

Perbandingan Model AlexNet dan ResNet dalam Klasifikasi Citra Bunga Memanfaatkan *Transfer Learning*

Comparison of AlexNet and ResNet Models in Flower Image Classification Utilizing Transfer Learning

BANA FALAHKHI¹, ELMIRA F. ACHMAL¹, MUHAMMAD RIZALDI¹, RENATA RIZKI R.A.¹, NOVANTO YUDISTIRA^{1*}

Abstrak

Klasifikasi spesies bunga otomatis berbasis citra merupakan masalah penting bagi para ahli biologi yang membuat katalog bunga digital. Banyak penelitian tentang pengenalan spesies bunga telah diusulkan sejauh ini berdasarkan rutinitas pemrosesan gambar tradisional. Saat ini, para peneliti menerapkan pembelajaran mendalam pada berbagai tugas pengenalan objek berbasis gambar. Dalam makalah ini, *deep learning* berbasis *transfer learning* diterapkan pada klasifikasi spesies bunga. Metode yang diusulkan menggunakan model *transfer learning* AlexNet dan ResNet. *Dataset* Flower102 yang memiliki banyak kategori digunakan dalam karya eksperimental. Berbagai hasil eksperimen menunjukkan bahwa masing-masing model telah mencapai kinerja akurasi 87% dan 96% untuk AlexNet dan ResNet. Hasil yang diperoleh menunjukkan efektifitas model berbasis ResNet lebih tinggi bila dibandingkan dengan model berbasis AlexNet.

Kata Kunci: klasifikasi bunga, *transfer learning*, *deep learning*, AlexNet, ResNet.

Abstract

Image-based automatic flower species classification is an important issue for biologists creating digital flower catalogs. Many studies on flower species recognition have been proposed so far based on traditional image processing routines. Currently, researchers are applying deep learning to various image-based object recognition tasks. In this paper, deep learning based on transfer learning is applied to the classification of flower species. The proposed method uses AlexNet and ResNet transfer learning models. The Flower102 dataset which has many categories is used in the experimental work. Various experimental results show that each model has achieved 87% and 96% accuracy performance for AlexNet and ResNet. The results obtained show that the effectiveness of the ResNet-based model is higher than the AlexNet-based model.

Keywords: flower classification, transfer learning, deep learning, AlexNet, ResNet

PENDAHULUAN

Pengenalan karakteristik keilmuan hayati dengan memanfaatkan komputasi semakin populer dalam penelitian ilmiah (Yudistira *et al.* 2020). Hal ini termasuk pula pada penelitian pengenalan jenis bunga secara otomatis dengan memanfaatkan data yang besar. Ada banyak bunga di seluruh dunia yang termasuk dalam sekitar 369.000 spesies menurut laporan Royal Botanic Gardens, (Kew 2016), di Inggris. Bunga-bunga tersebut memiliki nilai budaya, nilai ekonomi, dan nilai ekologis yang besar dalam kehidupan kita. Banyaknya bunga dan besarnya manfaat tersebut mendorong untuk melakukan klasifikasi jenis bunga agar bunga-bunga tersebut dapat dikenali dan diketahui manfaatnya. Klasifikasi bunga memiliki berbagai

¹Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya, Malang, Tel. (0341) 577911

*Penulis Korespondensi: yudistira@ub.ac.id

manfaat, seperti dapat membantu dalam florikultura dan pencarian bunga di perpustakaan digital (Shaparia *et al.* 2017).

Dengan perkembangan *machine learning* dan teknik *computer vision*, klasifikasi bunga otomatis menarik perhatian penelitian yang semakin meningkat. Namun, sistem klasifikasi kategori bunga otomatis masih merupakan tugas yang menantang karena banyak kesamaan di antara kelas. Selain itu, bunga dapat berubah bentuk dalam banyak cara, dan akibatnya, ada juga variasi intra-kelas yang besar. Variasi lebih banyak terjadi pada sudut pandang, oklusi, skala gambar bunga. Gambar bunga mungkin memiliki posisi yang berbeda dengan latar belakang yang kompleks di bawah kondisi pencahayaan dan iklim yang bervariasi. Semua masalah ini membuat pengenalan bunga lebih menantang. Beberapa ciri fisik telah digunakan untuk membedakan satu bunga dengan bunga lainnya seperti warna, bentuk, dan pola tekstur. Kesulitannya adalah menemukan deskriptor yang cocok untuk warna, bentuk, pola, dan juga untuk pengklasifikasi yang memiliki kapasitas untuk memilih fitur yang signifikan.

