

CHAPTER 11

SEGMENTASI BERBASIS *DEEP LEARNING* UNTUK MENDETEKSI KETINGGIAN AIR

Rizky Munggaran, Adhiguna Mahendra, Meidy Fitranto, Randy Pangestu

Nodeflux

ABSTRAK

Sebelum proses deteksi tinggi dari permukaan air, hal pertama yang yang perlu dimiliki adalah suatu pendeteksian air yang andal juga menyegmentasi air pada gambar yang diberikan. Umumnya, beberapa metode yang dapat dipakai untuk mendeteksi dan segmentasi objek air, dapat dilakukan dengan metode pemrosesan citra sederhana, seperti histogram warna (merujuk warna air) juga *thresholding* hingga metode yang lebih kompleks dengan menggunakan pembelajaran mendalam (*deep learning*). Penelitian ini difokuskan untuk mengeksplorasi beberapa metode yang potensial sebagai pendeteksi ketinggian air di area sungai, seperti pengembangan berdasarkan proyeksi balik (*histogram backprojection*) dan citra segmentasi berbasis *deep learning*. Hasil eksperimen menunjukkan bahwa metode proyeksi balik histogram tidak cukup stabil untuk diimplementasikan pada kondisi sungai yang sebenarnya. Sementara itu, segmentasi menggunakan *deep learning* memiliki stabilitas dan kinerja yang jauh lebih baik sehingga disarankan. sebagai metode utama untuk mendeteksi dan menyegmentasi air.

Kata kunci: histogram proyeksi balik, pengolahan citra, citra segmentasi, *deep learning*

A. PENDAHULUAN

1. Latar Belakang

Permasalahan banjir masih saja menjadi masalah langganan yang saban tahun melanda ibu kota. Data Badan Penanggulangan Bencana Daerah (BPBD) DKI Jakarta mencatat banjir pada tahun 2021 berdampak pada 113 RW dan menurun sehari setelahnya seiring surutnya luapan air.

R. Munggaran, A. Mahendra, M. Fitranto, & R. Pangestu
Nodeflux, e-mail: rizky.munggaran@nodeflux.io

@2023 Kolaborasi Riset dan Inovasi Industri Kecerdasan Artifisial (KORIKA) & Penerbit BRIN
R. Munggaran, A. Mahendra, M. Fitranto, and R. Pangestu, "Segmentasi berbasis *deep learning* untuk mendeteksi ketinggian air," in *Prosiding Use Cases Artificial Intelligence Indonesia: Embracing Collaboration for Research and Industrial Innovation in Artificial Intelligence*, B. R. Trilaksono, H. Riza, A. Jarin, N. D. S. Darmayanti, and S. Liawatimena, Eds. Jakarta: Penerbit BRIN, Februari 2023, ch. 11, pp. 121-126, doi: 10.55981/brin.668.c547
ISBN: 978-623-8052-49-3, E-ISBN: 978-623-8052-50-9

Bertolak pada data dari laman Pantau Banjir Jakarta yang dikelola Pemprov DKI, sepanjang tujuh tahun terakhir, kondisi banjir tercatat fluktuatif. Hal tersebut ditunjukkan berdasarkan data daerah terdampak, ketinggian air, lama genangan hingga jumlah korban.

Pada tahun 2014, area terdampak banjir masih menembus lebih 500 RW, dari tahun ke tahun trennya menurun, meskipun kembali merangkak naik sekitar 500-an RW pada tahun 2020. Pelaksana tugas (Plt.) Kepala BPBD DKI Jakarta, Sabdo Kurnianto, mengakui bahwa hampir pasti bakal menghadapi bencana banjir setiap tahunnya. Penanganan banjir tergolong kompleks dan dipengaruhi berbagai hal, mulai dari cuaca hingga topografi Jakarta.

