



The Determination of River Cleanliness Level Based on the Number of Waste Based of Digital Image Tabulation using Deep Convolutional Neural Network

Penentuan Tingkat Kebersihan Sungai Berdasarkan Banyak Sampah Berbasis Pengolahan Citra Digital Menggunakan Deep Convolutional Neural Network

Aditya Yuli Setyawan*, Yosi Kristian

Institut Sains dan Teknologi Terpadu Surabaya, Department of Informatics

OPEN ACCESS

ISSN 2541-5107 (online) (online)

Edited by:

Akbar Wiguna

Reviewed by:

Etistika Yuni Wijaya

***Correspondence:**

Aditya Yuli Setyawan
adityasetya88@gmail.com

Received: 29-09-2020

Accepted: 20-10-2020

Published: 29-10-2020

Citation:

Setyawan AY and Kristian Y (2020)

The Determination of River Cleanliness Level Based on the Number of Waste Based of Digital Image Tabulation using Deep Convolutional Neural Network.
JICTE (Journal of Information and Computer Technology Education).

4:2.

doi: 10.21070/jicte.v4i2.971

The river environment pollution due to the industrial and house hold waste are widely happening nowadays. River functions as the ecosystem for many creatures including human beings who often utilize it as a support for their daily life. As the development of technology in which many things are set automatically, there are many technology discoveries used to overcome the problems of waste in the river. This research discusses on how to get river cleanliness level using Deep Convolutional Neural Network based on digital image tabulation as a method to detecting waste based on the number of waste in the river. To achieve the purpose, there are many steps done. First step is processing, namely process to construct data learning which produces two categories, waste and non-waste. The second step is the process of object detection to a computer functions as program dataset. The third step is the making of selection area on the river surface which is called ROI (Region of Interest). The next step is the counting of detected waste average in the pixel unit in the video. The result of pixel average can be used as a reference to determine the river cleanliness level. In this research, the river cleanliness level modeled uniformly into four classes, they are: very dirty in which the percentage of detected waste is 76%-100%, dirty in which the percentage of detected waste is 51%-75%, dirty enough in which the percentage of detected waste is 26%-50%, clean in which the percentage of detected waste is 0%-25%. After that the tabulation was simulated with desktop-based application using python programming.

Keywords: waste, ROI, python, digital image tabulation, Deep Convolutional Neural Network, ROI, python, pengolahan citra, Deep Convolutional Neural Network

Pencemaran lingkungan sungai oleh limbah industri dan sampah rumah tangga sudah umum terjadi saat ini. Dalam fungsinya sungai adalah ekosistem dari berbagai makhluk hidup tidak terkecuali manusia yang sering memanfaatkan sungai sebagai penunjang

kegiatan sehari – hari. Seiring perkembangan jaman yang serba otomatis maka banyak penemuan teknologi yang dimanfaatkan untuk menanggulangi masalah sampah di sungai. Penelitian ini membahas tentang bagaimana memperoleh tingkat kebersihan sungai menggunakan Deep Convolutional Neural Network berbasis pengolahan citra digital sebagai metode pendekripsi sampah berdasarkan banyaknya sampah di sungai. Untuk mencapai tujuan tersebut diperlukan beberapa tahap. Tahap pertama dimulai dari pre-processing yaitu proses pembuatan data learning yang menghasilkan dua kategori yaitu sampah dan non sampah. Tahap kedua proses pengenalan objek pada sebuah komputer yang berfungsi sebagai dataset program. Tahapan ketiga pembuatan area seleksi pada permukaan sungai yang diberikan istilah ROI (Region Of Interest). Tahapan selanjutnya adalah penghitungan rata – rata sampah yang terdeteksi dalam satuan piksel pada video dari hasil rata-rata piksel didapat dijadikan salah acuan untuk menentukan tingkat kebersihan sungai. Pada penelitian ini tingkat kebersihan sungai dimodelkan secara uniform menjadi empat kelas, meliputi kategori sangat kotor dengan prosentase sampah terdeteksi 76%-100%, kotor dengan prosentase sampah terdeteksi 51%-75%, cukup kotor dengan prosentase sampah terdeteksi 26%-50%, bersih dengan prosentase sampah terdeteksi 0%-25%. Selanjutnya perhitungan tersebut disimulasikan dengan aplikasi berbasis desktop dengan bahasa pemrograman python.

