

Klasifikasi Citra Bunga dengan Menggunakan *Deep Learning: CNN (Convolution Neural Network)*

Gramandha Wega Intyanto

gramandha@aknpacitan.ac.id
 Tatalaksana Studio Produksi, Akademi
 Komunitas Negeri Pacitan

Abstrak

Keanekaragaman hayati Indonesia memiliki presentasi tertinggi di Asia Tenggara, salah satunya yaitu jenis bunga yang tercatat hingga 19.232. Keanekaragaman jenis bunga ini memberikan potensi bagi masyarakat dari nilai budaya, ekonomi, dan ekologi. Pada kehidupan sehari-hari mengenal jenis bunga membutuhkan waktu yang tidak singkat, dimana mulai dari mengetahui karakteristik kemudian mengidentifikasi nama bunga. Proses belajar ini dilakukan dengan bertanya pada pakar, mencari di buku bahkan di Internet. Salah satu cara identifikasi jenis bunga dengan cepat yaitu dilakukan dengan klasifikasi data gambar atau citra. Hal tersebut yang memberikan ide penelitian ini, dimana melakukan komputasi citra dalam pengimplementasian *deep learning* untuk klasifikasi citra jenis bunga (daisy, dandelion, rose, sunflower, dan tulip). Metode *deep learning* yang digunakan yaitu *CNN (Convolution Neural Network)*, dimana arsitektur I dirancang penulis dan arsitektur II yaitu menggunakan VGG16. Hasil nilai akurasi pada arsitektur I yaitu bernilai 0.62 dan arsitektur II (VGG16) yaitu bernilai 0.8. Disimpulkan bahwa hasil proses klasifikasi dengan VGG16 memiliki tingkat akurasi cukup baik dibandingkan dengan arsitektur I.

Kata Kunci — Klasifikasi Citra Bunga, *Deep learning*, *Convolution Neural Network (CNN)*, VGG16

Abstract

Indonesia's biodiversity has a high percentage in Southeast Asia, one of which is the type of flower recorded up to 19,232. The diversity of these types of flowers provides potential for the community from cultural, economic, and ecological values. In everyday life, knowing the type of flower that takes a long time, starting from knowing and then identifying the name of the flower. This learning process is done by asking experts, looking in books and even on the Internet. One way to find out the type of flower quickly is done by classifying image data. This gives the idea of this research, which performs image computation in implementing deep learning for image classification of flower species (daisy, dandelion, rose, sunflower, and tulip). The deep learning method used is CNN (Convolution Neural Network), where architecture I is designed by the author and architecture II is using VGG16. The results of the accuracy value on architecture I is 0.62 feasible and architecture II (VGG16) is feasible 0.8. It is concluded that the results with architecture II (VGG16) have a fairly good level of accuracy compared to the CNN architecture that the author made

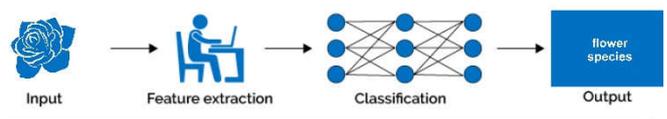
Keywords — Flower Image Classification, *Deep learning*, *Convolution Neural Network (CNN)*, VGG16

I. PENDAHULUAN

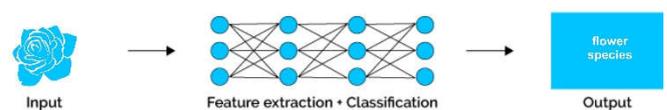
Keanekaragaman hayati, jenis habitat dan ekosistem yang dimiliki oleh Indonesia memiliki persentase tertinggi di Asia Tenggara. Salah satunya yaitu jenis bunga yang tercatat di Indonesia mencapai hingga 19.232. Keanekaragaman jenis bunga memberikan potensi bagi masyarakat dari nilai budaya, ekonomi, maupun ekologi. [1] Realitanya, pada kehidupan sehari-hari mengenal semua jenis bunga akan membutuhkan waktu yang tidak singkat, dimana dimulai dari mengetahui karakteristik pada setiap jenis bunga, kemudian mereka dapat mengidentifikasi nama bunga. Proses belajar tersebut dapat dilakukan dengan bertanya pada pakar, mencari di buku tentang bunga atau mencari di Internet. [2]