Berangkat dari permasalahan tersebut, Nodeflux melakukan inovasi dengan menciptakan solusi berbasis kecerdasan buatan untuk mendeteksi tinggi muka air di sungai secara *real-time* dan otomatis. Hal ini karena, dalam banjir, tindakan dini dalam pencegahan dan prediksi bencana adalah salah satu bagian penting yang tidak dapat ditinggalkan dalam sistem manajemen keamanan dan keselamatan. Dengan perkembangan teknologi, khususnya teknologi AI Computer Vision, sistem pencegahan tersebut dapat terus ditingkatkan guna meningkatkan keamanan dan efisiensi biaya.

2. Tujuan

Tujuan utama dari penelitian ini sebagai berikut.

- a. Menemukan metode yang andal untuk menyegmentasikan air di setiap *region of interest* pada berbagai kondisi air.
- b. Menemukan metode optimal dalam hal sumber daya komputasi.
- c. Memberikan informasi terkait eksperimen yang telah dilakukan dan menjelaskan kelemahan dan kelebihan metode yang telah dikembangkan.
- d. Menginformasikan alasan di balik keputusan peneliti dalam memilih metode terbaik.

3. Tolok Ukur Kondisi

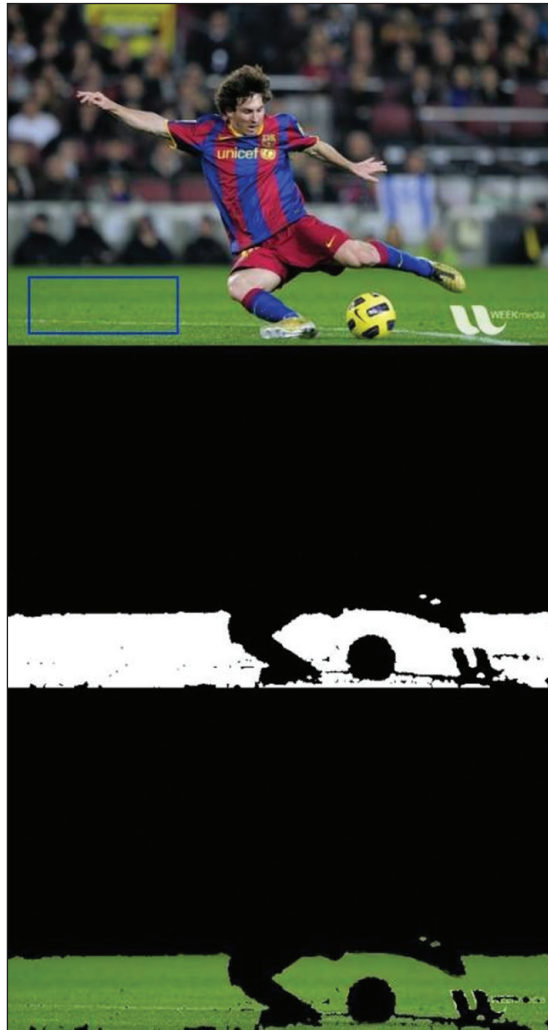
Untuk menerapkan kondisi lingkungan yang sebenarnya, perlu mempertimbangkan beberapa kondisi air yang mungkin terjadi. Kondisi air yang digunakan untuk memutuskan metode terbaik untuk deteksi air adalah tekstur air yang homogen dan tidak homogen yang kinerjanya dinilai berdasarkan kemampuan dan keterbatasan metode saat menangani dua kondisi tersebut.

4. Metodologi

Penelitian ini membandingkan dua metode untuk mendeteksi ketinggian air, yaitu proyeksi balik histogram [1] (*histogram backpropagation*) dan segmentasi berbasis *deep learning* [2][3].

a. Proyeksi Balik Histogram (*Histogram Backprojection*)

Metode ini digunakan untuk mengetahui seberapa bagus piksel dari suatu sampel citra yang diberikan sesuai dengan distribusi suatu piksel dalam model histogram citra atau sampel pengujian. Pada dasarnya, metode ini melihat fitur warna dari histogram sampel yang diberikan kemudian melakukan segmentasi terhadap citra pengujian berdasarkan fitur tersebut.



