

## IMPLEMENTATION OF DEEP LEARNING ON FLOWER CLASSIFICATION USING CNN METHOD

Anggun Pratiwi<sup>\*1</sup>, Ahmad Fauzi<sup>\*2</sup>

<sup>1,2</sup>Information Systems And Technology Education, Universitas Pendidikan Indonesia, Indonesia  
Email: <sup>1</sup>[anggunpratiwi@upi.edu](mailto:anggunpratiwi@upi.edu), <sup>2</sup>[ahmad.fauzi.upi.edu](mailto:ahmad.fauzi.upi.edu)

(Article received: January 5, 2024; Revision: January 30, 2024; Published: April 04, 2024)

### Abstract

Technological developments in the field of artificial intelligence, particularly deep learning, have made significant contributions to various applications, including pattern recognition and object classification in visual images. One of the interesting applications of deep learning is image classification, where these techniques have proven effective in tackling complex problems, such as object recognition in visual images. Flowering plants, with approximately 369,000 known species, are an interesting object of study. In an effort to classify different types of flowers quickly and efficiently, a digital approach is a must. This research aims to implement deep learning technology, especially CNN method, in flower classification. One method that can be used is Convolutional Neural Network (CNN), a deep learning algorithm that is able to process image information well. In flower type classification, supervised learning techniques are essential. By giving the label (flower type) to the algorithm as the basis of truth, the use of CNN on a large scale can produce predictions and classifications with a high level of accuracy. This research produces a classification model that is more precise and able to overcome variations in flower morphology with 2 different datasets namely Oxford17 resulting in 84% accuracy and oxford102 resulting in an accuracy value of 64%.

**Keywords:** CNN, Deep Learning, Flower Classification

## IMPLEMENTASI DEEP LEARNING PADA PENGKLASIFIKASIAN BUNGA DENGAN MENGGUNAKAN METODE CNN

### Abstrak

Pengembangan teknologi di bidang kecerdasan buatan, khususnya *deep learning*, telah memberikan kontribusi signifikan pada berbagai aplikasi, termasuk pengenalan pola dan klasifikasi objek dalam citra visual. Salah satu aplikasi menarik dari *deep learning* adalah pengklasifikasian gambar, di mana teknik-teknik ini telah terbukti efektif dalam menangani masalah kompleks, seperti pengenalan objek pada citra visual. Tanaman berbunga, dengan sekitar 369.000 spesies yang diketahui, merupakan objek studi yang menarik. Dalam upaya mengklasifikasikan berbagai jenis bunga dengan cepat dan efisien, pendekatan digital menjadi suatu keharusan. Penelitian ini bertujuan mengimplementasikan teknologi *deep learning*, terutama metode CNN, dalam pengklasifikasian bunga. Salah satu metode yang dapat digunakan adalah *Convolutional Neural Network (CNN)*, sebuah *algoritma deep learning* yang mampu mengolah informasi citra dengan baik. Pada pengklasifikasian jenis bunga, teknik supervised learning menjadi esensial. Dengan memberikan label (jenis bunga) kepada *algoritma* sebagai dasar kebenaran, penggunaan CNN dalam skala besar dapat menghasilkan prediksi dan klasifikasi dengan tingkat akurasi yang tinggi. Penelitian ini menghasilkan model klasifikasi yang lebih presisi dan mampu mengatasi variasi morfologi bunga dengan 2 *dataset* yang berbeda yaitu Oxford17 menghasilkan akurasi 84% dan oxford102 menghasilkan nilai akurasi 64%.

**Kata kunci:** CNN, Deep Learning, Pengklasifikasian Bunga

### 1. PENDAHULUAN

Kemajuan teknologi dalam bidang kecerdasan buatan, terutama dalam *deep learning*, telah menjadi pendorong utama transformasi pada berbagai sektor, mulai dari

industri hingga riset akademis [1]. Salah satu aspek yang paling mencolok adalah kemampuan *deep learning* dalam pengenalan pola dan klasifikasi objek, yang telah mengubah cara kita berinteraksi dengan data visual[2]. Dalam

pengklasifikasian gambar, *deep learning* telah menjadi solusi yang sangat efektif dan efisien, terutama ketika dihadapkan pada tugas-tugas yang memerlukan pemahaman kontekstual yang mendalam dan kemampuan adaptasi terhadap variasi yang kompleks. Melalui teknik-teknik yang berkembang dalam *deep learning*, seperti *convolutional neural networks (CNN)*, model-model dapat belajar secara mandiri untuk mengidentifikasi fitur-fitur penting dari gambar, memungkinkan mereka untuk mengenali objek-objek dengan tingkat akurasi yang tinggi. Hal ini sangat berguna dalam berbagai aplikasi praktis, termasuk deteksi objek pada tumbuhan salah satunya bunga [3].

Bunga atau kembang (bahasa Latin: *flos*) adalah alat reproduksi seksual pada tumbuhan berbunga. Ada sekitar 391.000 spesies tanaman vaskular yang saat ini diketahui sains, dimana sekitar 369.000 spesies adalah tanaman berbunga, menurut sebuah laporan oleh Royal Botanic Gardens, Kew, di Inggris [4]. Selain itu bunga dapat dikatakan sebagai alat perkembangbiakan genetik tumbuhan biji tertutup. Setiap jenis bunga memiliki struktur yang berbeda sesuai dengan fungsi yang dimilikinya[5].

