

IMPLEMENTASI ARSITEKTUR XCEPTION PADA MODEL MACHINE LEARNING KLASIFIKASI SAMPAH ANORGANIK

Rian Kurniawan¹, Yessi Mulyani², Puput Budi Wintoro^{3*}, Muhamad Komarudin⁴

^{1,2,3,4}Teknik Informatika, Universitas Lampung; Jl. Jl. Prof. Dr. Ir. Sumantri Brojonegoro No.1, Bandar Lampung, Lampung

Riwayat artikel:

Received: 2 April 2023

Accepted: 10 April 2023

Published: 12 April 2023

Keywords:

Xceptionm;

Klasifikasi;

Convolutional Neural

Network;

Sampah Anorganik.

Correspondent Email:

budi.wintoro@eng.unila.ac.id

Abstrak. Sampah yang dihasilkan setiap hari dapat menjadi masalah karena beberapa jenis sampah sulit terurai sehingga dapat mencemari lingkungan. Sampah yang berpotensi dapat didaur ulang dan memiliki nilai jual adalah sampah anorganik terutama sampah kardus, logam, kertas, kaca, plastik, karet dan sampah lainnya seperti kemasan produk. Berbagai jenis limbah dapat diklasifikasikan menggunakan model pembelajaran mesin. Model pembelajaran mesin yang digunakan untuk klasifikasi sistem limbah adalah model dengan metode *Convolutional Neural Network* (CNN). Pemilihan arsitektur CNN memperhitungkan akurasi yang diperlukan dan biaya komputasi. Penelitian ini bertujuan untuk menentukan arsitektur, pengoptimal, dan laju pembelajaran terbaik dalam sistem klasifikasi limbah. Model yang dirancang menggunakan arsitektur *Xception* dengan *Adam optimizer* dan *learning rate* 0,001 memiliki akurasi sebesar 87,81%.

Abstract. Garbage generated every day can be a problem because some types of waste are difficult to decompose so they can pollute the environment. Waste that can potentially be recycled and has a selling value is inorganic waste, especially cardboard, metal, paper, glass, plastic, rubber and other waste such as product packaging. Various types of waste can be classified using machine learning models. The machine learning model used for classification of waste systems is a model with the *Convolutional Neural Network* (CNN) method. The selection of the CNN architecture takes into account the required accuracy and computational costs. This study aims to determine the best architecture, optimizer, and learning rate in the waste classification system. The model designed using the *Xception* architecture with the *Adam optimizer* and a learning rate of 0.001 has an accuracy of 87.81%.

1. PENDAHULUAN

Sampah yang dihasilkan setiap hari dapat menjadi masalah karena beberapa jenis sampah sulit terurai sehingga dapat mencemari lingkungan. Sampah terdiri dari dua jenis, yaitu sampah organik dan sampah anorganik. Sampah organik adalah sampah yang berasal dari sisa-sisa organisme hidup, sedangkan sampah anorganik berasal dari organisme tak hidup. Sampah yang berpotensi dapat didaur ulang dan memiliki nilai jual adalah sampah

anorganik terutama sampah kardus, logam, kertas, kaca, plastik, karet dan sampah lainnya seperti kemasan produk. [1]

Berbagai jenis limbah dapat diklasifikasikan menggunakan model *machine learning*. Model *machine learning* yang digunakan untuk klasifikasi sistem limbah adalah model dengan metode *Convolutional Neural Network*. Model dengan metode ini akan mengenali citra sampah dengan mengekstraksi fitur citra dan mengenali pola sesuai dengan label pada data latih [2].

Dalam beberapa dekade terakhir, *Deep Learning* telah menjadi alat yang ampuh. Hal ini dibuktikan dengan kemampuannya menangani data dalam jumlah besar dan mampu mengenali pola dari data yang dikelolanya. Salah satu algoritma yang populer untuk menangani data dalam jumlah besar adalah *Convolutional Neural Network* [3].

Arsitektur *Convolutional Neural Network* yang digunakan untuk merancang model pembelajaran mesin memainkan peran penting. Semakin tepat pemilihan arsitektur *Convolutional Neural Network*, semakin baik akurasi model yang dibuat untuk memprediksi citra sampah. Selain akurasi yang baik, setiap arsitektur memiliki ukuran, parameter, dan biaya (CPU/GPU) yang berbeda. Arsitektur *Xception* merupakan arsitektur yang memiliki akurasi tinggi, ukuran kecil, dan parameter yang lebih sedikit dibandingkan beberapa arsitektur lainnya, sehingga model yang dilatih menggunakan arsitektur ini akan dapat digunakan secara efektif dan efisien untuk memprediksi citra [4].