Gambar 1. Contoh masukan *proyeksi balik histogram* dan Hasil Segmentasinya [4]

Secara statistik, nilai-nilai yang disimpan dalam proyeksi balik histogram mewakili probabilitas bahwa sebuah piksel dalam citra uji yang diwakili oleh bingkai penuh citra, termasuk dalam area tertentu. Berikut adalah langkah metode proyeksi balik histogram.

- 1) Hitung histogram warna dari kedua objek yang perlu kita temukan ('M') beserta gambar yang akan dicari ('I').
- 2) Tentukan rasio $R=MI$ dan *backproject* R menggunakan R sebagai palet dan membuat gambar baru dengan setiap piksel dengan probabilitas yang sesuai untuk menjadi target, yaitu $B(x,y) = R[h(x,y),s(x,y)]$, di mana h adalah *hue* dan s adalah saturasi piksel pada (x,y) . Setelah itu, terapkan kondisi $B(x,y)=\min[B(x,y),1]$.
- 3) Terapkan konvolusi dengan $B=D*B$, di mana D adalah kernelnya.

Hasil proyeksi tersebut memperlihatkan lokasi intensitas maksimum dan lokasi objek. Jika mengharapkan wilayah dalam gambar, perlu memberi ambang batas (*threshold*) yang sesuai untuk memberikan hasil yang bagus.

b. Segmentasi Berbasis *Deep Learning*

Metode ini dikembangkan menggunakan Resnet-18 dan PPM Deepsup [2][3][5] dengan langkah sebagai berikut.

- 1) Membagi data citra ke dalam dua kelas, yaitu *air* dan *background*, yang dapat digunakan sebagai *groundtruth*.
- 2) Melakukan *training* semua citra berlabel menggunakan Resnet-18 dan PPM Deepsup dengan komposisi 60% untuk pelatihan, 20% untuk validasi, dan 20% untuk pengujian (*testing*). Segmentasi semantik mengklasifikasikan setiap piksel dalam gambar berdasarkan kelas untuk menghasilkan peta segmentasi sebagai keluaran (*output*) yang memiliki ukuran sama dengan input. Arsitektur segmentasi semantik umumnya terdiri dari jaringan *encoder-decoder*. *Encoder* biasanya menggunakan jaringan klasifikasi yang telah dilatih sebelumnya untuk membedakan kelas dengan melakukan *downsampling*, sedangkan *decoder* melakukan operasi *upsampling*.
- 3) Menerapkan augmentasi data untuk mengatasi permasalahan keterbatasan data, misalnya refleksi cahaya dapat ditambahkan secara acak dalam dataset pelatihan.
- 4) Melakukan konfigurasi *hyperparameter* untuk pelatihan, seperti *learning rate*, *epoch*, dan ukuran *batch size*, sehingga mendapatkan model segmentasi yang optimal.


B. PEMBAHASAN

Segmentasi air menggunakan *deep learning* menunjukkan hasil yang lebih menjanjikan. Meskipun model hanya dilatih pada kurang dari 500 citra dan dihaluskan menggunakan beberapa dataset negatif, hasil segmentasi pada sebagian besar kondisi dapat dikatakan sangat baik. Selain itu, metode ini lebih baik daripada proyeksi balik histogram dalam hal akurasi kinerja segmentasi, baik pada video maupun gambar. Namun, di antara beberapa keunggulannya, segmentasi *deep learning* masih memiliki kelemahan pada kondisi tertentu karena beberapa hasil segmentasi pada kondisi tertentu menunjukkan hasil yang kurang baik, antara lain

1. *false positive* masih terjadi pada dinding abu-abu dan jalan abu-abu;
2. masih menemukan kesulitan untuk menyegmentasi air yang hitam; dan
3. garis lurus pada permukaan air, seperti kabel yang panjang, akan mengurangi kinerja segmentasi.