Mengetahui banyaknya jenis bunga yang telah ditemukan, diperlukan adanya pendekatan digital agar dapat mengklasifikasi berbagai jenis bunga dengan mudah dan cepat. Klasifikasi adalah salah satu teknik dalam membedakan sebuah objek[6]. Salah satu cara klasifikasi adalah dengan menggunakan *Convolutional Neural Network*, yang merupakan salah satu metode *Deep Learning* yang memiliki kemampuan mengolah informasi citra[7].

Untuk dapat mengklasifikasi jenis bunga dari semua *input* (citra bunga) dengan *machine learning*, maka dibutuhkan teknik *supervised learning*. *supervised learning* adalah algoritma yang bergantung pada data input berlabel untuk mempelajari fungsi yang menghasilkan output yang sesuai ketika diberi data baru tanpa label[8][9]. Dalam teknik *supervised learning*, label (jenis bunga) diberikan kepada algoritma sebagai dasar kebenaran [10]. *Machine learning* sendiri adalah kemampuan komputer untuk melakukan pembelajaran dari pengalaman sesuai dengan tugas yang diberikan dengan kinerja yang terukur[11]. Dengan memanfaatkan *Convolutional Neural Network* dalam skala besar, dapat menghasilkan prediksi maupun klasifikasi dengan akurasi yang tinggi[12].

Salah satu tantangan dalam pengklasifikasian objek pada citra adalah gambaran perbedaan karakteristik antara objek yang berbeda[13]. Dalam konteks ini, pengklasifikasian bunga menjadi salah satu domain yang menarik,

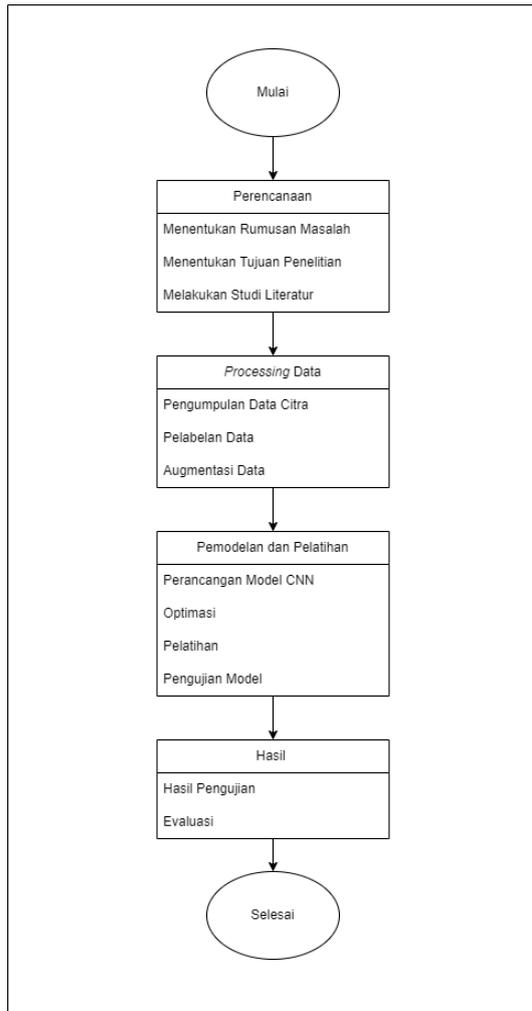
mengingat keragaman dan kompleksitas morfologi bunga yang dapat ditemui. Dalam upaya untuk meningkatkan akurasi pengklasifikasian bunga, metode-metode yang lebih canggih perlu diterapkan [14].

Salah satu metode *deep learning* yang telah terbukti berhasil dalam pengenalan pola pada citra adalah *Convolutional Neural Network (CNN)*. *CNN* secara khusus dirancang untuk mengekstrak fitur-fitur hierarkis dari data visual, membuatnya sangat sesuai untuk pengolahan gambar, termasuk dalam konteks pengklasifikasian bunga[15].

Penelitian ini bertujuan untuk mengimplementasikan teknologi *deep learning*, khususnya metode *CNN*, dalam pengklasifikasian bunga. Melalui pendekatan ini, diharapkan dapat diperoleh model klasifikasi yang lebih presisi dan dapat menangani variasi morfologi bunga dengan lebih baik. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi pada pengembangan sistem pengklasifikasian bunga yang dapat diaplikasikan dalam berbagai konteks, seperti konservasi tumbuhan, pertanian, dan bidang lainnya.

## 2. METODE PENELITIAN

Metode yang digunakan dalam klasifikasi bunga tersebut mengacu pada pendekatan berbasis citra yang memanfaatkan teknik-teknik pemrosesan gambar dan *machine learning*, seperti *Convolutional Neural Networks (CNN)*, untuk membedakan dan mengidentifikasi jenis-jenis bunga berdasarkan ciri-ciri visualnya[16]. Adapun alur penelitian yang digambarkan pada gambar 1.



