuk model yang dilatih menggunakan dataset OBIA, pada model yang dilatih menggunakan dataset anotasi OBIA mendapatkan skor mIoU 75.31% pada *epoch* 40, dan dengan model yang dilatih menggunakan dataset anotasi manual mendapat skor mIoU 92.88% pada *epoch* 40.

**Kata kunci**— Ekstraksi jalan, *Deep Learning*, DeepLabV3+, OBIA.

## I. PENDAHULUAN

Penginderaan jarak jauh didefinisikan sebagai ilmu dalam mengumpulkan informasi suatu objek tanpa menyentuh atau berkontak fisik langsung dengan objek tersebut. Secara umum, penginderaan jauh berkaitan dengan

pengolahan citra dalam mengetahui atau mengamati suatu

fenomena di muka bumi. Pemetaan jalan yang akurat memiliki banyak manfaat dalam aplikasi seperti navigasi, pemantauan lalu lintas, dan perencanaan perkotaan. Namun, ekstraksi jalan dari citra penginderaan jarak jauh merupakan tugas yang kompleks dikarenakan fitur-fitur jalan yang kompleks dan interaksi mereka dengan lingkungan sekitarnya[1]. Menggunakan teknik manual atau ekstraksi jalan secara manual untuk mengumpulkan citra geografis sudah dianggap tidak lagi efisien dilakukan dikarenakan disamping memerlukan banyaknya sumber daya manusia, teknik manual akan sangat banyak menghabiskan waktu serta biaya, apalagi apabila daerah yang dicakup luas tentu akan sangat sukar untuk melakukan ekstraksi jalan, namun tidak dapat dipungkiri perkembangan teknologi akan sensor dan platform perihal geografis membuat citra ortofoto mudah didapatkan menggunakan foto udara atau biasa disebut penginderaan jauh, akan tetapi citra ortofoto yang didapat masih mentah dan sangat dibutuhkan sebuah teknik pengolahan yang tepat sehingga mendapat hasil citra ortofoto yang akurat. Dalam beberapa tahun terakhir sudah dilakukan beberapa penelitian untuk melakukan ekstraksi jalan menggunakan *deep learning*, sejauh ini berdasarkan penelitian yang sudah dilakukan sebelumnya, metode *deep learning* terbagi menjadi 3 kategori, yaitu metode berbasis Fully Connection Network (FCN)[2], metode berbasis U-Net[3] dan metode berbasis DeepLab[4], berdasarkan metode FCN[5], Pada hasil percobaan dalam Road Extraction Challenge menggunakan dataset DeepGlobe[6], model s-FCN-loc[5] berhasil mendapatkan tingkat akurasi di angka 52%, lalu dengan metode U-Net menggunakan model HsgNet[7] mendapatkan tingkat akurasi pada angka 71% dan yang terakhir pada metode DeepLab menggunakan model DeepLabV3+[8] mendapatkan tingkat akurasi akurasi 73%. Dengan melihat penelitian yang telah dilakukan metode DeepLab dengan model DeepLabV3+ memiliki performa yang paling tinggi diantara model lainnya, untuk tugas ekstraksi jalan dari citra ortofoto, oleh karena itu penulis mengusulkan pendekatan menggunakan metode *deep learning* dengan model DeepLabV3+ dengan Encoder ResNet50, dengan judul Capstone Design “Ekstraksi Jalan Menggunakan Deep Learning dengan Model DeepLabV3+”, yang dimana Capstone Design ini akan membuat sebuah sistem untuk melakukan ekstraksi jalan dari citra ortofoto, dengan menggunakan dataset citra ortofoto daerah Jatininggor dan Sumedang yang didapatkan dari Laboratorium Modis Geodesi ITB.