Keywords: sampah, ROI, python, pengolahan citra, Deep Convolutional Neural Network

PENDAHULUAN

Secara visual tingkat pencemaran sungai dapat deteksi dan dinilai dari banyaknya sampah pada sungai tersebut. Sampah dan limbah industri secara visual juga dapat dikenali oleh mata manusia tanpa bantuan peralatan tambahan, baik dalam segi bentuk objek sampah yang beraneka macam maupun warna objek sampah yang beraneka ragam. Tampilan visual tersebut dapat dilihat seperti Gambar 1



FIGURE 1 | Sungai dengan sampah yang terbawa aliran air

Dengan mengetahui informasi dasar seperti tingkat kebersihan sungai berdasarkan banyaknya sampah di sungai, dinas terkait dapat dengan sigap sehingga tidak sampai berakibat bencana dan menimbulkan kerugian. Dengan adanya karakteristik visual tersebut maka memungkinkan proses tersebut dapat dikenali oleh komputer, dengan menggunakan pengolahan citra digital.

Proses pengenalan objek termasuk dalam ilmu klasifikasi, yang mana dalam klasifikasi objek akan dapat dikenali dengan menggunakan pengetahuan (data) yang telah dikenalkan sebelumnya pada sebuah komputer. Pengetahuan (data) tersebut dikenal dengan istilah data learning. Pada permasalahan ini data learning yang digunakan adalah beberapa jenis sampah yang meliputi sampah rumah tangga maupun sampah yang lainnya, sehingga diharapkan dengan menggunakan data learning ini objek akan dapat dikenali serta dapat dikelompokkan sebagai sampah atau objek bukan sampah. *Deep Learning* adalah salah satu contoh bidang *Machine Learning* yang menggunakan jaringan syaraf tiruan pada penerapan permasalahan dengan dataset yang besar [Panella et al. \(2018\)](#); [Zhang et al. \(2017\)](#). Teknik *Deep Learning* sangat mendukung proses *Supervised Learning* pada komputer dikarenakan pengenalan data set yang sangat kuat sehingga mampu menjadi pondasi dalam proses klasifikasi [Socher et al. \(2012\)](#); [Xin et al. \(2018\)](#). *Convolutional Neural Network* merupakan salah satu jenis *neural network* yang juga merupakan bagian dari *Deep Learning* [Zhang et al. \(2018\)](#); [Sharma et al. \(2017\)](#). Pada umumnya *Convolutional Neural Network* digunakan pada pengolahan data yang berupa image atau data lainnya [Krizhevsky et al. \(2012\)](#); [Azizah et al. \(2018\)](#); [Darmando \(2019\)](#). Convolutional neural network ini juga diklaim sebagai algoritma terbaik dan paling banyak digunakan untuk mendeteksi objek dari data citra digital [Putra \(2016\)](#). Dari uraian permasalahan tersebut di dalam jurnal ini membahas tentang bagaimana cara menghitung tingkat kebersihan dengan menggunakan *Deep Convolutional Neural Network* berbasis pengolahan citra digital dengan tahap awal adalah menentukan objek dengan kat-

egori sampah dan objek kategori non sampah, diteruskan oleh tahap kedua berupa penentuan ROI (*Region Of Interest*) dan selanjutnya tahap ketiga adalah deteksi sampah yang terbawa arus air sungai yang mengalir. Terakhir adalah penghitungan tingkat kebersihan sungai berdasarkan prosentase sampah dengan sungai pada ROI (*Region of Interest*).

METODOLOGI PENELITIAN

Arsitektur Sistem

Secara garis besar sistem penelitian menggunakan 2 tahapan yaitu dengan pemodelan data learning untuk mendapatkan output data learning sampah maupun non sampah dan tahap berikutnya yaitu penentuan tingkat kebersihan sungai.