Gambar 1. Alur Penelitian

### 2.1 Tahap Perencanaan

Dalam fase perencanaan, terdapat tiga langkah utama yang perlu dijalani. Pertama, merumuskan dengan cermat permasalahan yang akan menjadi fokus penelitian, tujuannya adalah untuk mengarahkan dan membatasi ruang lingkup penelitian yang akan dilakukan. Kedua, menetapkan tujuan penelitian sebagai langkah untuk mencapai hasil yang diinginkan dari penelitian tersebut. Ketiga, melakukan studi literatur dengan maksud untuk mengumpulkan referensi yang mendukung penelitian, memastikan bahwa penelitian dilakukan dengan landasan yang kuat dan sesuai.

### 2.2 Processing Data

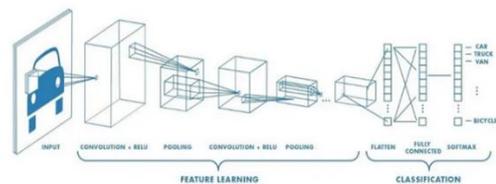
Tahapan *processing* terhadap data citra dilakukan dengan melakukan pengumpulan data (*gathering*), pelabelan citra, perubahan ukuran pixel pada citra (*resize*), dan melakukan *augmentasi* pada citra dari keseluruhan citra *training*[17].

### 2.3 Pemodelan dan Pelatihan

*Convolutional Neural Network* (CNN) merupakan pengembangan dari *Multilayer*

*Perceptron* (MLP) yang dirancang khusus untuk mengolah data dua dimensi. Sebagai bagian dari jenis *Deep Neural Network*, CNN menonjol karena kedalaman jaringannya yang tinggi dan keberhasilannya dalam pengolahan data citra. Penerapan CNN dalam klasifikasi objek pada citra telah terbukti melebihi metode *Machine Learning* lainnya, seperti *Support Vector Machine* (SVM)[18].

CNN memiliki arsitektur yang dirancang untuk mengekstrak pola dan fitur dari data citra dengan cara yang sangat efektif. Keberhasilannya dapat diatribusikan pada beberapa fitur khususnya, termasuk lapisan konvolusi yang dapat menangkap informasi lokal pada citra, lapisan *pooling* yang membantu mengurangi dimensi data, dan lapisan *fully connected* yang mengintegrasikan informasi dari seluruh citra seperti pada gambar 2.



Gambar 2. Arsitektur pada CNN

Berbeda dengan MLP yang umumnya digunakan untuk data yang bersifat tabular atau vektor, CNN dirancang khusus untuk menangani struktur data dua dimensi seperti citra. Kemampuan CNN dalam menangkap fitur *hierarkis* dari data citra membuatnya sangat efektif dalam tugas-tugas klasifikasi objek pada citra[19].

Dalam beberapa kasus, CNN telah berhasil mengungguli metode *Machine Learning* tradisional, seperti SVM, terutama dalam konteks klasifikasi objek pada citra. Keberhasilan ini telah membuat CNN menjadi pilihan utama dalam berbagai aplikasi yang melibatkan pengolahan citra, seperti pengenalan wajah, klasifikasi objek pada gambar, dan deteksi pola visual lainnya. Dengan terus berkembangnya teknologi, CNN terus menjadi fokus utama dalam penelitian dan pengembangan di bidang pengolahan citra dan pembelajaran mesin.

### 2.4 Hasil

Setelah menyelesaikan pengujian, langkah berikutnya adalah menampilkan hasil pengujian yang telah dilakukan dan melakukan evaluasi

akurasi. Perhitungan akurasi bertujuan untuk menilai sejauh mana keberhasilan Model CNN dalam mengklasifikasi Citra. Akurasi menjadi parameter penting untuk membandingkan hasil dan merencanakan pengembangan di masa depan.

$$Akurasi = \frac{Benar}{Jumlah Sampel} \times 100\%$$

### 3. HASIL DAN PEMBAHASAN

#### 3.2 Processing Data

##### 3.2.1 Pengumpulan Data Citra

Data pertama adalah oxford17 yang terdiri atas 17 jenis tanaman bunga (*Daffodil, Snowdrop, Lily Valley, Bluebell, Crocus, Tigerlily, Tulip, Fritillary, Sunflower, Daisy, Colts Foot, Dandelion, Cowslip, Buttercup, Windflower, Pansy*) dan masing-masing jenis berjumlah sekitar 80 gambar, sehingga total terdapat 1.360 data gambar. Contoh citra gambar bunga dapat dilihat pada gambar 3.