Kelemahan-kelemahan tersebut terjadi karena proses latih yang menggunakan data sangat sedikit dan mudah diselesaikan dengan bertambahnya data latih yang diambil pada saat pengimplementasian metode segmentasi dengan *deep learning* ini.

Berdasarkan hasil eksperimen yang dilakukan, hasil evaluasi secara kualitatif menunjukkan bahwa metode *deep learning* memiliki peningkatan yang signifikan dari segi performa jika dibandingkan metode sebelumnya, yaitu proyeksi balik histogram. Berikut perbandingan hasil uji secara kualitatif dua metode yang diujikan dengan skenario perubahan air.



Gambar 2. Hasil Segmentasi dengan Proyeksi Balik Histogram



Gambar 3. Hasil Segmentasi dengan Metode *Deep Learning*

Pada Gambar 2 dan Gambar 3, warna biru merupakan hasil deteksi air, sedangkan poligon dengan garis coklat merupakan *region of interest* (ROI). Hasil eksperimen menunjukkan bahwa perubahan kondisi air sangat berpengaruh terhadap ketepatan dan konsistensi dari segmentasi. Penggunaan proyeksi balik histogram (Gambar 2) menunjukkan proses segmentasi lebih sensitif terhadap perubahan air yang terjadi. Hal ini dapat dilihat dari banyaknya *false positive* (salah dalam mendeteksi air). Namun sebaliknya, untuk metode *deep learning*, pendeteksian lebih stabil dan konsisten sehingga terlihat lebih tepat dalam menyegmen air hal ini ditunjukkan pada Gambar 3.

Selain itu, proses peningkatan performa dengan metode *deep learning* akan menjadi jauh lebih mudah jika dibandingkan metode proyeksi balik histogram. Hanya dengan penambahan data yang telah dianotasi ke dalam proses pelatihan, tidak seperti proyeksi balik histogram yang mengharuskan perbaikan di algoritma dan perhitungan segmentasi. Jadi kelemahan-kelemahan yang masih ada pada metode *deep learning*, akan dapat diatasi dengan lebih mudah seiring dengan bertambahnya data latih. Berikut adalah tampilan pada sistem *Visionaire Nodeflux*.



Gambar 4. Tampilan Hasil segmentasi pada Platform *Visionaire*

C. KESIMPULAN

Hasil penelitian menunjukkan bahwa segmentasi *deep learning* berbasis Resnet-18 jauh lebih baik daripada proyeksi balik histogram dalam hal stabilitas dan keandalan. perubahan kondisi air dan pencahayaan dapat diatasi dibandingkan metode proyeksi balik histogram yang sangat sensitif terhadap perubahan. Penelitian berikutnya akan difokuskan pada segmentasi air menggunakan *deep learning* dengan arsitektur yang lebih baik seperti DeepLabv3, untuk mengoptimalkan biaya komputasi dan akurasi.

DAFTAR PUSTAKA

- [1] Swain, M. J. dan Ballard, D. H. Indexing via color histograms. Dalam *Active perception and robot vision*, pp. 261—273, 1992.
- [2] Zhou, B., Zhao, H., Puig, X., Fidler, S., Barriuso, A., & Torralba, A., “Scene parsing through ade20k dataset,” Dalam *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 633—641.
- [3] Zhou, B., Zhao, H., Puig, X., Xiao, T., Fidler, S., Barriuso, A., “Torralba, A. Semantic understanding of scenes through the ade20k dataset.” *International Journal of Computer Vision*, vol. 127, no. 3, pp. 302—321, 2019.
- [4] OpenCV, “Histogram-4: Histogram backpropagation.” [Daring]. https://docs.opencv.org/4.x/dc/df6/tutorial_py_histogram_backprojection.html
- [5] Zhao, H., Shi, J., Qi, X., Wang, X., dan Jia, J., “Pyramid scene parsing network,” Dalam *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 2881—2890.