Penentuan data learning dimulai dengan membuat potongan gambar dari beberapa frame video dan gambar dari media lain. Potongan – potongan gambar dengan berbagai kondisi tersebut selanjutnya dilakukan proses seleksi dengan metode CNN untuk disamakan ukurannya sehingga didapatkan data yang homogen dengan ukuran 64 X 64. Untuk lebih jelasnya disajikan dalam bentuk diagram pada Gambar 2 :

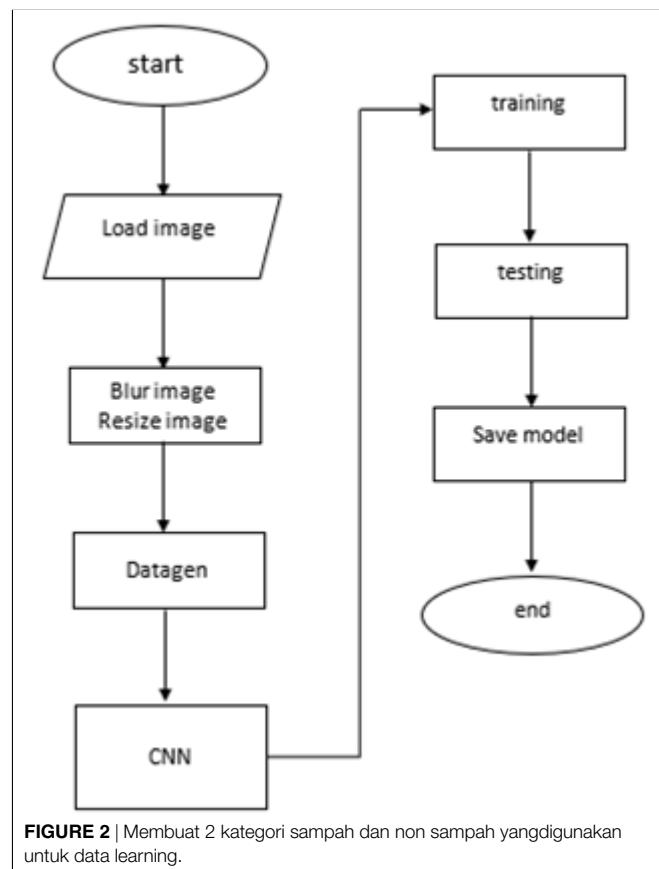
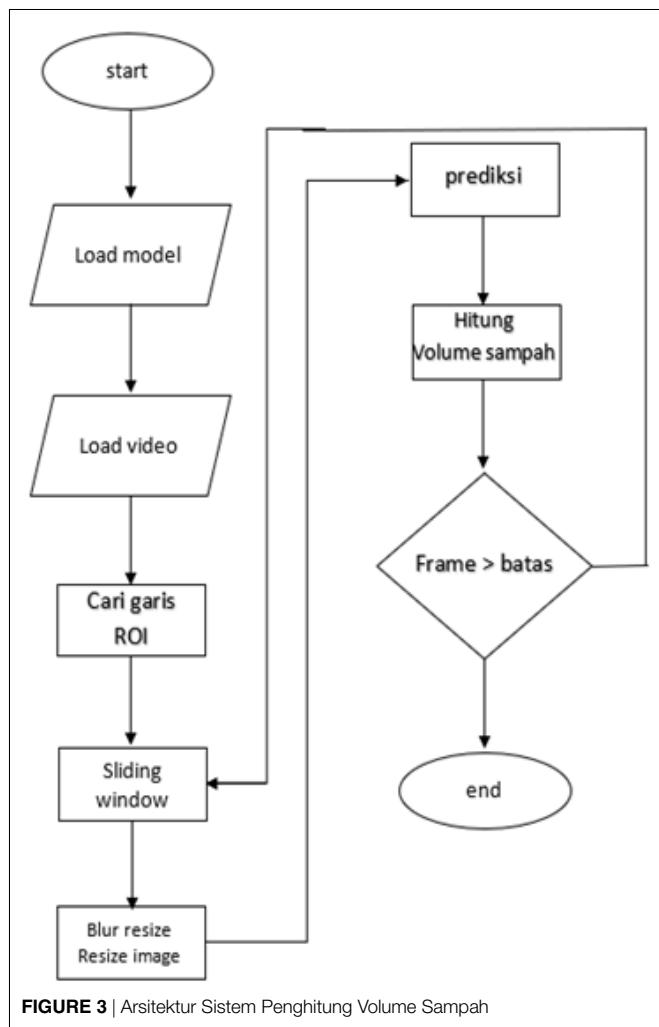