Baru-baru ini, *deep learning* memungkinkan pembelajaran fitur yang kuat dan mencapai kinerja mutakhir pada berbagai tugas klasifikasi gambar (Wu *et al.* 2019). Diketahui bahwa Tantangan Klasifikasi Visual Skala Besar ImageNet/ImageNet Large Scale Visual Classification Challenge (ILSVRC) menandai awal dari perkembangan pesat *deep learning*. Namun sejauh ini metode *deep learning* pada klasifikasi bunga masih terbatas pada dataset yang kecil, yang hanya berisi sampel atau spesies bunga yang sangat sedikit (Xia *et al.* 2017).

Dalam penelitian ini, dua model diusulkan untuk pengenalan citra bunga, yaitu model *transfer learning* AlexNet dan ResNet untuk ekstraksi fitur klasifikasi kenis bunga. Alasan untuk memilih model ini adalah model tersebut telah mencapai hasil yang sukses dalam tantangan ImageNet (Chen *et al.* 2016). Kami menguji kinerja pendekatan kami dengan kumpulan data yang tersedia untuk umum yang disebut Flower102. Hasil kinerja yang diperoleh disajikan dan dibandingkan antara dua model *transfer learning* yang digunakan.

Sistematika pembahasan makalah ini diatur sebagai berikut. Pada bagian kedua, metodologi yang terkait dengan metode yang diusulkan disajikan. Kumpulan data, dasar teori, dan penelitian terdahulu dengan metode mutakhir diberikan di bagian 3. Pada bagian 4 disajikan hasil dari penelitian yang dilakukan. Akhirnya, pada bagian kelima kami menyimpulkan penelitian dan secara singkat meringkas pendekatan kami.

Berikut ini akan dipaparkan kajian pustaka berkaitan dengan klasifikasi jenis bunga menggunakan model *transfer learning* AlexNet dan ResNet. Kajian pustaka ini juga membahas penelitian terkait untuk mengetahui apa saja yang telah dilakukan oleh peneliti terdahulu.

Flower102

Dataset ini, dibuat di Inggris, terdiri dari 8189 gambar yang dibagi menjadi 102 kategori bunga (Razavian *et al.* 2014). Setiap kategori berisi antara 40 dan 258 gambar. Gambar yang memiliki banyak kategori, memiliki skala besar dalam intensitas kontras yang berbeda. Ada juga banyak kategori serupa yang sulit dibedakan dan divisualisasikan menggunakan isomap dengan fitur bentuk dan warna. Terlebih lagi, *dataset* ini lebih menantang daripada *dataset* Flower17 karena memiliki lebih banyak gambar.

Transfer Learning

Transfer learning bertujuan untuk meningkatkan kinerja tugas target dengan mentransfer pengetahuan yang dipelajari dari tugas sumber ke tugas target. *Transfer learning* mengasumsikan bahwa mempelajari pengetahuan domain baru dapat dipelajari lebih mudah dengan menggunakan pengetahuan yang dipelajari sebelumnya dari domain yang sama ketika mempelajari data, seolah-olah manusia menggunakan pengetahuan yang mereka pelajari ketika memecahkan masalah baru. Misalnya, ketika Anda mengajarkan apel ke komputer, komputer dapat belajar lebih mudah dengan menggunakan pengalaman belajar jeruk. Yang penting saat menggunakan *transfer learning* adalah *target task* dan *source task domain* harus serupa (Sachan *et al.* 2018).