Gambar 3. Oxford 17

Serta data yang kedua adalah oxford102 yang memiliki 102 jenis bunga dan setiap jenis terdiri atas 40 sampai 258 gambar. *Dataset* ini memiliki total data 8.189 gambar. Contoh citra gambar bunga dapat dilihat pada gambar 4. Terdiri atas: *pink primrose, hard-leaved pocket orchid, canterbury bells, sweet pea, english marigold, tiger lily, moon orchid, bird of paradise, monkshood, globe thistle, snapdragon, colts foot, king protea, spear thistle, yellow iris, globe-flower, purple coneflower, peruvian lily, balloon flower, giant white arum lily, fire lily, pincushion flower, fritillary, red ginger, grape hyacinth, corn poppy, prince of wales feathers, stemless gentian, artichoke, sweet william, carnation, garden phlox, love in the mist, mexican aster, alpine sea holly, ruby-lipped cattleya, cape flower, great masterwort, siam tulip, lenten rose, barbeton daisy, daffodil, sword lily, poinsettia, bolero*

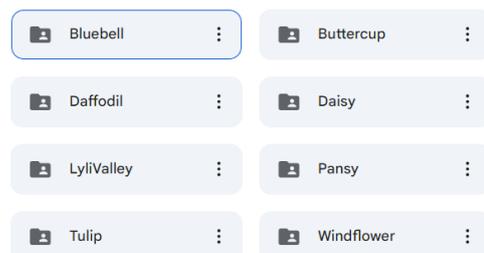
*deep blue, wallflower, marigold, buttercup, oxeye daisy, common dandelion, petunia, wild pansy, primula, sunflower, pelargonium, bishop of llandaff, gaura, geranium, orange dahlia, pink-yellow dahlia, cautleya spicata, japanese anemone, black-eyed susan, silverbush, californian poppy, osteospermum, spring crocus, bearded iris, windflower, tree poppy, gazania, azalea, water lily, rose, thorn apple, morning glory, passion flower, lotus, toad lily, anthurium, frangipani, clematis, hibiscus, columbine, desert-rose, tree mallow, magnolia, cyclamen, watercress, canna lily, hippeastrum, bee balm, ball moss, foxglove, bougainvillea, camellia, mallow, mexican petunia, bromelia, blanket flower, trumpet creeper, blackberry lily).*



Gambar 4. Oxford 102

##### 3.2.2 Pelabelan Data

Proses pemberian label pada data berfungsi untuk memberikan nama terhadap data untuk dapat dikenali seperti yang terlihat pada gambar 4. Peneliti membuat dua folder utama yaitu *folder train* dan *folder test / validation*[3]. *Folder train* berfungsi untuk menaruh data untuk diproses pada proses pembelajaran[20], sedangkan *folder test / validation* berfungsi untuk memvalidasi data pada proses *training*[21]. Pada setiap *subfolder* diberi nama bunga dan diisi dengan data sesuai namanya seperti pada gambar 5. Perbandingan jumlah data pada *folder train* berjumlah 80% dan *folder test* atau *validation* sebesar 20% dari jumlah data.



Gambar 5. Contoh pelabelan gambar

### 3.2.3 Augmentasi Data

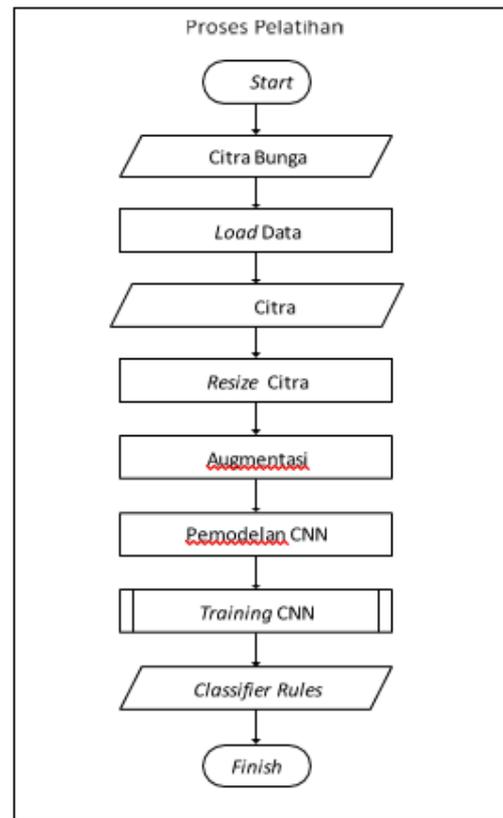
Proses *agumentasi* terhadap data citra bunga untuk proses *training* dilakukan untuk mencegah terjadinya *overfitting* (memiliki kinerja baik selama pelatihan, tetapi buruk pada data baru)[22]. Pengaturan *augmentasi* data citra secara otomatis yang berfungsi untuk membalik secara *vertikal* citra gambar dengan acak, di atur dengan nilai benar. Sehingga akan menghasilkan citra gambar yang lebih beragam seperti yang ditunjukkan pada gambar 6.



Gambar 6. Contoh *Augmentasi* gambar

### 3.3 Pemodelan dan Pelatihan

Dalam pembuatan model atau pemodelan terdiri atas beberapa proses, untuk model klasifikasi bunga membutuhkan *input* citra bunga, sebagai sumber data pembelajaran. Data citra yang dimuat ke dalam dua variabel, yaitu citra *training* dan citra *validasi*, dan pada masing-masing citra dilakukan perubahan ukuran citra menjadi  $224 \times 224$  *pixel*. Pada data citra terjadi proses *augmentasi* data untuk menghasilkan model dengan kinerja yang baik, menghindari *overfitting*, dan memperkaya data citra *training*[23]. Tahapan selanjutnya adalah perancangan model, pada penelitian ini menggunakan model CNN seperti pada gambar 7. Setelah tahap perancangan model CNN, kemudian dilakukan *training* untuk menghasilkan model (*classifier rules*) yang dapat mengklasifikasikan bunga.



