

PEMBUATAN UNSUR JALAN SECARA OTOMATIS DENGAN KECERDASAN BUATAN METODE MULTI TASK ROAD EXTRACTOR

Bagus Hafid Maulana, Ir. Levana Apriani S.T, M.T.²,
Prima Rizky Mirelva S.T., M.T., Ph.D.³

¹Mahasiswa Teknik Geodesi Universitas Winaya Mukti, Bandung

²Dosen pembimbing 1 Teknik Geodesi Universitas Winaya Mukti, Bandung

³Dosen pembimbing 2 Teknik Geodesi Universitas Winaya Mukti, Bandung

ABSTRACT

Base maps are one of the important components in carrying out a design, study, and decision-making related to a certain area. Indonesia, as an archipelagic country with a large land area, needs breakthroughs in accelerating the creation of base maps. One of the technologies related to acceleration is the use of machine-assisted map element production, also known as geospatial-based artificial intelligence, utilizing high-resolution satellite imagery as supporting data. However, further research is needed regarding the results and quality of this automated map element production.

The purpose of this research is to automatically create road features, using Pleiades satellite imagery with a resolution of 50 cm that has road network as reference data, and using artificial intelligence methods with the Multi-task road extractor algorithm.

The final result of modeling accuracy test in this research produced a score of 0,96 (mIOU) with the modeling taking approximately 30 hours using a batch size of 16. Subsequently, the final data was refined using dissolve and smoothing methods to ensure that road segments merged and their shapes were improved. Overall, the automated results were almost identical to reference data, however, there were still errors such as dead-end roads, overly wide roads, and misdetection of objects.

Keywords : *Artificial Intelligence, Automatic Road Extraction.*

ABSTRAK

Indonesia merupakan negara kepulauan yang memiliki wilayah yang luas sehingga akan memunculkan tantangan tersendiri dalam pembuatan peta dasar. Pentingnya memiliki peta dasar adalah untuk perencanaan wilayah yang komprehensif, maka dari itu perlunya penyediaan peta secara cepat guna menunjang pembangunan dan juga pengelolaan wilayah yang merata dan efisien. Penggunaan metode otomatis dengan pembelajaran mesin atau *deep learning* adalah salah satu pilihan yang dapat dipilih sehingga pembuatan peta dasar dapat dilakukan lebih cepat. Namun perlunya evaluasi terhadap data yang dihasilkan dari metode otomatis ini.

Deep learning merupakan salah satu metode pembelajaran mesin atau *artificial intelligence*. Yang memungkinkan pembuatan objek secara otomatis dengan memanfaatkan pola pengenalan dari data yang sudah ada. Dalam penelitian ini dilakukan pembuatan unsur jalan otomatis menggunakan metode *Multi task road extractor*. Dan menggunakan citra satelit resolusi tinggi sebagai acuan visual nya.

Hasil uji akurasi dalam penelitian ini menghasilkan skor 0,96 (mIOU) serta lamanya pemodelan memakan waktu ± 30 jam dengan *batch size* 16. Selanjutnya dilakukan penghalusan pada data hasil dengan metode *dissolve* dan *smoothing* agar segmen jalan bergabung dan bentuk nya lebih baik. Secara keseluruhan hasil otomatis nyaris sama dengan hasil data referensi nya, tetapi masih banyak kesalahan seperti jalan buntu, lebar jalan terlalu besar dan salah deteksi objek.

Kata Kunci : *Artificial Intelligence*, Ekstraksi Jalan Otomatis.

PENDAHULUAN

Latar Belakang

Indonesia merupakan negara kepulauan yang memiliki daratan yang luas, membutuhkan penyediaan peta yang akurat dan juga cepat sebagai strategi untuk mendukung perencanaan tata ruang yang efisien guna menunjang pembangunan yang berkelanjutan serta pengelolaan wilayah yang adil dan merata.