Transfer learning telah digunakan dalam pembelajaran yang mendalam dan menunjukkan kinerja yang sangat baik. Secara khusus, Yosinski *et al.* (2014) menunjukkan bahwa kinerja generalisasi model *deep learning* dapat ditingkatkan ketika *transfer learning* digunakan. Dalam model *deep learning*, *transfer learning* digunakan untuk mengekstrak fitur tugas sumber menggunakan struktur model yang dipelajari dalam domain yang memiliki sejumlah besar data dan bobot yang dipelajari. *Transfer learning* juga dapat digunakan ketika data pelatihan kecil tersedia (Soekhoe *et al.* 2016).



Gambar 1 Sampel data citra Flower102.

Freezing layer (pembekuan lapisan)

Secara umum, pembelajaran mendalam dengan *convolutional neural network* (CNN) membutuhkan data yang banyak agar fitur yang terbentuk mampu melakukan klasifikasi secara akurat terutama pada data citra. Dalam hal ini, *transfer learning* dapat dimanfaatkan untuk dapat mentransfer fitur yang dilatih pada *dataset* ImageNet untuk kemudian dilakukan *fine-tuning* ke *dataset* Flower102. Akan tetapi, beberapa lapisan konvolusi kemungkinan mempunyai fitur yang sangat kaya hasil dari pelatihan data yang besar seperti ImageNet. Agar fitur-fitur yang kaya tersebut tidak berubah ke tugas yang lebih spesifik seperti halnya citra-citra bunga, maka pembekuan lapisan filter menjadi salah satu opsi. Dalam penelitian ini kami mencoba membekukan lapisan dua teratas karena lapisan-lapisan ini menyimpan fitur-fitur dasar dari citra.

AlexNet

AlexNet adalah jaringan saraf kompleks dengan 60 juta parameter dan 650.000 neuron. AlexNet meningkatkan kapasitas pembelajaran dengan meningkatkan kedalaman jaringan dan menerapkan strategi pengoptimalan multi-parameter (Khan *et al.* 2020). Secara khusus, untuk mengatasi masalah bahwa fungsi aktivasi tradisional (termasuk fungsi logistik, tanh, dan arctan) sering terjebak dalam penghilangan gradien jaringan dalam, Krizhevsky menggunakan *Rectified Linear Unit* (ReLU) sebagai fungsi aktivasi baru. ReLU didefinisikan sebagai Persamaan 1.

$$ReLU(x) = \max(x, 0) \quad (1)$$

Selanjutnya, penggunaan *dropout layer* yang mengikuti *fully connected layer* adalah untuk menghindari *overfitting*, mengurangi adaptasi *joint* antar neuron dan meningkatkan generalisasi dan ketahanan. Juga, konvolusi dapat secara otomatis mempelajari fitur dari gambar pelatihan dan mengurangi kompleksitas jaringan melalui berbagi parameter. Konvolusi didefinisikan sebagai Persamaan 2 (Lu *et al.* 2019).

$$C(m, n) = (M * w)(m, n) = \sum_k \sum_l M(m - k, n - l)w(k, l) \quad (2)$$

Di mana (m, n) adalah ukuran gambar M dan (k, l) adalah ukuran *kernel* konvolusi w . Selain itu, *pooling* digunakan untuk pengurangan fitur. *Pooling* mempertimbangkan satu set piksel tetangga di peta fitur dan menghasilkan nilai untuk representasi dengan beberapa strategi. Akhirnya, saluran silang sebagai metode normalisasi lokal terinspirasi oleh neuron nyata, yang menghasilkan jumlah dari peta tetangga pada posisi yang sama, yang berarti bahwa peta fitur dinormalisasi sebelum dimasukkan ke lapisan jaringan berikutnya. Neuron di lapisan terhubung penuh yang berdekatan terhubung langsung, dan fungsi aktivasi *softmax* mengaktifkan neuron dalam rentang (0,1) dengan membatasi *output*. Fungsi aktivasi *softmax* didefinisikan sebagai (Lu *et al.* 2019) Persamaan 3.

$$\text{softmax}(X)_i = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)} \quad (3)$$

$\exp(x_i)$ menggambarkan fungsi eksponensial standar yang diterapkan pada setiap elemen x_i dari vektor *input*, $\sum_{j=1}^n \exp(x_j)$ adalah istilah normalisasi, dan n adalah jumlah kelas.