## II. TINJAUAN KONSEPTUAL

### ➤ Ekstraksi Jalan

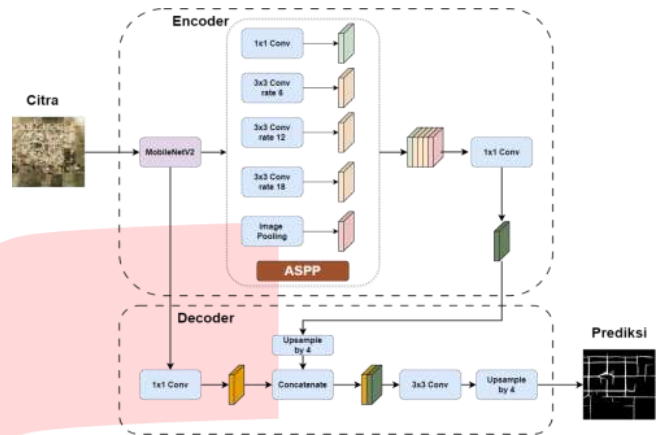
Kesulitan ekstraksi jalan dari citra satelit terletak pada karakteristik citra fitur jalan yang dapat dipengaruhi oleh tipe sensor, resolusi spektral dan spasial, cuaca, variasi cahaya, dan karakteristik tanah, dsb. Dalam praktiknya, jaringan jalan terlalu kompleks untuk dimodelkan dengan menggunakan model struktural umum. Oleh karena itu, analisis fitur jalan dan model jalan sangat penting. Secara umum, kita harus melakukan peningkatan citra untuk mengekstrak informasi yang berguna dari citra satelit. Jalan dalam citra satelit tampak sebagai fitur geometris yang memanjang dengan nilai keabuan yang berubah secara perlahan[9].

Teknologi tentang ekstraksi jalan dari citra digital masih berada dalam tahap awal, dan banyak yang belum sempurna. Hingga saat ini, sistem yang mampu sepenuhnya otomatis mengekstrak informasi jalan yang berbeda belum dibuat. Sebagian besar dari teknologi yang ada membutuhkan bantuan manusia untuk mengekstrak jalan. Karena keragaman jalan dan banyaknya gangguan jalan, penelitian ini menjadi salah satu topik yang paling sulit dan topik terpanas dalam domain pemrosesan gambar[10]. Metode ekstraksi jalan dengan pendekatan semi-otomatis yang sering digunakan yaitu dengan metode Object-Based Image Analysis (OBIA) untuk melakukan anotasi pada setiap objek spasial pada citra ortofoto yang digunakan lalu dengan bantuan perangkat lunak eCognition untuk melakukan segmentasi dan klasifikasi pada citra satelit yang telah didapat. Object-Based Image Analysis (OBIA) sendiri merupakan pendekatan yang proses klasifikasinya tidak hanya mempertimbangkan aspek spektral namun juga aspek spasial objek[11]. Metode Object-Based Image Analysis (OBIA) tidak hanya bergantung pada nilai spektral saja tapi juga mampu mengoptimasi fitur spasial dalam citra satelit sesuai dengan unsur interpretasi seperti bentuk, ukuran tekstur dan informasi kontekstual lainnya. Langkah pemrosesan klasifikasi berbasis objek terdiri dari 3 tahap yaitu segmentasi, klasifikasi dan validasi[12].