Gambar 7. *Flowchart* Pemodelan CNN

#### 3.3.1 Optimasi

Proses pelatihan memerlukan beberapa pengaturan, penggunaan *loss function categorical crossentropy* karena data pelatihan berbentuk kategori, sehingga pengevaluasian *loss* dilakukan berdasarkan kategori data. Penelitian ini menggunakan optimasi Nadam, penggunaan optimasi Nadam dipilih karena optimasi ini lebih efisien dan efektif serta tidak menggunakan banyak sumber daya. Metrik yang digunakan dalam penelitian ini adalah akurasi.

#### 3.3.2 Pelatihan

Untuk mengatur jalannya proses pelatihan diperlukan pengaturan pelatihan. Pengaturan pelatihan bertujuan untuk mendapatkan model terbaik secara efisien dan efektif. Pada proses pelatihan terhadap *dataset* terjadi pengulangan (*epoch*) beberapa kali untuk mendapatkan kinerja model yang paling maksimal, pada setiap kali pengulangan nilai akurasi dapat naik dan turun, maka untuk mendapatkan nilai terbaik dibutuhkan fungsi *checkpoint*. *Checkpoint* di set untuk hanya menyimpan model dengan nilai *loss error* terendah, nilai *loss function* yang rendah berbanding lurus dengan tingkat akurasi yang dimiliki model seperti pada gambar 8.

```

Epoch 1/10
34/34 [=====] - 51s 2s/step - loss: 0.7902 - accuracy: 0.7243 - val_loss: 1.1867 - val_accuracy: 0.6397
Epoch 2/10
34/34 [=====] - 41s 1s/step - loss: 0.7507 - accuracy: 0.7417 - val_loss: 1.3183 - val_accuracy: 0.5993
Epoch 3/10
34/34 [=====] - 42s 1s/step - loss: 0.7306 - accuracy: 0.7491 - val_loss: 1.0897 - val_accuracy: 0.6618
Epoch 4/10
34/34 [=====] - 41s 1s/step - loss: 0.7094 - accuracy: 0.7693 - val_loss: 1.3588 - val_accuracy: 0.6029
Epoch 5/10
34/34 [=====] - 40s 1s/step - loss: 0.6752 - accuracy: 0.7822 - val_loss: 1.0877 - val_accuracy: 0.6618
Epoch 6/10
34/34 [=====] - 42s 1s/step - loss: 0.6335 - accuracy: 0.7794 - val_loss: 1.1685 - val_accuracy: 0.6765
Epoch 7/10
34/34 [=====] - 40s 1s/step - loss: 0.5678 - accuracy: 0.8051 - val_loss: 1.2880 - val_accuracy: 0.6434
Epoch 8/10
34/34 [=====] - 42s 1s/step - loss: 0.5326 - accuracy: 0.8171 - val_loss: 1.1907 - val_accuracy: 0.6507
Epoch 9/10
34/34 [=====] - 41s 1s/step - loss: 0.5432 - accuracy: 0.8088 - val_loss: 1.1800 - val_accuracy: 0.6985
Epoch 10/10
34/34 [=====] - 41s 1s/step - loss: 0.4974 - accuracy: 0.8272 - val_loss: 1.2638 - val_accuracy: 0.6728
    
```

Gambar 8. Epoch Pemodelan CNN

Dalam proses pelatihan *layer* pertama dalam CNN adalah input *layer*, pada input *layer* menerima masukan citra gambar dengan tiga atribut, yaitu panjang citra (*pixel*), lebar citra (*pixel*) dan *channel* warna (RGB atau *grayscale*). Sebagai contoh diambil salah satu data citra untuk pelatihan dan labelnya yaitu *sunflower* yang dapat dilihat pada gambar 9.



Gambar 9. Salah satu data citra oada Input Layer

Ketika memasukkan contoh gambar *sunflower* ke dalam program, program akan mempelajari karakteristik gambar tersebut, termasuk warna,

bentuk, dan polanya. Program kemudian akan menggunakan informasi ini untuk mendeteksi *sunflower* pada gambar lain. Dalam kasus ini, program berhasil mendeteksi *sunflower* karena telah dilatih dengan contoh gambar *sunflower* yang cukup banyak. Contoh gambar ini membantu program untuk mempelajari karakteristik *sunflower* yang khas, seperti warna kuningnya yang cerah dan bentuk kepala bunganya yang besar.

Pada tahap deteksi, program akan membandingkan gambar yang ingin dideteksi dengan karakteristik *sunflower* yang telah dipelajarinya. Jika ada kesamaan, maka program akan menyimpulkan bahwa gambar tersebut adalah *sunflower*. Dalam kasus ini, program berhasil mendeteksi *sunflower* karena telah dilatih dengan contoh gambar *sunflower* yang cukup banyak. Contoh gambar ini membantu program untuk mempelajari karakteristik *sunflower* yang khas, seperti warna kuningnya yang cerah dan bentuk kepala bunganya yang besar. Hasil deteksi dapat dilihat pada gambar 10 berikut.