Peta dasar yang merupakan landasan utama untuk menyusun sebuah rancangan tata ruang suatu daerah (BIG, 2023). Penyediaan terkait peta dasar merupakan sebuah pekerjaan yang tidak mudah karena terkait luasan yang harus diselesaikan dalam kurun waktu tertentu, dan juga biaya yang dikeluarkan untuk pekerjaan tersebut, untuk itu BIG menggunakan gabungan beberapa sumber data dan juga bantuan teknologi percepatan berbasis *Artificial Intelligence* (AI), Informasi Geospasial yang dihasilkan merupakan unsur peta dasar yang tertuang secara detail pada undang-undang No.4 tahun 2011 tentang informasi geospasial, singkatnya salah satu produk turunan yang nanti akan dihasilkan berupa Informasi Geospasial Dasar (IGD), untuk menghasilkan data tersebut dapat dilakukan melalui berbagai macam metode dari berbagai sumber data utama, strategi yang dapat diterapkan untuk mempercepat pembuatan dalam pembuatan unsur peta ini, salah satunya dilakukan dengan percepatan pemetaan skala besar dengan menggunakan bantuan teknologi *artificial intelligence* (AI).

AI merupakan teknologi yang dapat mempercepat proses manual yang dilakukan oleh operator manusia untuk menghasilkan sebuah unsur pada peta, proses AI adalah melakukan pembelajaran dari data yang sudah ada sebelumnya dari hasil manual sehingga memungkinkan melakukan proses otomatisasi pada area lain yang mempunyai kemiripan pada

sumber data yang digunakan. Otomatisasi ini dapat digunakan untuk pembuatan unsur peta yang salah satunya adalah objek jalan pada sebuah data citra.

Penerapan AI ini umumnya dikenal dengan istilah *Deep Learning* yaitu teknologi deteksi objek berbasis komputer atau *computer vision* yang saat ini telah banyak diimplementasikan diberbagai macam bidang, dan menghasilkan hasil yang dapat diterima pada kasus tertentu (Bernard & Matt, 2021), maka dari itu pembuatan unsur jalan yang dilakukan dengan otomatisasi *deep learning* juga melakukan analisis pada data yang dihasilkan adalah topik utama pada tulisan ini

Berdasarkan latar belakang yang telah disampaikan mengenai korelasi antara peran penting peta dasar untuk menunjang pembuatan peta dasar maka percepatan pembuatan unsur peta dasar dapat dilakukan dengan bantuan teknologi kecerdasan buatan, selanjutnya akan dilakukan analisis dari data yang dihasilkan oleh proses otomatisasi dan manual.

METODE PENELITIAN

Lokasi Penelitian

Lokasi penelitian tugas akhir ini dilakukan di Kota Banjarbaru.




Gambar 1. Peta Administrasi Kota Banjarbaru

Dalam penelitian tugas akhir ini digunakan metode analisis untuk pengolahan data. Adapun penggunaan metode analisis dalam penelitian ini adalah sebagai berikut :

1. Metode *Multi Task Road Extractor*


Adalah sebuah algoritma klasifikasi yang dikembangkan dan juga lebih mutakhir dari alogritma pendahulunya yaitu *U-Net*, *U-net* Adalah sebuah arsitektur segmentasi citra yang didalamnya terdapat jaringan *encoder* dan diikuti oleh jaringan *decoder*, segmentasi ini mengaplikasikan tingkatan yang membedakan antara tingkatan piksel sekaligus memproyeksikannya pada tahapan *encoder* kedalam ruang piksel (ESRI, 2024).



Gambar 2. Arsitektur Jaringan U-net (ESRI, 2024)

U-net merupakan klasifikasi citra berdasarkan nilai piksel dan juga masuk dalam kategori segmentasi *semantic*, algoritma ini dianggap lebih baik digunakan untuk klasifikasi objek berdasarkan sifat objeknya yang tidak bisa dihitung. Klasifikasi ini dibedakan menjadi kelas tertentu yang nantinya akan dipisahkan berdasarkan hasil deteksi oleh algoritma, seperti contoh pemisahan pada citra satelit yang memisahkan objek penggunaan lahan, jalan, dan badan air. Selanjutnya penambahan *Orientation learning* terinspirasi dari bagaimana manusia menerjemahkan, menginterpretasikan atau mengambil

hipotesis dari pola jalan berdasarkan pemahaman.