ResNet

Arsitektur *deep neural network* (DNN) buatan yang sangat sukses adalah *Residual Network* (ResNet) dan keluarganya (ResNet-18, ResNet-50, ResNet-152 juga ResNext). Karakteristik utama dari arsitektur ResNet adalah menghindari hilangnya masalah gradien. Masalah ini terjadi pada jaringan yang sangat dalam karena penurunan fungsi *loss* untuk menemukan bobot yang sesuai. Dalam *deep learning*, perkalian berulang menyebabkan gradien semakin kecil, hingga hilang dengan bertambahnya jumlah lapisan. Selain itu, melatih jaringan saraf yang lebih dalam dengan banyak parameter membutuhkan *learning rate* yang signifikan (Wu *et al.* 2019). ResNet mengusulkan koneksi pintasan identitas yang dilewati dari beberapa lapisan dan menggunakan fungsi aktivasi lapisan sebelumnya. Ide seperti itu memungkinkan kita merancang DNN buatan dengan banyak lapisan dan tidak peduli dengan masalah gradien hilang. Untuk tujuan ini, dikembangkan arsitektur modular yang menumpuk blok sisa dengan pemetaan identitas. Pada blok residual, perhitungan Persamaan 4 dilakukan:

$$x_{l+1} = x_l + F(x_l \cdot W_l) \quad (4)$$

x_l dan x_{l+1} adalah *input* dan *output* dari blok residual ke- l . W_l adalah himpunan bobot, dan $F(x_l \cdot W_l)$ adalah fungsi residual. Persamaan 5 dapat diwujudkan dengan '*shortcut connection*' dengan melakukan pemetaan identitas dan melewatkan satu atau lebih lapisan. Hal ini dilakukan berulang-ulang untuk setiap blok sisa L sehingga diperoleh:

$$x_L = x_l + \sum_{i=1}^{L-1} F(x_i \cdot W_i) \quad (5)$$

Dari gradien fungsi *loss*, ketika bobot sangat kecil, gradien lapisan tidak hilang. Namun demikian, masih belum ada pengetahuan tentang posisi bagian objek.

Fungsi Loss

Fungsi *loss* yang dipakai ini adalah *cross entropy* (CE) *loss* klasifikasi *multiclass* dengan jumlah *class* lebih dari 2 menggunakan Persamaan 6 berikut:

$$CE = - \sum_{c=1}^M y_{o,c} \log(p_{o,c}) \quad (6)$$

M adalah banyaknya kelas, $y_{o,c}$ = label *output* o indeks (kelas) ke- c (0 atau 1), sedangkan $p_{o,c}$ adalah probabilitas *output* o indeks (kelas) ke- c (skala 0-1).

Akurasi

Akurasi hasil deteksi dihitung berdasarkan banyaknya bunga yang diklasifikasikan benar dibagi total data uji dikali 100% seperti dirumuskan sebagai Persamaan 7 seperti berikut:

$$\text{Akurasi} = \frac{\text{Banyak data uji yang terklasifikasi benar}}{\text{Banyak data uji}} \quad (7)$$