Salah satu cara identifikasi jenis bunga dengan cepat yaitu dilakukan dengan klasifikasi data gambar atau citra. Klasifikasi citra khususnya pada bunga merupakan tugas pengolahan citra (*image processing*) pada bidang visi komputer. [3] Dilihat dari potensi ke depannya klasifikasi citra digital jenis bunga dapat memiliki manfaat diberbagai bidang seperti pertanian, bisnis, otomasi, dsb. [4] Zawbaa et al. [2] melakukan sebuah penelitian klasifikasi gambar bunga menggunakan machine learning dengan tahapan segmentasi, ekstraksi, dan klasifikasi. Metode ekstraksi yang digunakan yaitu *Scale Invariant Feature Transform (SIFT)* dan *Segmentation-based Fractal Texture Analysis (SFTA)*. Pada penelitian lain, ekstraksi fitur yang digunakan untuk klasifikasi bunga menggunakan metode *Histogram of Oriented Gradients (HOGs)*. [5] Peninjauan dari beberapa metode ekstraksi fitur yang digunakan akan mempengaruhi hasil dan performa dalam klasifikasi. Bahkan kombinasi dari keduanya antara metode ekstraksi fitur dan klasifikasi akan mempengaruhi hasil yang memiliki performa baik.

Machine Learning



Deep Learning



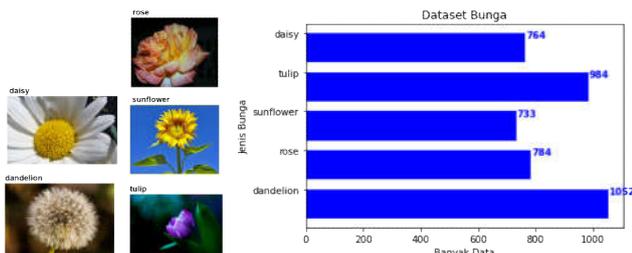
Gbr 1. Ilustrasi konsep *machine learning* dan *deep learning*

Berdasarkan hal tersebut, penulis mencoba melakukan penelitian klasifikasi citra bunga dengan membuat model arsitektur *deep learning*, yaitu arsitektur pada CNN yang memiliki kelebihan dalam hal ekstraksi fitur secara otomatis. Berbeda dengan arsitektur pada *machine learning* yang menggunakan ANN dimana untuk ekstraksi fitur-nya dilakukan secara manual. [6] Pada arsitektur CNN yang diuji coba memiliki dua metode yaitu ekstraksi fitur dan klasifikasi. Arsitektur CNN yang digunakan pada penelitian ini yaitu arsitektur 1 yang dirancang oleh penulis dan Arsitektur 2 menggunakan VGG16. [7] Data citra bunga yang dikelola yaitu 5 jenis bunga terdiri dari daisy, dandelion, rose (mawar), sunflower (matahari), dan tulip.

II. METODE PENELITIAN

A. Data Citra

Pada penelitian ini citra jenis bunga yang diteliti yaitu daisy, dandelion, rose, sunflower, tulip. Dataset yang digunakan yaitu diambil dari website Kaggle: *flowers recognition* (informasi detail dataset yaitu data diambil dari metode scraping dari *flick, google, Yandex*). [8] Jumlah keseluruhan data bunga yaitu 4317 dengan jumlah masing masing jenis bunga yaitu daisy 764 data, tulip terdapat 984 data, sunflower terdapat 733 data, rose terdapat 784 data dan dandelion terdapat 1052 data (Gambar 2). Pada tiap citra memiliki 3 channel model warna yaitu RGB (red, green, blue).