## III. METODE

- DeepLabV3+
- Flowchart Deep Learning

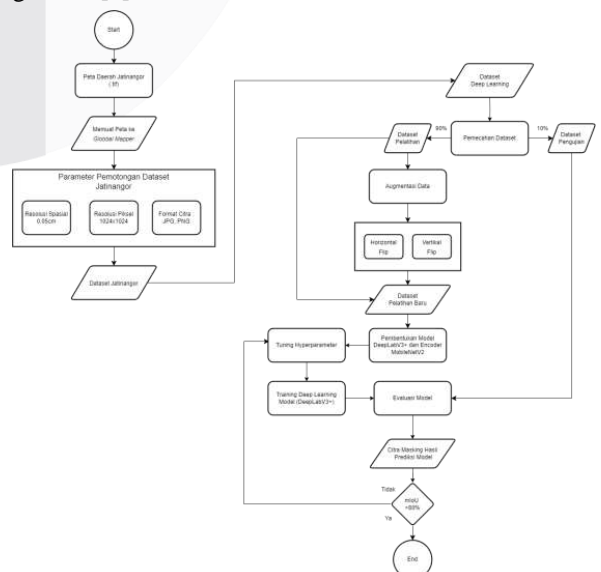
Metode ekstraksi jalan yang bisa digunakan juga adalah dengan menggunakan pendekatan deep learning, tidak seperti pendekatan semi otomatis. Metode deep learning menggunakan sebuah kecerdasan buatan dalam hal ini deep learning untuk melakukan klasifikasi dan segmentasi pada citra satelit, pada ekstraksi jalan metode otomatis berfokus pada penggunaan deep learning dengan menggunakan model DeepLabV3+.



Gambar 1. Arsitektur DeepLabV3+

Dibandingkan dengan model lain, DeepLabV3+ dinilai bisa melakukan ekstraksi fitur dengan lebih baik, ini dikarenakan model ini menambahkan modul Atrous Spatial Pyramid Pooling (ASPP) kedalam blok encoder [13] dengan menggunakan atrous convolution dengan tingkat atrous rate yang berbeda-beda, ini memungkinkan untuk mengeskrak informasi fitur

tanpa mengurangi resolusinya dan menangkap informasi kontekstual dalam skala yang berbeda, yang dimana akan menghasilkan ekstraksi fitur dengan lebih baik dibandingkan dengan model DeepLabV3 sebelumnya, modul encoder pada DeepLabV3+ akan digunakan untuk mengekstrak fitur tingkat tinggi seperti pengenalan objek, klasifikasi citra, dll sedangkan pada modul decoder akan digunakan untuk mengekstrak fitur tingkat rendah seperti warna, tekstur, garis dll[8].



Gambar 2. Flowchart Deep Learning

Fitur utama pada model ini adalah bisa melakukan prediksi atau segmentasi pada citra ortofoto dengan tingkat akurasi yang tinggi, lalu mendapatkan citra ekstraksi jalan, yang dimana citra tersebut akan bersifat biner dengan fitur atau objek yang tersegmentasi sebagai jalan akan berwarna putih dan bukan jalan berwarna hitam. Pada dasarnya karna model ini dilatih dan dibentuk menggunakan sebuah program, model ini memungkinkan untuk melakukan prediksi atau segmentasi pada banyak citra sekaligus, serta dengan adanya matrik evaluasi, seperti *Intersection over Union (IoU)* memungkinkan untuk mengevaluasi hasil akurasi dengan tepat guna pengembangan lebih lanjut.

## I. HASIL DAN PEMBAHASAN

### A. Dataset OBIA

Upaya percobaan dilakukan dengan memanfaatkan dataset Area Jatinangor, di mana data ini telah diannotasi oleh operator dan dijadikan sebagai data eksperimen dalam penelitian ini. Dataset yang digunakan terdiri dari 3755 citra untuk pelatihan, 396 citra untuk validasi, dan 4 citra untuk pengujian. Citra-citra dalam dataset ini memiliki dua saluran, yaitu citra grayscale warna, dan memiliki dimensi piksel sebesar  $1024 \times 1024$ . Untuk meningkatkan performa dan kemampuan model dalam menggeneralisasi selama proses pelatihan, serta untuk mencegah model mengalami overfitting atau underfitting, dilakukanlah proses pembalikan acak secara horizontal dan vertikal pada data pelatihan. Hal ini bertujuan untuk memberikan variasi yang lebih kaya kepada model dalam proses pelatihan.