FIGURE 2 | Membuat 2 kategori sampah dan non sampah yang digunakan untuk data learning.

untuk menentukan besaran objek sampah yang terbawa aliran air sungai. Proses pendekripsi tersebut diawali dengan memasukkan video dengan durasi waktu yang telah ditentukan. Dilanjutkan dengan penentuan luas area ROI (Region

Of Interest) yang digunakan sebagai parameter pembanding untuk menentukan tingkat kebersihan sungai. Luas area ROI diberikan satuan hitung berupa piksel. Tahapan berikutnya adalah melakukan deteksi dengan sliding window meliputi penyesuaian warna dan ukuran objek. Dilanjutkan kembali dengan proses prediksi oleh CNN yang berfungsi menentukan objek sampah dan non sampah dengan memanfaatkan data learning yang telah terbentuk pada proses sebelumnya. Hasil prediksi diakumulasikan sehingga terbentuk kumpulan piksel sampah terdeteksi. Langkah terakhir adalah proses penghitungan sampah yaitu dengan membandingkan sampah yang terdeteksi dengan luas area ROI yang terbentuk. Dari perbandingan akumulasi jumlah piksel sampah terdeteksi dengan jumlah piksel luas area ROI maka didapatkan prosentase volume kebersihan sungai yang terdeteksi. Untuk lebih jelasnya disajikan dalam bentuk arsitektur pada Gambar 3.



Pengumpulan Data

Data diambil dari beberapa sumber yang meliputi video dan gambar – gambar yang terdapat pada media online. Setelah itu

dilakukan proses pemotongan gambar secara random baik itu gambar sampah dan non sampah dengan ukuran piksel yang berbeda. Data uji yang berupa video diambil dengan menggunakan batasan durasi 1-2 menit.

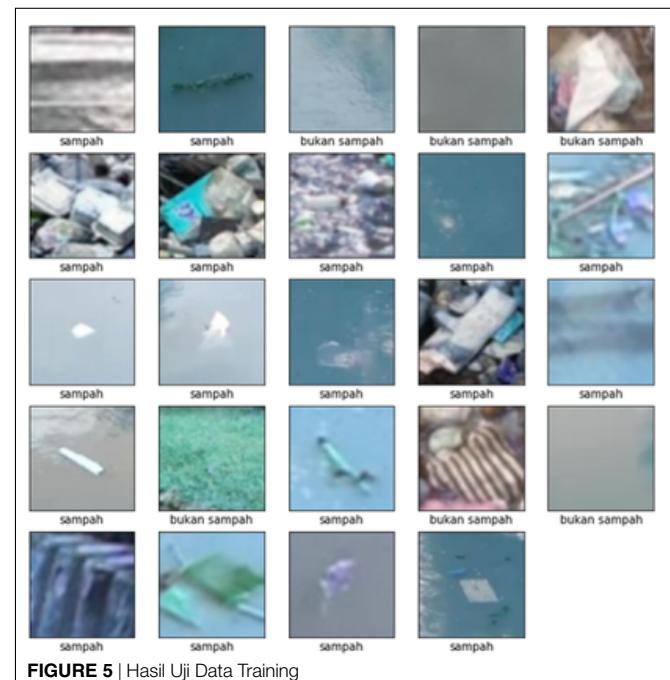
HASIL DAN PEMBAHASAN

Hasil pengujian data learning didapatkan angka f1-score yang baik. Dapat dilihat pada Gambar 4 yang menunjukkan nilai 0,83 untuk f1-score.