Gambar 3. Penerapan *Multi Task* (Arcgis.com, 2024)

2. Metode *mIOU*

Metode ini adalah melakukan perbandingan berdasarkan hasil jalan baik dari hasil *on-screen* maupun hasil *deep learning*. Perbandingan ini dihitung berdasarkan tumpang tindih dari kedua data tersebut, semakin mirip data yang dihasilkan dari metode otomatis terhadap data referensi maka semakin besar nilai akurasi nya perhitungan ini disebut *IoU*. Sementara *MIoU* adalah melakukan perbandingan dari hasil rata rata dari nilai *IoU*, artinya perbandingan yang dilakukan akan dilakukan lagi perhitungan ulang dan dilakukan rata rata dari hasil perbandingan *IoU*. Rumus perhitungan *mIoU* adalah sebagai berikut :

$$mIoU = \frac{1}{K+1} \sum_{i=0}^K IoU_i \dots \dots \dots (1)$$

$$IoU = \frac{TP}{TP_i + FP_i + FN_i} \dots \dots \dots (2)$$

Keterangan :

K = Total kelas


TP = True Positive

FP = False Positive

FN = False Negative

Kerangka Pemikiran

Kerangka pemikiran yang dilaksanakan dalam kegiatan ini dapat dilihat dari diagram berikut ini :



Gambar 4. Diagram alir kerangka penelitian

Pra-pengolahan data

Proses ini berkaitan langsung dengan data citra satelit yang digunakan dengan melakukan koreksi radiometrik untuk penyesuaian warna pada citra satelit. Juga dilakukan koreksi geometrik untuk meningkatkan akurasi posisi pada lokasi sebenarnya

Pembuatan *Training Sample*

Dalam membentuk sebuah model dari *deep learning* dibutuhkan data sampel untuk pengenalan pola terhadap sebuah bentuk, dalam penelitian ini data yang dibutuhkan untuk pengenalan pola jalan adalah data citra satelit yang dilengkapi jalan yang sudah dilakukan oleh digitasi *on-screen* yang disimpan dalam bentuk *shapefile*. Dalam pembuatan *training sample* ini dilakukan menggunakan *resnet* sebagai arsip penyimpanan pola dari jalan yang dilatih.

Ekstraksi Jalan

Setelah tahap *training sample* selesai maka dilanjutkan dengan ekstraksi pada data citra, ekstraksi ini menggunakan algoritma *multi task road extractor*.

Uji Akurasi

Pengujian akurasi dilakukan untuk mengukur sejauh mana ketelitian jalan otomatis dihasilkan dari metode *deep learning* dengan algoritma *multi task road extractor*. Persamaan matematis untuk pengukuran ini adalah *Mean Intersection over Union* atau MIOU. Yaitu perbandingan antara hasil rata rata dari sebuah hasil perbandingan data otomatis dengan data hasil digitasi *on-screen*.


HASIL DAN PEMBAHASAN

Pembuatan Label Objek Jalan

Proses dalam pembuatan *training sample* adalah dengan melakukan pembuatan label pada data *shapefile* yang akan digunakan. Hal ini diperlukan sebagai pengenalan yang selanjutnya akan disimpan pada pola jaringan *deep learning*. Perubahan dilakukan dengan mengubah nama tabel jalan dengan atribut *classvalue* yang diterapkan pada semua jalan yang akan digunakan. Hal ini merupakan *mandatory process* yang harus dipenuhi jika tidak maka proses pelatihan data tidak akan bisa dilanjutkan karena hilangnya atau tidak ditemukannya parameter yang telah ditetapkan sebelumnya.

Proses Training Sample

Sebelumnya telah kita lakukan proses *labelling* data maka pada tahap *training sample* adalah menggunakan data tersebut untuk pelatihan data atau *training sample*. Langkah tersebut erat kaitannya dengan proses pengisian parameter pada tahap *training sample*.



Gambar 5. Parameter *Training Sample*

Hasil pembuatan model selanjutnya akan ditampilkan berupa gambar contoh prediksi dari model yang telah dibuat, yang dapat dilihat pada Gambar 6



Gambar 6. Contoh Prediksi Model Jalan

Ekstraksi Jalan

Hasil dari segmentasi yang dilakukan menghasilkan jaringan jalan yang hampir mirip dengan data pelatihan dan juga ada penambahan dari jaringan jalan yang tidak ada pada data pelatihan. Meskipun masih terdapat kesalahan pada

deteksi jaringan jalan yang besar seperti jalan nasional dengan 4 jalur kendaraan, dikarenakan data pelatihan mayoritas adalah jalan dengan 2 jalur. Untuk itu perlu ditingkatkan lagi dengan data pelatihan yang lebih komprehensif untuk semua jenis jalan.