### B. Implementasi

Pelatihan dan evaluasi model akan dilakukan menggunakan perangkat keras yang disediakan oleh platform Google Colab, dengan pemanfaatan GPU T4. Informasi terkait parameter pelatihan model dapat ditemukan dalam **TABEL 1**. Proses pelatihan model akan dijalankan dalam lima iterasi, dengan variasi nilai Epoch mulai dari 5 hingga 40. Hasil dari proses ini akan dievaluasi melalui analisis yang dilakukan.

**TABEL 1.** Pengaturan *Hyperparameter*

Nama parameter	Nilai Parameter
Epoch	5 – 40
Batch Size	4
Learning Rate	0.00008
Optimazer	Adam

### C. Ukuran

Pada eksperimen ini, IoU (*Intersection over Union*) digunakan sebagai ukuran untuk mengevaluasi akurasi hasil segmentasi dari model. Metrik ini beroperasi dengan mengukur kesamaan antara hasil segmentasi (mask prediksi) dan hasil segmentasi sebenarnya (ground truth). Rumus IoU dapat ditemukan dalam Persamaan (1).

(1)

Apabila  $i$  merupakan suatu label atau kategori pada citra, maka  $A$  mengacu pada gambar dengan

segmentasi, sementara  $B$  merujuk kepada citra yang telah diprediksi oleh model.

Di samping Indeks Kesamaan (IoU), kami memanfaatkan Indeks Kesamaan atas Gabungan Rata-rata (mIoU) sebagai metrik untuk mengukur nilai rata-rata IoU pada setiap perbandingan antara area tumpang tindih dan area yang digabungkan. Cara perhitungan mIoU tertera dalam **Persamaan (2)**.

$$IoU_i = \frac{(A \cap B)}{(A \cup B)}$$

(1)

$$mIoU = \frac{\sum_{i=1}^n IoU_i}{n}$$

(2)

Di mana " $i$ " mewakili jumlah label atau kelas dalam gambar, sementara " $n$ " mengacu pada jumlah set data gambar yang sah.

Selain dari penggunaan IoU dan mIoU, penerapan Dice Loss sebagai metode kerugian digunakan untuk mengukur perbedaan antara hasil prediksi model dengan ground truth pada level piksel. Fungsi kerugian Dice Loss bisa berperan sebagai metrik yang digunakan untuk menghitung kesalahan prediksi model selama proses pelatihan model segmentasi. Selama pelatihan, model berupaya untuk mengoptimalkan fungsi kerugian Dice Loss agar mendekati nilai nol, sehingga dapat meningkatkan kesesuaian antara prediksi dan label sebenarnya. Detail persamaan untuk Dice Loss dapat ditemukan dalam **Persamaan (3)**.

$$Dice\ Loss = 1 - Dice$$

(3)

### D. Output dan Evaluasi

Model yang diinisiasi dengan sampel yang berasal dari wilayah Jatinangor, dengan ukuran piksel  $1024 \times 1024$ .

**TABEL 2.** mIoU Score untuk model DeepLabV3+

Nilai Parameter	mIoU
Epoch 5	0.422
Epoch 10	0.384
Epoch 15	0.492
Epoch 40	0.428
-	-


Pada **TABEL 2**, model dapat memprediksi jalan dan bukan jalan. Hanya saja tingkat keakuratannya kurang baik, pada epoch 10 didapatkan mIoU (0.422) epoch 20 (0.384), epoch 30 (0.492), epoch 40 (0.428),

dan epoch 50 (0.465). Untuk nilai mIoU terbaik pada eksperimen dengan model PSPNet, terdapat pada epoch 30, dengan nilai 0.492.

**TABEL 3.** Valid Dice Loss model DeepLabv3+

Nilai Parameter	Dice Loss
Epoch 5	0.424
Epoch 10	0.465
Epoch 15	0.362
Epoch 40	0.428
-	-

Pada **TABEL3**, Tingkat kerugian yang di dapat pada epoch 5 (0.424), epoch 10 (0.465), epoch 15 (0.362), dan epoch 40 (0.428). Maka, dari hasil *Dice Loss* tersebut, didapat tingkat kerugian terkecil pada epoch 30, dengan nilai 0.362.