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0 | 0.87 | 0.89 | 0.88 | 38 |
| 1 | 0.73 | 0.69 | 0.71 | 16 |
| accuracy | | | 0.83 | 54 |
| macro avg | 0.80 | 0.79 | 0.80 | 54 |
| weighted avg | 0.83 | 0.83 | 0.83 | 54 |

FIGURE 4 | Akurasi CNN

Dari data hasil F1-score tersebut dapat disimpulkan jika metode CNN baik untuk digunakan sebagai deteksi objek. Berikut contoh gambar hasil pengujian data training yang dapat menunjukkan klasifikasi objek sampah dan objek bukan sampah seperti ditunjukkan Gambar 5



Setelah mendapatkan data pada proses awal maka dilanjutkan pada langkah berikutnya yaitu melakukan uji coba data sample yang telah direkam oleh peneliti. Pada penelitian ini uji coba dilakukan dengan menggunakan 4 sample video sungai berbeda dengan durasi 1-2 menit. Untuk masing – masing kondisi sungai dapat dilihat pada Gambar 6 yang merupakan frame awal dari setiap video sample.



Proses dimulai dengan menginputkan salah satu dari keempat video tersebut. Dari masing-masing frame akan dilakukan pendekripsi oleh CNN untuk mengenali objek sampah dan bukan sampah. Proses ini akan terus berulang hingga durasi video habis. Dari proses pendekripsi ini didapatkan angka f1-score untuk sistem sebesar 0,82. f1-score didapatkan dari penghitungan confusion matrix, yaitu suatu cara untuk mengevaluasi performance algoritma. Dengan confusion matrix dapat menentukan accuracy, precision, recall, dan specificity. Untuk confusin matrix dapat dilihat pada Gambar 7

| | | Prediksi | | |
|-----------------|--------------|--------------------|--------------|---------------------|
| | | Sampah | Bukan Sampah | FN (false negatif) |
| Actually | Sampah | 328 | 69 | |
| | Bukan Sampah | 73 | - | |
| | | TP (true positif) | | |
| | | | | FP (false positif) |
| | | | | TN (true negatif) |

FIGURE 7 | Confusion Matrix

Angka – angka yang terdeteksi diambil dari penghitungan manual frame sebanyak 100 frame dan ditentukan berapa besaran dari masing – masing muatan confusion matrix tersebut yang digunakan sebagai pencari f1-score untuk uji performance algoritma. Untuk alur perhitungan dapat di tuliskan pada Tabel 1

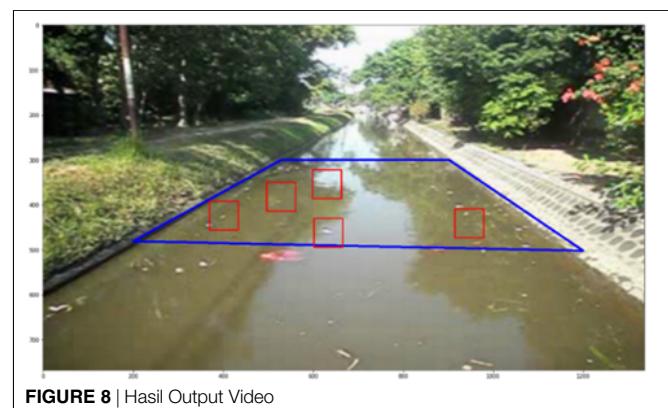
TABLE 1 | uji performance algoritma

| | |
|---------------|--|
| Accuracy | : $(TP + TN) / (TP+FP+FN+TN)$: $(328 + 0) / (328+73+69+0)$: $328/470$: $0,689 \text{ ---- dalam persen } X100\% = 68,9\%$ |
| Precision | : $TP/(TP+FP)$: $328 / (328+73)$: $328 / 401$: $0,817 \text{ ---- dalam persen } X100\% = 81,7\%$ |
| Recall | : $TP/(TP+FN)$: $328/(328+69)$: $328 / 397$: $0,826 \text{ ---- dalam persen } X100\% = 82,6\%$ |
| Specification | : $0/(0+FP)$: $0/(0+73)$: $0 / 73$: $0 \text{ ---- dalam persen } X100\% = 0\%$ |
| F1-Score | : $(2 \times (\text{recall} \times \text{precision})) / (\text{recall}+\text{precision})$: $(2 \times (82,6\% \times 81,7\%)) / (82,6\% + 81,7\%)$: $(2 \times 6.748,42\%) / 164,3\%$: $13.496,84\% / 164,3\%$: $82,147 \% \text{ (dalam persen)}$ |