Gbr 2. Dataset Bunga

B. Pre-processing Citra

Pada penelitian ini, proses pre-processing citra dilakukan sebagai berikut:

1. Resize (Mengubah ukuran)

Citra jenis bunga yang digunakan memiliki ukuran resolusi pixel yang berbeda-beda. Sebelum memasuki tahap *feature extraction* pada arsitektur CNN yang digunakan. Dilakukan *resize* ukuran resolusi pixel menjadi 150 x 150. Tujuan dilakukan *resize* untuk input yang digunakan sama jumlahnya.

2. Pembagian Dataset

Pada CNN akan dilakukan pembelajaran (*training*) dan uji (*test*) sehingga kami melakukan pembagian data menjadi dua kategori yaitu data *training* dengan presentasi 80% dan data *testing* dengan presentasi 20%. Pembagian data dilakukan secara acak (*random*) pada tiap jenis bunga.

C. Arsitektur CNN

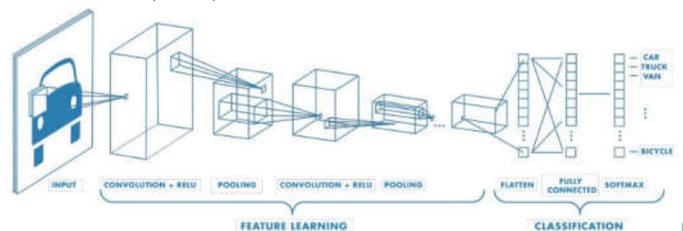
CNN merupakan salah satu metode pada algoritma *deep learning* yang mengimplementasikan jaringan saraf tiruan pada makhluk hidup. Metode yang digunakan pada CNN yaitu metode *backpropagation* (pembelajaran) dan *feedforward* (klasifikasi). [9] Terdapat 2 tahapan atau *layer* yang digunakan pada CNN yaitu tahapan fitur ekstraksi (*feature extraction layer*) dan klasifikasi (*fully connected layer*). Pada umumnya pada *feature extraction layer* terdapat proses konvolusi dan *down sampling* (*pooling*), sedangkan pada *fully connected layer* terdapat proses *flatten*, *hidden layer* dan *output layer*. [10] Pada Gambar 3 merupakan proses mulai dari input hingga output pada metode CNN secara mendetail. [11] Pada artikel ini, terdapat dua model arsitektur yang digunakan, dimana nantinya hasil dari kedua arsitektur akan dibandingkan. Arsitektur pertama yaitu arsitektur yang didesain sendiri oleh penulis (Gambar 5(a)) dan yang kedua yaitu arsitektur VGG16 dari K. Simonyan dan A. Zisserman. [7] (Gambar 5(b)).

Arsitektur pertama yaitu desain arsitektur sendiri, dimana pada *feature extraction layer* terdapat 4 tahapan yaitu dua kali proses konvolusi dan *down sampling*. Pada konvolusi dilakukan fungsi aktivasi dengan menggunakan ReLU dan tahap *down sampling*-nya menggunakan *max pooling*. Pada *fully connected layer* terdapat 3 tahapan yaitu *flatten*, 1 *dense/hidden layer* kemudian *layer output*. Setelah proses *dense/hidden layer* ditambahkan proses fungsi aktivasi dengan ReLU dan pada tahap *layer output* ditambahkan proses fungsi aktivasi dengan SoftMax. Penjelasan detail pada arsitektur pertama yang dirancang sendiri diilustrasikan pada Gambar 4.

Arsitektur kedua yaitu VGG16, dimana pada *feature extraction layer* terdapat 5 kali proses konvolusi dan *down sampling*. Pada tahapan 1 dan 2 proses konvolusi dilakukan 2 kali sedangkan pada tahapan berikutnya konvolusi dilakukan 3 kali. Pada konvolusi arsitektur ini dilakukan fungsi aktivasi dengan ReLU dan *down sampling*-nya dengan menggunakan *max pooling*. Pada *fully connected layer* dua kali proses *dense/hidden layer* dengan tiap ditambahkan fungsi aktivasi dengan ReLU dan kemudian di tahapan akhir *layer output* dengan menambahkan fungsi aktivasi dengan SoftMax.