**Gambar 3.** Hasil Prediksi Model DeepLabV3+

Pada **Gambar 3**. Model dapat memprediksi objek jalan dan bukan jalan. Akan tetapi hasil dari prediksinya masih kurang akurat. Hal ini terjadi karena model PSPNet mengalami Overfitting pada saat proses training.

## II. KESIMPULAN

Penginderaan jauh dengan citra beresolusi tinggi telah menjadi topik menarik dalam beberapa tahun terakhir. Salah satu bidang dalam penginderaan jauh adalah ekstraksi jalan, yang bertujuan untuk memisahkan dan mengidentifikasi objek jalan dalam citra penginderaan jauh untuk analisis lebih lanjut. Metode ekstraksi jalan telah mengalami perkembangan dari metode manual hingga metode otomatis dengan menggunakan deep learning, khususnya model PSPNet. PSPNet adalah model jaringan saraf konvolusi yang dirancang untuk segmentasi gambar pada tingkat piksel. Model ini menggunakan piramida konvolusi untuk menangkap informasi kontekstual dari berbagai skala, yang telah

terbukti berhasil dalam berbagai tugas segmentasi citra. Dalam percobaan menggunakan PSPNet untuk ekstraksi jalan pada dataset Area Jatinangor, ditemukan bahwa model memiliki performa yang kurang akurat pada awalnya, tetapi setelah beberapa epoch, performa meningkat dan mencapai tingkat akurasi terbaik pada epoch 30 dengan mIoU sebesar 0.492 dan Dice Loss sebesar 0.362. Namun, terdapat tantangan dalam pelatihan model, seperti overfitting yang dapat mempengaruhi akurasi prediksi. Oleh karena itu, penelitian lebih lanjut dan pengoptimalan parameter model dapat meningkatkan performa ekstraksi jalan menggunakan model PSPNet dalam penginderaan jauh.

## REFERENSI

- [1] Abolfazl Abdollahi, dan Biswajeet Pradhan, "Integrated Technique of Segmentation and Classification Methods with Connected Components Analysis for Road Extraction from Orthophoto Images," *Expert Systems with Applications*, vol. 176, August 2021.
- [2] Hamid Reza R.B, Abolfazl Abdollahi, Hani Rezaeian, "Semi Automatic Road Extraction from Digital Images," *The Egyptian Journal of Remote Sensing and Space Sciences*, Vol.20, Juni 2017, pp. 117-123.
- [3] Abolfazl Abdollahi, Biswajeet Pradhan, Nagesh Shukla, Subrata Chakraborty and Abdullah Alamri, "Deep Learning Approaches Applied to Remote Sensing Datasets for Road Extraction: A State-Of-The-Art Review," *Remote Sensing*, vol. 12, May 2020.
- [4] Zhaoli Hong, Dongping Ming, Keqi Zhou, Ya Guo, dan Tingting Lu, "Road Extraction from a High Spatial Resolution Remote Sensing Image Based on Richer Convolutional Features," *IEEE Access*, Vol.6, 26 Agustus 2018.
- [5] Chen, L., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2017). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *IEEE transactions on pattern analysis and machine intelligence*, 40(4), 834-848.
- [6] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, "Pyramid Scene Parsing Network," Dec. 2016, [Online]. Available: <http://arxiv.org/abs/1612.01105>
- [7] A. G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," Apr. 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>
- [8] L. Wang, C. Wang, Z. Sun, and S. Chen, "An improved dice loss for pneumothorax segmentation by mining the information of negative areas," *IEEE Access*, vol. 8, pp. 167939-167949, 2020, doi: 10.1109/ACCESS.2020.3020475.