'Bluebell': 0, 'Buttercup': 1, 'ColtsFoot': 2, 'Cowslip': 3, 'Crocus': 4, 'Daffodil': 5, 'Daisy': 6, 'Dandelion': 7, 'Fritillary': 8, 'Iris': 9, 'LilyValley': 10, 'Pansy': 11, 'Snowdrop': 12, 'Sunflower': 13, 'Tigerlily': 14, 'Tulip': 15, 'Windflower': 16

```

[ ] import numpy as np

from google.colab import files
from keras.preprocessing import image

uploaded=files.upload()

Pilih File Tidak ada file yang dipilih Upload widget is only available when the cell has been executed in the current browser session. Please rerun this cell to enable.
Saving image_0750.jpg to image_0750.jpg

for fn in uploaded.keys():

    # predicting images
    path='./content/' + fn
    img=image.load_img(path, target_size=(180, 180))

    x=image.img_to_array(img)
    test_img=np.expand_dims(x, axis=0)

    result = model.predict(test_img)
    pred = np.argmax(result) # get the index of max value

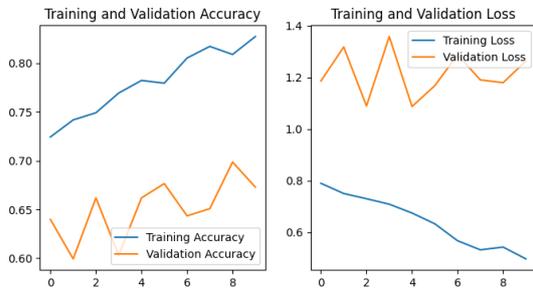
    print(pred)

1/1 [=====] - 0s 66ms/step
13
    
```

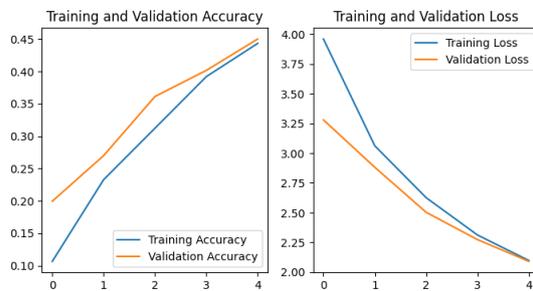
Gambar 10. Hasil Pelatihan Sunflower

### 3.3.3 Pengujian Model

Pada pengujian model menghasilkan *accuracy* dan juga *loss* yang terlihat pada gambar 11 dan 12. Pada awalnya, nilai *loss* masih tinggi dan *accuracy* masih rendah. Ini karena model masih dalam proses pembelajaran dan belum mempelajari karakteristik bunga dengan baik. Seiring berjalannya waktu, nilai *loss* semakin turun dan *accuracy* mulai naik. Ini karena model semakin mempelajari karakteristik bunga dan semakin mampu membuat prediksi yang benar. Pada akhirnya, nilai *loss* mencapai titik minimum dan nilai *accuracy* mencapai titik maksimum. Ini menunjukkan bahwa model telah mencapai kinerja optimal dan dapat membedakan antara gambar bunga yang satu dengan gambar bunga lainnya dengan sangat baik. Berikut merupakan gambar hasil pengujian *dataset* oxford17 pada gambar 11 dan oxford102 pada gambar 12.



Gambar 11. Grafik Accuracy dan Loss Oxford17



Gambar 12. Grafik Accuracy dan Loss Oxford102

### 3.4 Hasil Pengujian

Setelah menyelesaikan pengujian, langkah berikutnya adalah melakukan evaluasi akurasi. Perhitungan akurasi bertujuan untuk menilai sejauh mana keberhasilan Model CNN dalam mengklasifikasi Citra. Akurasi menjadi parameter penting untuk membandingkan hasil dan merencanakan pengembangan di masa depan.

Untuk menghitung nilai akurasi menggunakan sample testing sebanyak 100 sample bunga sesuai dengan *dataset* yang berbeda. Dengan perhitungan banyak salah dibagi banyak sample yang digunakan. Seperti yang terlihat pada tabel 1 dan 2.

#### 3.4.1 Oxford17

Tabel 1. Hasil Pengujian Oxford17

Pengujian Oxford17	
Benar	Salah
84	8

$$Akurasi = \frac{84}{100} \times 100\% = 84\%$$

#### 3.4.2 Oxford102

Tabel 2. Hasil Pengujian Oxford102

Pengujian Oxford102	
Benar	Salah
64	36

$$Akurasi = \frac{64}{100} \times 100\% = 64\%$$

## 4. DISKUSI

Berdasarkan dari proses pengujian *Convolutional Neural Network* untuk klasifikasi jenis bunga dengan total 119 jenis bunga didapatkan hasil akurasi sebagai nilai untuk perbandingan dengan metode *Support Vector Machine* (SVM) dan *Artificial Neural Network* (ANN) pada *Convolutional Neural Network* dengan menggunakan metode lebih unggul dengan nilai akurasi 84% jika dibandingkan dengan model SVM pada penelitian Albadarneh & Ahmad yang memiliki nilai akurasi 83.52% dan model ANN mendapatkan nilai akurasi 72% yang dibuat Firmansyah [24]. Data *preprocessing* terhadap citra bunga pada metode SVM menggunakan teknik *region growing segmentation*, yaitu memisahkan objek bunga dari latar belakangnya.