Penjelasan mendetail pada bagian-bagian di dalam *feature extraction layer* dan *fully connected layer* pada arsitektur CNN yang digunakan:

- Konvolusi menggunakan kernel 3x3 dengan layer filter yang sama tiap prosesnya (*weight sharing*). Padding yang digunakan 1 pixel pada tiap tepi citra dengan nilai nol/zero (*same*).

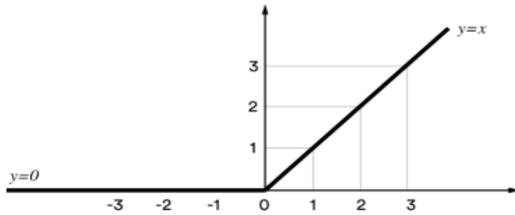


Gbr 3. Contoh desain arsitektur [11]

Stride atau pergeseran konvolusi menggunakan 1 pixel secara horizontal dan vertikal. Persamaan konvolusi yaitu pada persamaan 1.

$$conv(I, C)_{xy} = \sum_{i=1}^{M_H} \sum_{j=1}^{M_W} \sum_{k=1}^{M_C} C_{i,j,k} I_{x+i-1, y+j-1, k} \quad (1)$$

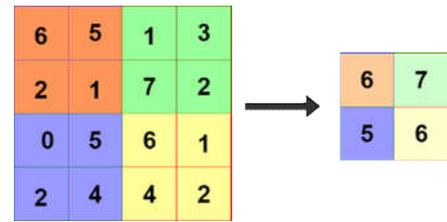
- Fungsi aktivasi yang dilakukan pada konvolusi dan hidden layer yaitu dengan ReLU (Rectified Linear Unit) Detail deskripsi tertera pada Persamaan 2 dan Gambar 4.



Gbr 4. Grafik ReLU (Rectified Linier Unit)

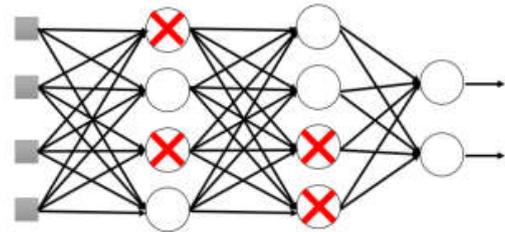
$$f(x) = \max(0, x) \quad (2)$$

- Down sampling menggunakan max-pooling dengan ukuran kernel 2x2. Stride atau pergeseran pixel-nya yaitu 2. Kegunaan untuk mengatasi overfitting dan mempercepat proses komputasi. Ilustrasi kinerja dideskripsikan pada Gambar 5