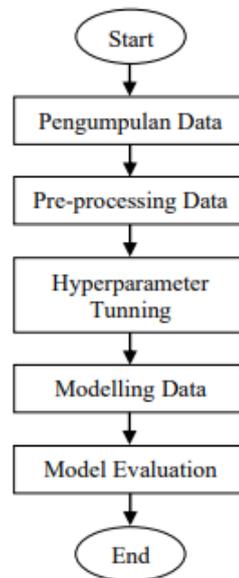
Penelitian Terkait

Di bidang *computer vision*, metode klasifikasi bunga menggunakan fitur visual telah dikembangkan. Nilsback dan Zisserman (2008) mengekstraksi fitur warna, tekstur, dan bentuk regional dalam gambar bunga dan mengklasifikasikan bunga menggunakan *multiple kernel Support Vector Machines* (SVM). Guru *et al.* (2010) menggunakan fitur tekstur berbasis matriks *co-occurrence* untuk mempelajari fitur yang membedakan bunga dari bunga lainnya. Sementara algoritma yang mereka usulkan menangkap fitur serupa antara bunga dari spesies yang sama, itu juga membedakan mereka dari bunga lain masing-masing. Mereka menggunakan *K-Nearest Neighbor* (KNN) *classifier* untuk mengklasifikasikan bunga. Metode konvensional ini memiliki keterbatasan bahwa manusia harus memilih filter sewenang-wenang secara manual. Liu *et al.* (2016) menggunakan CNN dan mengatasi keterbatasan ini dengan secara otomatis mempelajari fitur gambar yang bagus untuk klasifikasi gambar. Lin *et al.* (2015) mempertimbangkan pendekatan *transfer learning* dengan CNN untuk mengklasifikasikan bunga ketika sampel pelatihan sangat sedikit.

METODE

Secara umum, tahapan penelitian ini terdiri atas beberapa tahapan yang disajikan pada Gambar 2. Penelitian ini terdiri atas 5 tahapan seperti dijelaskan berikut ini:

- 1 Tahap pengumpulan data. Pada tahap ini, *dataset* yang digunakan, Flower102, diunduh dari web dan dimuat pada Google Collab.
- 2 Tahap *pre-Processing* data. Pada tahap ini, data yang sudah dimuat pada Google memiliki ukuran yang bervariasi, sehingga dilakukan penyeragaman dengan *resize* menjadi 256 x 256 piksel. Kemudian dilakukan *cropping* sehingga data citra berukuran 224 x 224 piksel. Selanjutnya, data citra tersebut dibagi menjadi 6552 data latih dan 818 data uji, dan dimuat ke dalam *data loader* menggunakan pytorch.
- 3 Pemilihan model. Pada tahap ini model AlexNet dan ResNet dipilih dikarenakan keduanya mewakili arsitektur CNN modern dimana ResNet terdapat penambahan *skip connection* pada layer konvolusinya yang berguna untuk mencegah terjadinya *vanishing gradient*.
- 4 *Modelling data*. Pada tahap ini kedua model AlexNet dan ResNet dilatih menggunakan data latih yang telah disediakan. Kedua model dilatih sebanyak 5 *epoch*.
- 5 *Hyperparameter Tunning*. Pada tahap ini dilakukan penentuan parameter yang paling optimal, seperti *loss function* dan *Optimizer* yang digunakan. Pada penelitian ini digunakan *categorical cross-entropy* sebagai *loss function*. *Optimizier* yang digunakan yaitu *Stochastic Gradient Descent* dengan *learning rate* 0.001 dan momentum 0.9.
- 6 *Model Evaluation*. Pada tahap ini kedua model diuji menggunakan data uji, dan dilihat jumlah klasifikasi data citra yang benar dan salah. Hasil dari kedua model dibandingkan sehingga didapatkan model dengan tingkat akurasi klasifikasi tertinggi.



Gambar 2 Bagan alur metodologi penelitian.