Proses berikutnya adalah perhitungan tingkat kebersihan sungai tiap frame diperoleh dengan menggunakan persamaan (6). Sedangkan tingkat kebersihan keseluruhan diperoleh dari kondisi 100% bersih dikurangi rata-rata tingkat kekotoran seluruh frame dari video input.

$$\text{Tingkat kebersihan sungai} = 100 \% - \frac{\text{jumlah piksel sampah}}{\text{jumlah piksel ROI}}$$

Dari proses penghitungan diperoleh kondisi sungai sangat bersih dengan tingkat prosentase kebersihan sungai mencapai 88,636 %. Dengan hasil output video yang dapat dilihat pada Gambar 8



Hal yang sama dilakukan pada tiga sample video sungai yang lain. Didapatkan hasil akhir dari ke empat video sample dapat dilihat pada Tabel 2

TABLE 2 | Hasil Uji coba

| NO | Nama Sungai | Tingkat Kebersihan Sungai |
|----|------------------|---------------------------|
| 1 | Sungai Sembung | 97,697 % |
| 2 | Sungai Mbrambang | 94,697 % |
| 3 | Sungai Cukir | 93,697 % |
| 4 | Sungai Perak | 88,636 % |

KESIMPULAN

Dari uji coba tersebut diperoleh hasil keadaan sungai sungai yang berbeda – beda yang bergantung pada banyak sampah yang terdeteksi. Penelitian ini masih mungkin untuk dikembangkan lagi menjadi lebih kompleks, karena masih banyak kekurangan dibeberapa hal.

REFERENCES

- Azizah, L. M., Umayah, S. F., and Fajar, F. (2018). Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multi-layer. *Semesta Teknika* 21, 230–236. doi: 10.18196/st.212229.
- Darmanto, H. (2019). Pengenalan Spesies Ikan Berdasarkan Kontur Otolith Menggunakan Convolutional Neural Network. *Joined Journal (Journal of Informatics Education)* 2, 41–59.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet Classification With Deep Convolutional Neural Networks. *Advances in neural information processing systems*, 1097–1105.
- Panella, F., Boehm, J., Loo, Y., Kaushik, A., and Gonzalez, D. (2018). DEEP LEARNING AND IMAGE PROCESSING FOR AUTOMATED CRACK DETECTION AND DEFECT MEASUREMENT IN UNDERGROUND STRUCTURES. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLII-2, 829–835. doi: 10.5194/isprs-archives-xlii-2-829-2018.
- Putra, W. S. E. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS* 5, 65–69. doi: 10.12962/j23373539.v5i1.15696.
- Sharma, A., Liu, X., Yang, X., and Shi, D. (2017). A patch-based convolutional neural network for remote sensing image classification. *Neural Networks* 95, 19–28.
- Socher, R., Huval, B., Bath, B., Manning, C. D., and Ng, A. Y. (2012). Convolutional Recursive Deep Learning for 3D Object Classification. *Advances in Neural Information Processing Systems*, 656–664.
- Xin, Y., Kong, L., Liu, Z., Chen, Y., Li, Y., Zhu, H., et al. (2018). Machine learning and deep learning methods for cybersecurity. *IEEE Access* 6, 35365–35381.
- Zhang, L., Tan, J., Han, D., and Zhu, H. (2017). From machine learning to deep learning: progress in machine intelligence for rational drug discovery. *Drug Discovery Today* 22, 1680–1685. doi: 10.1016/j.drudis.2017.08.010.
- Zhang, X., Zhou, X., Lin, M., and Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 6848–6856.
- Conflict of Interest Statement:** The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.
- Copyright © 2020 Setyawan and Kristian. This is an open-access article distributed under the terms of the Creative Commons Attribution License (CC BY). The use, distribution or reproduction in other forums is permitted, provided the original author(s) and the copyright owner(s) are credited and that the original publication in this journal is cited, in accordance with accepted academic practice. No use, distribution or reproduction is permitted which does not comply with these terms.