Gbr 5. Max-pooling

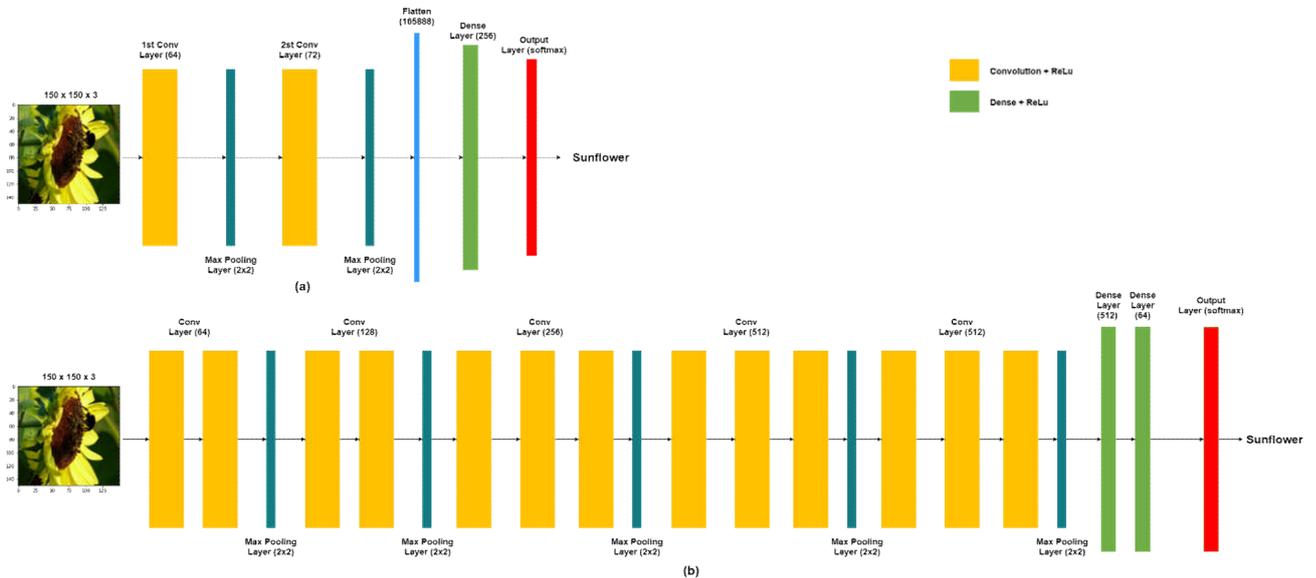
- Pada tahap kalsifikasi VGG16 dilakukan proses dropout, dimana proses ini yaitu untuk me-regulasi parameter dengan tujuan terhindar dari overfitting (Gambar 6).



Gbr 6. Dropout

- Fungsi aktivasi yang ditambahkan pada layer output yaitu fungsi aktivasi SoftMax yang bertujuan untuk meningkatkan probabilitas dalam klasifikasi kelas (jenis citra bunga) (Persamaan 3).

$$s(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (3)$$

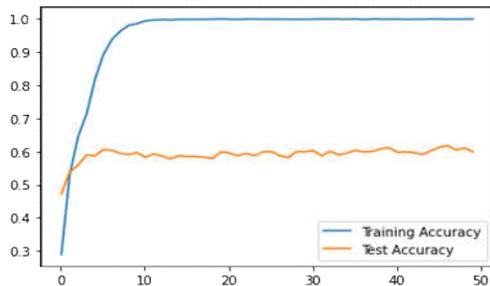


Gbr 7. Arsitektur CNN pada klasifikasi bunga (a) dirancang penulis (b) VGG16

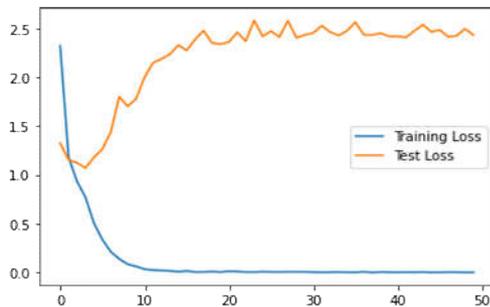
III. HASIL DAN ANALISA

Hasil *training* dan uji coba (*testing*) pada dataset citra jenis bunga dengan arsitektur pada CNN diproses iterasi (*epoch*) sebanyak 50 kali. Pada arsitektur pertama yang di rancangan oleh penulis menunjukkan hasil akurasi yaitu 0.62 dan nilai *loss* yaitu 2.5. Pada Gambar 8 dan 9 menyatakan bahwa hasil grafik menunjukkan *overfitting*, dilihat dari kurva performa pelatihan lebih baik dibandingkan dengan kurva performa validasi, seta model kurva yang sangat rentang.

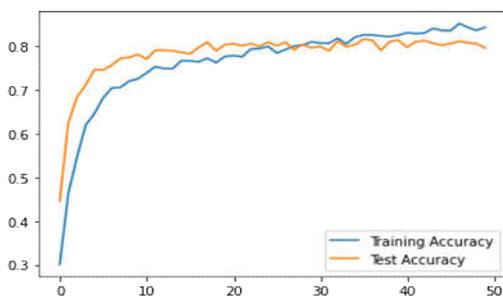
Hasil yang ditunjukkan pada arsitektur II (VGG16) nilai akurasi yaitu 0.8 dan nilai *loss* yaitu 0.52. Pada Gambar 10 dan 11 menyatakan hasil yang lebih baik dibandingkan dengan arsitektur pertama. Pada grafik akurasi dapat dilihat bahwa arsitektur II dengan menggunakan arsitektur VGG16 menunjukkan telah mempelajari dataset dengan cukup baik dan sebanding pada kedua hasil data (data uji dan testing/validasi).