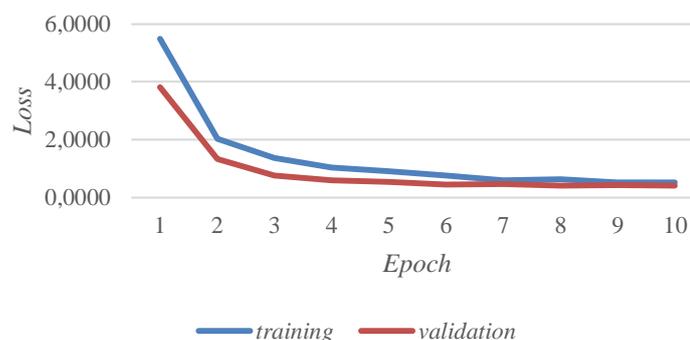
HASIL DAN PEMBAHASAN

AlexNet Model

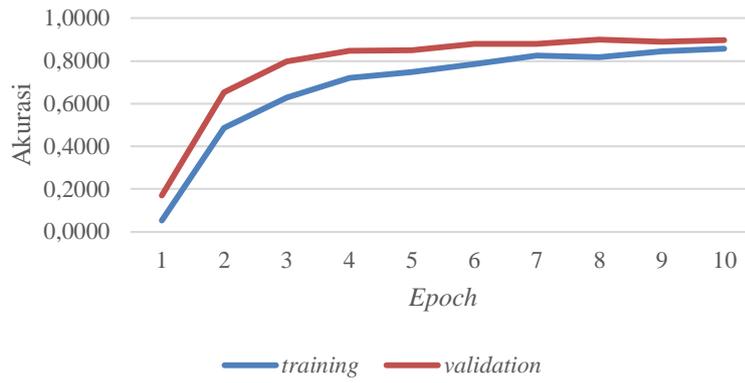
Model AlexNet dilatih sebanyak 10 *epoch* untuk memastikan model yang optimal. Tingkat *loss model* cenderung menurun seiring bertambahnya *epoch* pada tahap pelatihan, sedangkan tingkat akurasi cenderung meningkat seiring bertambahnya *epoch*. Hal ini dapat dilihat pada Gambar 3 dan Gambar 4. Dari 10 *epoch* pelatihan, didapatkan nilai akurasi dan *loss model* pada data pelatihan berturut-turut sebesar 85.7% dan 0.52. Pada tahap pengujian, dilakukan pengujian terhadap 818 sampel data uji yang dipilih didapatkan bahwa model dapat mengklasifikasikan dengan benar 90.2% dari data yang diujikan.

ResNet Model

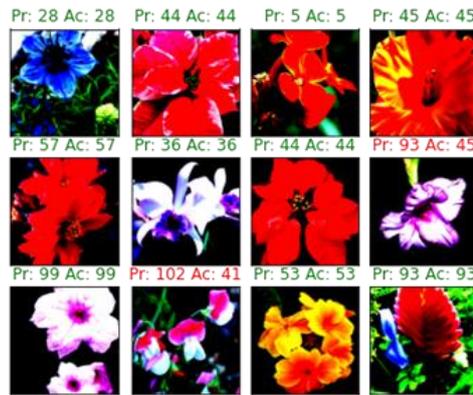
Sama seperti model AlexNet, model ResNet dilatih sebanyak 10 *epoch* untuk memastikan model yang optimal. Tingkat *loss model* cenderung menurun seiring bertambahnya *epoch* pada tahap pelatihan, sedangkan tingkat akurasi cenderung meningkat seiring bertambahnya *epoch*. Hal ini dapat dilihat pada Gambar 6 dan Gambar 7. Dari 10 *epoch* pelatihan, didapatkan nilai akurasi dan *loss model* pada data pelatihan berturut-turut sebesar 96% dan 0.16. Pada tahap pengujian, selain diujikan pada data uji sebanyak 818, juga dilakukan pengujian terhadap 12 sampel data uji yang dipilih secara acak sehingga didapatkan bahwa model dapat mengklasifikasikan dengan benar semua data yang diujikan.



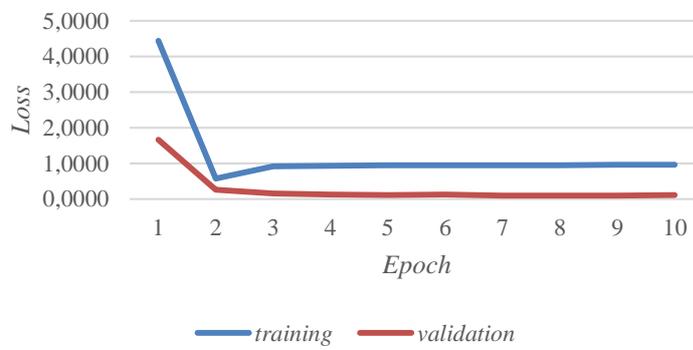
Gambar 3. Grafik nilai *loss model* AlexNet pada masing-masing *epoch*.