Sedangkan bila dibandingkan dengan ANN dan SVM untuk *dataset* Oxford102 model CNN mendapatkan nilai akurasi sebesar 64%. ANN pada penelitian tersebut menggunakan HSV *color descriptor*, Gray Level Co-occurrence Matrix (GLCM) dan *Invariant Moments* pada tahapan *data preprocessing* untuk memisahkan objek bunga dengan latar belakangnya[25].

Model CNN memiliki keunggulan dalam hal akurasi untuk model yang dilatih secara singkat. Dapat menghasilkan model dengan akurasi yang tinggi dengan waktu yang singkat (hanya dengan beberapa *epoch*) dibandingkan dengan model CNN yang dilatih dari dasar dengan jumlah *epoch* yang sama. Selain itu, semakin banyak jumlah jenis atau kelas maka hasil klasifikasi yang diperoleh semakin

tidak baik atau buruk, hal ini dibuktikan dengan kasus klasifikasi oxford17 yang memiliki 17 jenis bunga memiliki nilai akurasi yang lebih baik (84%) dibandingkan dengan klasifikasi oxford102 yang memiliki jenis bunga sebanyak 102 jenis (64%), keduanya menggunakan model yang sama.

Tabel 3. Hasil perbandingan metode CNN dengan SVM dan ANN

Dataset	Metode		
	CNN	SVM	ANN
Oxford17	84%	83.5%	72%
Oxford102	64%	32.4%	81.19%

## 5. KESIMPULAN

Berdasarkan hasil-hasil pembuatan dan pengujian model *deep learning* dengan *convolutional neural network* pada penelitian ini, menghasilkan prediksi klasifikasi jenis bunga dari dua *dataset* yang berbeda yaitu oxford17 dan oxford102. Penelitian ini menghasilkan *system* pengujian untuk mengklasifikasikan bunga berdasarkan model. Pengujian dilakukan dengan memasukan 100 data bunga dengan mencatat hasil akurasinya. Dari hasil pengujian didapatkan bahwa kinerja model CNN ini untuk mengklasifikasikan bunga pada oxford17 mendapatkan akurasi 84%. Sedangkan untuk bunga pada oxford102 mendapatkan hasil akurasi sebesar 64%.

## UCAPAN TERIMA KASIH

Ucapan terima kasih penulis sampaikan kepada Kemendikbudrustek atas kesempatannya dalam mengikuti KMII *Artificial Intelligence* di Universitas Padjajaran dan Bapak Ahmad Fauzi yang telah membantu dalam penulisan ini.

## DAFTAR PUSTAKA

- [1] K. Marlin, E. Tantrisa, B. Mardikawati, R. Anggraini, E. Susilawati, and M. Yunus Batusangkar, "Manfaat dan Tantangan Penggunaan Artificial Intelligences (AI) Chat GPT Terhadap Proses Pendidikan Etika dan Kompetensi Mahasiswa Di Perguruan Tinggi," *Innov. J. Soc. Sci. Res.*, vol. 3, no. 6, pp. 5192–5201, 2023.
- [2] S. R. Dewi, "Deep Learning Object Detection Pada Video," *Deep Learn. Object Detect. Pada Video Menggunakan Tensorflow Dan Convolutional Neural Netw.*, pp. 1–60, 2018, [Online]. Available: [https://dspace.uui.ac.id/bitstream/handle/123456789/7762/14611242\\_SyarifahRositaDewi\\_Statistika.pdf?sequence=1](https://dspace.uui.ac.id/bitstream/handle/123456789/7762/14611242_SyarifahRositaDewi_Statistika.pdf?sequence=1)
- [3] F. Marpaung, F. Aulia, and R. C. Nabila, *Computer Vision Dan Pengolahan Citra Digital*. 2022.
- [4] H. A. Pratiwi, M. Cahyanti, and M. Lamsani, "Implementasi Deep Learning Flower Scanner Menggunakan Metode Convolutional Neural Network," *Sebatik*, vol. 25, no. 1, pp. 124–130, 2021, doi: 10.46984/sebatik.v25i1.1297.
- [5] N. Noflindawati, A. Anwar, Y. Yusniwati, and A. Sutanto, "Karakter Morfologi dan Sitologi Bunga Pepaya Merah Delima," *J. Biol. UNAND*, vol. 7, no. 1, p. 21, 2019, doi: 10.25077/jbioua.7.1.21-26.2019.
- [6] Y. A. Suwitono and F. J. Kaunang, "Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Daun Dengan Metode Data Mining SEMMA Menggunakan Keras," *J. Komtika (Komputasi dan Inform.)*, vol. 6, no. 2, pp. 109–121, 2022, doi: 10.31603/komtika.v6i2.8054.
- [7] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [8] K. Kristiawan, D. D. Somali, T. A. Linggan jaya, and A. Widjaja, "Deteksi Buah Menggunakan Supervised Learning dan Ekstraksi Fitur untuk Pemeriksa Harga," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 3, pp. 541–548, 2020, doi: 10.28932/jutisi.v6i3.3029.
- [9] J. C. Mestika, M. O. Selan, and M. I. Qadafi, "Menjelajahi Teknik-Teknik Supervised Learning untuk Pemodelan Prediktif Menggunakan Python," vol. 99, no. 99, pp. 216–219, 2022.
- [10] S. P. Siahaan, E. Willy, A. Cahyadi, and I. P. Pangaribuan, "Tomat Menggunakan Convolutional Neural Network Monitoring and Controlling Fertilization System for Tomato Cultivation Using Convolutional Neural Network," *e-Proceeding Eng.*, vol. 7, no. 3, pp. 8647–8661, 2020.
- [11] M. Ula, A. F. Ulva, and M. Mauliza, "Implementasi Machine Learning Dengan Model Case Based Reasoning Dalam Mendagnosa Gizi Buruk Pada Anak," *J. Inform. Kaputama*, vol. 5, no. 2, pp. 333–339, 2021, doi: 10.59697/jik.v5i2.267.
- [12] 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.