Gambar 7. Hasil Jalan

Hasil Evaluasi

Selanjutnya dilakukan juga perbandingan hasil secara keseluruhan yang didapat antara data jaringan jalan referensi dengan hasil otomatis, ini dilakukan karena nilai perbandingan ini tidak muncul ketika melakukan proses *training sample* yang dapat dilihat pada Tabel 1

Tabel 1. Perhitungan Deteksi Objek

<i>Recall</i>	<i>True Positive (TP)</i>	<i>False Positive</i>	<i>False Negative</i>
0,9475	2324	20615	133

Keterangan:

Recall = Evaluasi untuk mengukur seberapa baik model mengenali TP


True Positive = Model memprediksi objek dengan benar

False Positive = Prediksi objek yang dianggap benar padahal salah

False Negative = Prediksi objek yang dianggap salah padahal benar

Post Processing

Tahap *post processing* digunakan setelah data hasil jalan telah dihasilkan. Tahap ini dilakukan untuk melakukan penghalusan sudut pada bentuk jalan itu sendiri dan menggabungkan segmen jalan yang bertampalan menjadi tergabung. Perbaikan ini dilakukan secara otomatis menggunakan tahapan *post processing* dengan metode *dissolve* dan *smoothing*.



Gambar 8. Hasil Jalan dengan *Post Process*

Evaluasi Perbandingan Jarak Jalan

Evaluasi ini adalah membandingkan panjang ruas data jalan hasil otomatis dengan data referensi dalam satuan meter, dan juga melakukan pembuatan model baru dengan data sebagian jalan saja menggunakan data kisaran 10% dan 30% dari total data referensi, ini dilakukan untuk tujuan menguji sejauh mana hasil otomatis yang bisa didapatkan serta melihat hasil yang pengenalan pola jalan yang bersumber dari sebagian data referensi yang dipakai adapun hasilnya dapat dilihat pada Tabel 2, 3 dan 4

Tabel 2. Perbandingan hasil digitasi *on screen* dan otomatis

Total Ruas Jalan Referensi	Hasil Otomatis
1.080.932,69	1.223.241,34

Tabel 3. Perbandingan menggunakan model data 10%

Ruas Jalan Referensi ($\pm 10\%$)	Hasil Otomatis
113.805,10	637.207,38

Tabel 4. Perbandingan menggunakan model data 30%

Ruas Jalan Referensi ($\pm 30\%$)	Hasil Otomatis
297.966,16	684.044,83

Dengan data jalan sebesar $\pm 10\%$ dan $\pm 30\%$ dari data referensi, yang menghasilkan jaringan jalan keseluruhan sepanjang 637 km dari model 10% dan 684 km dari model 30%. Dari pemodelan 10% dan 30% hanya memiliki selisih 47 km dan perbedaan waktu pemodelan 6 jam. Yang artinya tidak begitu signifikan dalam hasil akhirnya. Secara keseluruhan model dapat mengenali jalan pada area citra akan tetapi terdapat banyak yang terputus jika dibandingkan dengan pemodelan yang pertama

KESIMPULAN

Setelah dilakukan proses penelitian yang dimulai dari tahap pengolahan data sampai dengan pembuatan jalan secara otomatis, maka kesimpulan yang dapat diambil adalah sebagai berikut:

1. Hasil jalan otomatis dari sampel 10% (113 km) menghasilkan jalan sepanjang 637 km, sedangkan sampel 30% (297 km) menghasilkan jalan sepanjang 684 km. Perbedaan dari kedua pemodelan tersebut berkisar 6 jam dengan selisih hasil akhir jalan yang tidak begitu signifikan.
2. Pemodelan memiliki skor MIoU 96% menggunakan data jalan keseluruhan. Dan lamanya proses berkisar 30 jam

SARAN

Adapun saran yang dapat dipertimbangkan untuk masukan penelitian selanjutnya adalah sebagai berikut :

1. Menggunakan citra lain dengan resolusi spasial yang lebih tinggi seperti foto udara atau drone.
2. Menggunakan data digitasi jalan yang lebih banyak untuk meningkatkan pengenalan pola jalan.