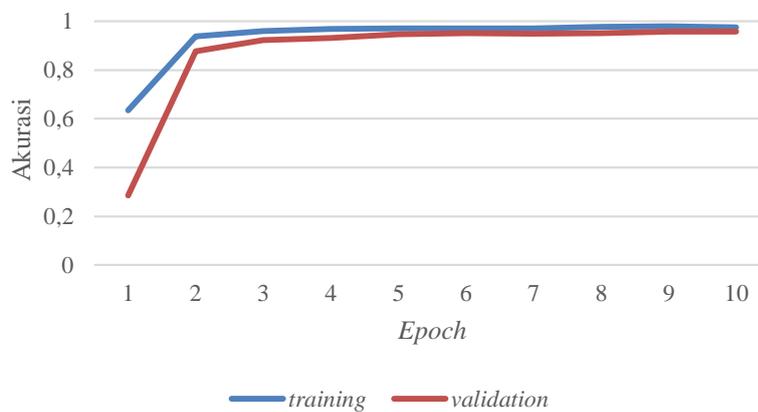
Gambar 4 Grafik nilai *accuracy model* AlexNet teratas pada masing-masing *epoch*.



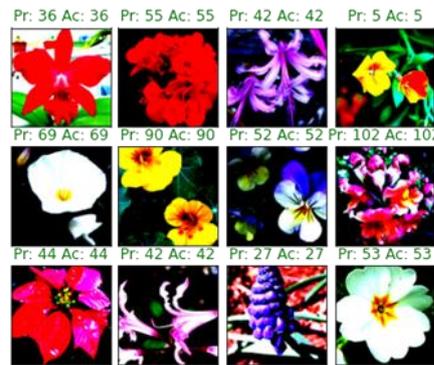
Gambar 5 Hasil pengujian model AlexNet.



Gambar 6 Grafik nilai *loss model* ResNet50 dengan *freezing 2 layer* teratas pada masing-masing *epoch*.



Gambar 7 Grafik nilai *accuracy model* ResNet50 dengan *freezing 2 layer* teratas pada masing-masing *epoch*.



Gambar 8 Hasil pengujian model ResNet.

Perbandingan Model

Dari percobaan dan pelatihan yang telah dilakukan terhadap kedua model, dapat dibandingkan nilai *loss*, *accuracy*, jumlah klasifikasi yang benar dan salah, seperti yang tertera pada Tabel 1. Berdasarkan hasil tersebut, dapat dilihat bahwa model AlexNet kurang bila dibandingkan dengan model ResNet. Model ResNet memiliki nilai yang lebih baik, pada semua aspek perbandingan bila dibandingkan dengan model AlexNet. Disamping itu, model ResNet50 mempunyai akurasi yang sama dengan DenseNet121 dengan menggunakan 818 data uji sebagai pengujian. Akhirnya, hal ini membuktikan pula pembekuan dua lapisan teratas ResNet50 mampu menghasilkan kaurasi terbaik sebesar 97.3%.

Tabel 1 Perbandingan performa model AlexNet dan ResNet

Model	Akurasi
AlexNet	90.2%
Resnet50	97.3%
Densenet121	97.3%
Resnet50 (freeze top 2 layer)	97.6%

SIMPULAN

Sistem klasifikasi bunga otomatis berdasarkan kategori masih merupakan tugas yang menantang karena kesamaan antar kelas dan variasi intra kelas. Oleh dalam penelitian ini, dua model diusulkan untuk pengenalan citra bunga, yaitu model *transfer learning* AlexNet dan ResNet untuk ekstraksi fitur klasifikasi jenis bunga. Kami menguji kinerja pendekatan kami dengan kumpulan data yang tersedia untuk umum yang disebut Flower102. Hasil kinerja yang diperoleh disajikan dan dibandingkan antara dua model *transfer learning* yang digunakan. Hasil ini didapatkan dalam percobaan: (1) Model AlexNet memiliki akurasi 90.2%; (2) Model ResNet memiliki akurasi 97.3%; dan (3) Pada uji *random data test*, AlexNet salah 2 kali dan ResNet benar semua. Dari hasil-hasil tersebut dapat disimpulkan bahwa ResNet adalah model yang lebih baik daripada AlexNet pada penelitian ini. Lebih jauh, dengan digunakannya pembekuan 2 layer teratas dapat sedikit menaikkan akurasi model ResNet ke 97.6% pada klasifikasi bunga Flower102.