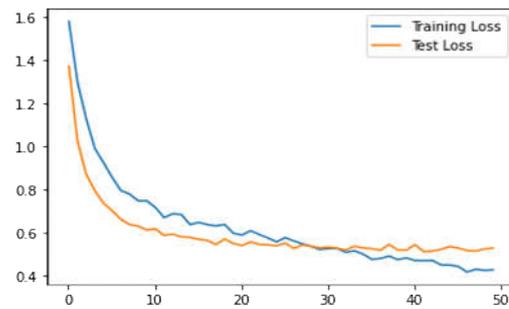
Gbr 8. Grafik akurasi arsitektur 1



Gbr 9. Grafik loss arsitektur 1



Gbr 10. Grafik akurasi arsitektur 2 (VGG16)



Gbr 11. Grafik loss arsitektur 1 (VGG16)

IV. KESIMPULAN (PENUTUP)

Kesimpulan pada penelitian ini, dalam penggunaan *deep learning* dengan CNN pada citra jenis bunga sangat dipengaruhi oleh arsitektur yang dipilih atau digunakan. Hasil menyatakan ketika dilakukan iterasi sebanyak 50 kali pada Arsitektur I nilai akurasi-nya yaitu 0.62 sedangkan arsitektur II dengan menggunakan VGG16 memiliki akurasi 0.8 dan dari dinyatakan lebih baik dibandingkan dengan arsitektur I.

REFERENSI

- [1] D. J. Middleton *et al.*, "Progress on Southeast Asia's Flora projects," *Gard. Bull. Singapore*, vol. 71, no. 2, pp. 267–319, 2019, doi: 10.26492/gbs71(2).2019-02.
- [2] H. M. Zawbaa, M. Abbass, S. H. Basha, M. Hazman, and A. E. Hassenian, "An automatic flower classification approach using machine learning algorithms," in *2014 International conference on advances in computing, communications and informatics (ICACCI)*, 2014, pp. 895–901.
- [3] A. Peryanto, A. Yudhana, and R. Umar, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," *Format J. Ilm. Tek. Inform.*, vol. 8, no. 2, p. 138, 2020, doi: 10.22441/format.2019.v8.i2.007.
- [4] P. Rosyani and Oke Hariansyah, "Pengenalan Citra Bunga Menggunakan Segmentasi Otsu Treshold dan Naïve Bayes," *J. Sist. dan Inform.*, vol. 15, no. 1, pp. 1–7, 2020, doi: 10.30864/jsi.v15i1.304.
- [5] A. Angelova and S. Zhu, "Efficient object detection and segmentation for fine-grained recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 811–818, 2013, doi: 10.1109/CVPR.2013.110.
- [6] E. Sperling, "Deep Learning Spreads," *Semiconductor Engineering*, 2018. <https://semiengineering.com/deep-learning-spreads/>.
- [7] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
- [8] A. Mamaev, "Flowers Recognition," *kaggle*, 2021. <https://www.kaggle.com/alxmamaev/flowers-recognition/activity>.
- [9] N. Kalchbrenner, E. Grefenstette, and P. Blunsom, "A convolutional neural network for modelling sentences," *52nd Annu. Meet. Assoc. Comput. Linguist. ACL 2014 - Proc. Conf.*, vol. 1, pp. 655–665, 2014, doi: 10.3115/v1/p14-1062.
- [10] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," in *2017 International Conference on Engineering and Technology (ICET)*, 2017, pp. 1–6.
- [11] "How CNNs Work," *mathwork*. <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>.