- [13] I. Wulandari, H. Yasin, and T. Widiharih, "Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma Convolutional Neural Network (Cnn)," *J. Gaussian*, vol. 9, no. 3, pp. 273–282, 2020, doi: 10.14710/j.gauss.v9i3.27416.
- [14] L. F. Viera Valencia and D. Garcia Giraldo, "濟無No Title No Title No Title," *Angew. Chemie Int. Ed.* 6(11), 951–952., vol. 2, pp. 12–64, 2019.
- [15] O. D. Nurhayati, D. Eridani, and M. H. Tsalavin, "Sistem Isyarat Bahasa Indonesia (SIBI) Metode Convolutional Neural Network Sequential secara Real Time," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 4, pp. 819–828, 2022, doi: 10.25126/jtiik.2022944787.
- [16] M. Harahap, Em Manuel Laia, Lilis Suryani Sitanggang, Melda Sinaga, Daniel Franci Sihombing, and Amir Mahmud Husein, "Deteksi Penyakit Covid-19 Pada Citra X-Ray Dengan Pendekatan Convolutional Neural Network (CNN)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 70–77, 2022, doi: 10.29207/resti.v6i1.3373.
- [17] I. Suhardin, A. Patombongi, and A. M. Islah, "MENGIDENTIFIKASI JENIS TANAMAN BERDASARKAN CITRA DAUN MENGGUNAKAN AIGORITMA CONVOLUTIONAL NEURAL NETWORK," *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 6, no. 2, pp. 100–108, 2021, doi: 10.51876/simtek.v6i2.101.
- [18] I. Deep, L. Menggunakan, U. Image, and C. Varietas, *Digital Repository Universitas Jember Implementasi Deep Learning Menggunakan*. 2022.
- [19] Stephen, Raymond, and H. Santoso, "Aplikasi Convolution Neural Network," *J. Sist. Inf. dan Telemat.*, vol. Volume 10, pp. 122–132, 2019.
- [20] S. R. Putra, "Implementasi Convolutional Neural Network Untuk Klasifikasi Obyek Pada Citra," 2015, [Online]. Available: <http://repository.its.ac.id/71292/1/5111100076-Undergraduate Thesis.pdf>
- [21] M. Fasounaki, E. B. Yüce, S. Öncül, and G. Ince, "CNN-based Text-independent Automatic Speaker Identification Using Short Utterances," *Proc. - 6th Int. Conf. Comput. Sci. Eng. UBMK 2021*, vol. 01, pp. 413–418, 2021, doi: 10.1109/UBMK52708.2021.9559031.
- [22] A. TiaraSari and E. Haryatmi, "Penerapan Convolutional Neural Network Deep Learning dalam Pendeteksian Citra Biji Jagung Kering," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 2, pp. 265–271, 2021, doi: 10.29207/resti.v5i2.3040.
- [23] rahayu deny danar dan alvi furwanti Alwie, A. B. Prasetio, R. Andespa, P. N. Lhokseumawe, and K. Pengantar, "Tugas Akhir Tugas Akhir," *J. Ekon. Vol. 18, Nomor 1 Maret201*, vol. 2, no. 1, pp. 41–49, 2020.
- [24] R. A. Y, "Perbandingan Algoritma Cnn Dan Svm Untuk Analisis Sentimen Mengenai Kenaikan Harga Bahan Bakar Minyak," vol. 10, no. 6, pp. 5418–5422, 2023.
- [25] P. R. Sihombing, "Perbandingan Metode Artificial Neural Network (ANN) dan Support Vector Machine (SVM) untuk Klasifikasi Kinerja Perusahaan Daerah Air Minum (PDAM) di Indonesia," *J. Ilmu Komput.*, vol. 13, no. 1, p. 9, 2020, doi: 10.24843/jik.2020.v13.i01.p02.