2. TINJAUAN PUSTAKA

2.1. Machine Learning

Awalnya, *machine learning* adalah istilah yang digunakan untuk merujuk pada cabang ilmu komputer yang mempelajari metode desain algoritma yang mampu mempelajari atau beradaptasi dengan pola data tanpa diprogram secara eksplisit. *Machine learning* memiliki beberapa metode komputasi yang dapat meningkatkan kinerja dengan memanfaatkan pengetahuan yang didapat dari pengalaman saat belajar [5].

2.2. Convolutional Neural Network

Convolutional Neural Network adalah salah satu algoritma *deep learning* yang digunakan untuk mengklasifikasikan gambar. CNN beroperasi menggunakan konvolusi dan menggunakan setidaknya satu lapisan. Jaringan syaraf tiruan umumnya dapat mengubah nilai masukan dengan memasukkannya ke dalam rangkaian lapisan tersembunyi. Setiap lapisan dapat terdiri dari sekumpulan *neuron*, dimana setiap lapisan akan berhubungan penuh dengan lapisan sebelumnya. Terakhir, lapisan sebelumnya akan terhubung sepenuhnya untuk menghasilkan prediksi.



Gambar 1. Operasi Konvolusi

Convolutional Layer atau lapisan konvolusi adalah lapisan yang di dalamnya terdapat operasi ekstraksi esensi fitur. Operasi ekstraksi fitur inti adalah produk titik antara bobot dalam filter dan piksel citra yang akan difilter kemudian dijumlahkan setelahnya seperti yang ditunjukkan pada Gambar 1. Operasi Konvolusi [2].

2.3. Xception


Extreme of Inception (Xception) adalah arsitektur *Convolutional Neural Network* yang menggunakan metode konvolusi yang dapat dipisahkan secara mendalam. Arsitektur ini merupakan hasil pengembangan dari arsitektur Inception yang memiliki 36 lapisan konvolusi yang menjadi dasar dari jaringan ekstraksi fitur [6].

2.4. Optimizer

Optimizer adalah algoritma atau metode yang digunakan untuk mengubah atribut yang ada pada jaringan syaraf tiruan. Atribut yang dapat diubah menggunakan algoritma ini adalah nilai bobot dan *learning rate* dengan tujuan untuk mengurangi nilai *loss* selama proses pelatihan [7].

Adam adalah algoritma yang dikembangkan dari algoritma klasik *Stochastic Gradient Descent* (SGD) dimana nilai bobot jaringan telah diperbarui. Penggunaan algoritma ini membutuhkan pengaturan *learning rate* terlebih dahulu sebelum melakukan proses pelatihan. *Learning rate* merupakan parameter pelatihan yang digunakan untuk menghitung nilai bobot koneksi pada saat proses pelatihan dilakukan. Besar kecilnya *learning rate* yang digunakan akan mempengaruhi efektivitas dan efisiensi proses pelatihan [8].

3. METODE PENELITIAN



Gambar 2. Tahapan Penelitian

Bahan penelitian berupa dataset *Kaggle*, dataset foto yang diperoleh secara mandiri, dataset yang bersumber dari internet, buku, tesis, jurnal, dan sumber ilmiah lainnya yang diperoleh dari berbagai *website*. Tahapan penelitian ini dimulai dengan pengumpulan data, pemisahan data, desain model, pelatihan model, dan evaluasi model.

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan data

Data yang terkumpul terdiri dari 2.527 data yang bersumber dari *Kaggle* dan 120 data yang dihasilkan secara mandiri oleh penulis dengan mengambil foto langsung dan mencarinya dari internet, sehingga total data yang digunakan adalah 2.647 data. Setiap data dalam dataset adalah gambar dengan ekstensi .jpg (*Joint Photographic Experts Group*).



Gambar 3. Data sampah anorganik

Gambar tersebut merupakan beberapa data kelas kardus, kaca, logam, kertas, plastik, dan sampah yang diperoleh dari situs *kaggle*. Terdapat 403 data pada kelas karton, 501 data pada kelas kaca, 410 data pada kelas logam, 594 data pada kelas kertas, 482 data pada kelas plastik, dan 137 data pada kelas sampah.