DAFTAR PUSTAKA

Chen Y, Jiang H, Li C, Jia X, Ghamisi P. 2016. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing* 54(10): 6232 – 6251.

- Guru DS, Sharath YH, Manjunath S. 2010. Texture features and KNN in classification of flower images. *IJCA Journal* 5(1): 21 - 29.
- Kew RBG. 2016. *The State of The World's Plants Report – 2016*. Sidney(AU): Royal Botanic Gardens.
- Khan A, Jamil M, Naz R, Humayun A, Ullah S, Jelani G. 2020. Investigation of treatment regimen of the genital warts using various chemotherapeutic agents. *Biomedical Sciences* 6(1): 1 - 4.
- Lin K, Yang HF, Chen CS. 2015. Flower classification with few training examples via recalling visual patterns from deep CNN. Di dalam: *IPPR Conference on Computer Vision, Graphics, and Image Processing (CVGIP)*.
- Liu Y, Tang F, Zhou D, Meng Y, Dong W. 2016. Flower classification via convolutional neural network. Di dalam: *2016 IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA)*; Qingdao, 2016 Nov 7-11. New York(US): IEEE. hlm 110 - 116.
- Lu S, Lu Z, Zhang YD. 2019. Pathological brain detection based on AlexNet and transfer learning. *Journal of Computational Science* 30:41 - 47.
- Nilsback M, Zisserman A. 2008. Automated flower classification over a large number of classes. Di dalam: *2008 Sixth Indian Conference on Computer Vision, Graphics & Image Processing*; 2008 Des 16-19. Washington(US): IEEE Computer Society. hlm. 722-729.
- Novanto Y, Sumitro SB, Nahas A, Riama NF. 2020. UV light influences covid-19 activity through big data: trade offs between northern subtropical, tropical, and southern subtropical countries. *medRxiv*.
- Novanto Y, Kavitha M, Itabashi T, Iwane AH, Kurita T. Prediction of sequential organelles localization under imbalance using a balanced deep u-net. *Scientific reports* 10(1): 1-11.
- Pan SJ, Yang Q. 2010. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering* 22: 1345 - 1359.
- Razavian AS, Azizpour H, Sullivan J Carlsson S. 2014. CNN features off-the-shelf: an astounding baseline for recognition. Di dalam: *2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops*; Ohio, 2014 Jun 23-28. Washington(US): IEEE Computer Society. hlm. 512 - 519.
- Sachan DS, Xie P, Sachan M Xing EP. 2018. Effective use of bidirectional language modeling for transfer learning in biomedical named entity recognition. *Proceedings of Machine Learning Research* 85: 1 -19.
- Shaparia R, Patel N, Shah Z. 2017. Flower classification using texture and color features. Di dalam: *International Conference on Research and Innovations in Science, Engineering and Technology*; Anand, 2017 Feb 17-19. Manchester(UK): EasyChair. hlm. 113-118.
- Soekhoe D, Putten PVD, Plaat A. 2016. On the impact of data set size in transfer learning using deep neural networks. Di dalam: *International Symposium on Intelligent Data Analysis*; Sweden, 2016 Oktober 13-15. hlm 50 - 60.
- Wu X, Zhan C, Lai Y, Cheng M, Yang J. 2019. A large-scale benchmark dataset for insect pest recognition. Di dalam: *IEEE Conference on Computer Vision and Pattern Recognition*; Long Beach, 2019 Jun 15-20. Washington(US): IEEE. hlm. 8787 - 8796.
- Wu Z, Shen C, Hengel AVD. 2019. Wider or deeper: revisiting the resnet model for visual recognition. *Pattern Recognition* 90: 119 - 133.
- Xia X, Xu C, Nan B. 2017. Inception-v3 for Flower Classification. Di dalam: *International Conference on Image, Vision and Computing*; Chengdu, 2017 Jun 2-4. Washington(US): IEEE. hlm. 783 - 787.