3. Menggunakan algoritma deep learning lain yang lebih baik, yang mempunyai kelebihan memperpendek durasi waktu proses training sample.

DAFTAR PUSTAKA

- Airbus. (2024). *Pleiades*. Diakses dari Very High Resolution Satellite: <https://space-solutions.airbus.com/imagery/our-optical-and-radar-satellite-imagery/pleiades/>
- Arcgis.com. (2024). *How Multi-Task Road Extractor works ?* Diakses dari [developers.arcgis.com: https://developers.arcgis.com/python/latest/guide/how-multi-task-road-extractor-works/](https://developers.arcgis.com/python/latest/guide/how-multi-task-road-extractor-works/)
- Bennet, L. (2018, 12). *Machine Learning in ArcGIS*. Diakses dari ESRI: <https://www.esri.com/about/newsroom/wp-content/uploads/2018/12/Machine-Learning-in-ArcGIS.pdf>
- Bernard, M., & Matt, W. (2021). *Artificial Intelligence In Practice*. Jakarta: PT Elex Media Komputindo.
- BIG. (2023, 10 26). *Kepala BIG Ungkap Strategi Percepatan Pemetaan Dasar Skala Besar dalam Konferensi Internasional*. Diakses dari Berita Badan Informasi Geospasial: <https://big.go.id/news/2023/10/26/kepala-big-ungkap-strategi-percepatan->

- pemetaan-dasar-skala-besar-dalam-konferensi-internasional
- BRIN. (2022). *Serba Seri Pemanfaatan Penginderaan Jauh*. Diakses dari BRIN: <https://brin.go.id/reviews/110263/serba-serbi-pemanfaatan-penginderaan-jauh>
- Deepak, S. (2013). Estimation of Rainfall–Runoff in a Watershed Using Remote Sensing and GIS.
- Deng, L., & Yu, D. (2013). Deep Learning : Method and Applications. *Foundations and Trends in Signal Processing*, <https://doi.org/10.1136/bmj.319.7209.0a>.
- ESA. (2024). *European Space Agency*. Diakses dari Quickbird-2: <https://earth.esa.int/eogateway/missions/quickbird-2>
- ESRI. (2024). *How U-net Works*. Diakses dari ArcGIS Developer: <https://developers.arcgis.com/python/latest/guide/how-unet-works/>
- ESRI. (2024). *System Requirements*. Diakses dari Arcgis Pro: <https://pro.arcgis.com/en/pro-app/latest/get-started/arcgis-pro-system-requirements.htm>
- Geospasial, B. I. (2024, 06 27). *IG Kejar Target Pemenuhan Peta Dasar Guna Dukung OSS*. Diakses dari Badan Informasi Geospasial: <https://www.big.go.id/news/2024/06/27/big-kejar-target-pemenuhan-peta-dasar-guna-dukung-oss>
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing 4th Edition*. New York: Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. Cambridge: Massachusetts Institute of Technology.
- Haque, N. (2024). *What is Convolutional Neural Network — CNN (Deep Learning)*. Diakses dari medium.com: nafizshahriar.medium.com/what-is-convolutional-neural-network-cnn-deep-learning-b3921bdd82d5
- Indarto. (2013). *Teori dan praktek penginderaan jauh*. Jember: Andi Offset.
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). *Remote Sensing and Image Interpretation*. John Wiley & Sons.
- RI, B. (n.d.). *Database Peraturan*. Diakses dari Informasi Geospasial: <https://peraturan.bpk.go.id/Details/39136/uu-no-4-tahun-2011>
- Siyoto, & Sodik. (2015). *Dasar Metodologi Penelitian*. Yogyakarta: Literasi Media Publishing.
- Sugiyono. (2006). *Metode Penelitian Pendidikan (Pendekatan Kualitatif, Kuantitatif, R&D)*. Bandung: Alfabeta.

Sugiyono. (2009). *Metode Penelitian Pendidikan*. Bandung: Alfabeta.