4.2. Pembagian data

Pada tahap ini penulis membagi dataset yang terkumpul menjadi beberapa bagian yaitu data latih, data validasi, dan data uji, dengan rasio masing-masing sebesar 70%, 15%, dan 15% dari total data yang memiliki rasio 1. Rasio distribusi bertujuan untuk mendistribusikan data validasi dan data uji diperoleh secara mandiri yang disebar lebih banyak yaitu 3 data untuk setiap kelas. Jika rasio diturunkan menjadi 0,1 untuk data validasi dan 0,1 untuk data uji, maka hanya terdapat 2 data yang tersebar untuk setiap kelas. Rasio distribusi 0,15 untuk data validasi dan data uji membuat data terdistribusi 50% lebih banyak. Dari pembagian dengan rasio ini diperoleh 1.850 data latih, 402 data validasi, dan 395 data uji. Setelah proses tersebut, data yang dihasilkan adalah 1.850 data latih, 402 data validasi, dan 395 data uji.

4.3. Perancangan Model

Model yang dibuat memiliki 2048 neuron pada lapisan *Fully-Connected* sebelum masuk ke layer prediksi yang akan memprediksi 6 kelas dengan fungsi aktivasi *Softmax*. Dari gambar tersebut, awalnya ukuran input adalah 224x224 kemudian dilakukan konvolusi menjadi ukuran 7x7, namun kedalamannya bertambah.

Model dikompilasi menggunakan *Adam optimizer*, learning rate 0,001, loss menggunakan *categorical crossentropy*, dan akurasi metrik. Sehingga model cenderung dilatih cukup lama untuk mendapatkan akurasi prediksi yang optimal untuk mengklasifikasikan setiap kategori.

4.3.1. Pelatihan model

Pada tahap ini dilakukan pelatihan pada masing-masing model dengan optimasi dan *learning rate* yang berbeda. Nilai *epoch* disini tidak berpengaruh signifikan karena selama proses training fungsi callbacks digunakan untuk menghentikan training ketika nilai validasi tidak bertambah, akurasi model sudah optimal.

4.3.2. Evaluasi model

Pada tahap ini dilakukan evaluasi terhadap model menggunakan data uji dan metode evaluasi yang disediakan oleh *framework TensorFlow* dengan tujuan untuk mendapatkan nilai akurasi model. Berdasarkan gambar di atas akurasi untuk model *Xception* adalah 87,81% dimana model menggunakan *Adam optimizer* dengan *learning rate* 0,001.

5. KESIMPULAN

Model *machine learning* klasifikasi sampah anorganik yang dirancang menggunakan arsitektur *Xception* dengan *Adam optimizer* dan *learning rate* 0,001 memiliki akurasi yang lebih baik sebesar 87,81% sehingga mampu mendeteksi sampah anorganik dengan cukup baik.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Fakultas Teknik Universitas Lampung, TPST Unila, Lab Komputer Teknik Informatika Unila dan Perpustakaan Unila serta pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] I. Febriadi, "Pemanfaatan Sampah Organik Dan Anorganik Untuk Mendukung Go Green Concept Di Sekolah," *Abdimas: Papua Journal of Community Service*, vol. 1, no. 1, pp. 32-39, 2019.
- [2] M. D. Payana, "Deteksi Masker Wajah Menggunakan Metode Convolutional Neural Network (CNN) Meningkatkan Nilai Akurasi Melalui Arsitektur Layer Konvolusi," *Journal of Informatics and Computer Science*, vol. 8, no. 1, pp. 30-35, 2022.
- [3] A. A. Kurniawan, "Implementasi Deep Learning Menggunakan Metode CNN dan LSTM untuk Menentukan Berita Palsu dalam Bahasa Indonesia," *Jurnal Informatika Universitas Pamulang*, vol. 5, no. 4, pp. 544-552, 2020.
- [4] A. Santoso, "Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah," *Jurnal Teknik Elektro*, vol. 18, no. 1, pp. 15-21, 2018.
- [5] A. Roihan, "Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper," *IJCIT (Indonesian Journal on Computer and Information Technology)*, vol. 5, no. 1, pp. 75-82, 2020.
- [6] Sandhopi, "Identifikasi Motif Jepara pada Ukiran dengan Memanfaatkan Convolutional Neural Network," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 9, no. 4, pp. 403-413, 2020.
- [7] A. Wikarta, "Analisa Berbagai Optimizer pada Convolutional Neural Network untuk Mendeteksi Pemakaian Masker Pengemudi Kendaraan," in *Seminar Nasional Informatika 2020 (SEMNASIF 2020)*, Yogyakarta, 2020.
- [8] N. Rochmawati, "Analisa Learning rate dan Batch size Pada Klasifikasi Covid Menggunakan Deep learning dengan Optimizer Adam," *JIEET (Journal Information Engineering and Educational Technology)*, vol. 5, no. 2, pp. 44-48, 2021.