

Perbandingan Model Transfer Learning Untuk Klasifikasi Data Agricultural Crop Images

¹Vina Ayumi

¹Universitas Mercu Buana, Jakarta, Indonesia

¹vina.ayumi@mercubuana.ac.id

Article Info

Article history:

Received, 2022-07-28

Revised, 2022-10-25

Accepted, 2022-11-22

Kata Kunci:

transfer learning
agriculture crop
deep learning

ABSTRAK

Klasifikasi tanaman telah diterapkan selama bertahun-tahun sebagai salah satu komponen utama pemantauan pertanian. Klasifikasi jenis tanaman merupakan teknik penting untuk menyediakan informasi tersebut. Berdasarkan latar belakang diatas, penelitian ini akan melakukan agricultural crop type classification from digital images. Dataset *crop images* terdiri dari 40 lebih gambar untuk setiap kelas yang ada yaitu kelas *maize*, *wheat*, *jute*, *rice* dan *sugarcane*. Dataset kemudian dilakukan augmentasi sehingga menghasilkan 159+ gambar untuk setiap kelas. Proses augmentasi dilakukan dengan proses *horizontal flip*, *rotation*, *horizontal shift* dan *vertical shift*. Data pengujian dipersiapkan dengan jumlah terdiri dari 51 gambar dengan masing-masing 10 gambar setiap kelasnya. Berdasarkan dari hasil eksperimen, hasil akurasi validasi terbesar didapatkan dengan implementasi metode VGG16 sebesar 96.52%, sedangkan VGG19 mendapatkan akurasi sebesar 94.03%, Resnet50 mendapatkan akurasi sebesar 41.79%, Inceptionv3 mendapatkan akurasi sebesar 94.53% dan EfficientNetB0 mendapatkan akurasi sebesar 20.40%.

Keywords:

transfer learning
agriculture crop
deep learning

ABSTRACT

Crop classification has been applied for many years as one of the main components of agricultural monitoring. Classification of plant species is an important technique for providing this information. Based on the above background, this research will classify agricultural crop types from digital images. The crop images dataset consists of more than 40 images for each class, namely corn, wheat, jute, rice and sugarcane. The dataset is then augmented to produce 159+ images for each class. The augmentation process is carried out by horizontal flip, rotation, horizontal shift and vertical shift processes. The test data was prepared in a total of 51 images, with ten images each for each class. Based on the experimental results, the highest validation accuracy results were obtained by implementing the VGG16 method of 96.52%, while VGG19 got an accuracy of 94.03%, Resnet50 got an accuracy of 41.79%, Inceptionv3 got an accuracy of 94.53%, and EfficientNetB0 got an accuracy of 20.40%.

This is an open access article under the [CC BY-SA](#) license.



Penulis Korespondensi:

Vina Ayumi,
Fakultas Ilmu Komputer
Universitas Mercu Buana, Jakarta, Indonesia
Email: vina.ayumi@mercubuana.ac.id

1. PENDAHULUAN

Ketahanan pangan menjadi salah satu perhatian dunia dikarenakan jumlah populasi dunia diperkirakan saat ini yang terus meningkat, dan kondisi air dan suhu pertanian secara signifikan semakin menurun kualitasnya. Untuk mengatasi masalah kerawanan pangan perlu adanya manajemen pertanian, pemantauan hasil pertanian yang efektif dan efisien. Perkembangan teknologi informasi saat ini terutama pada bidang digital image processing dapat menjadi salah satu pendukung untuk pemantauan hasil pertanian [1]–[9].

Klasifikasi tanaman telah diterapkan selama bertahun-tahun sebagai salah satu komponen utama pemantauan pertanian [10]. Klasifikasi jenis tanaman merupakan teknik penting untuk menyediakan informasi tersebut [1], [11]–[13]. Pada *image processing*, metode klasifikasi juga sangat penting untuk kategorisasi jenis tanaman, baik menggunakan metode unsupervised maupun metode supervised learning. Pemilihan metode tergantung pada bentuk dan jenis sampel pelatihan [1], [12], [14]–[21].

Penelitian ini akan menggunakan metode Convolutional Neural Network (CNN) untuk klasifikasi data hasil tanaman pertanian berdasarkan data digital images. Pada bidang pertanian, CNN telah banyak digunakan untuk klasifikasi beberapa jenis dataset [22]–[25]. Penelitian Mazzia, Khaliq, and Chiaberge (2020) berjudul *Improvement in Land Cover and Crop Classification Based on Temporal Features Learning from Sentinel-2 Data Using Recurrent-Convolutional Neural Network (R-CNN)*. Penelitian ini menggunakan dataset Sentinel-2 dari gambar citra lahan pertanian di Itali. Penelitian ini mendapatkan hasil akurasi sebesar 96.5% dengan mengimplementasikan model Pixel R-CNN [23].

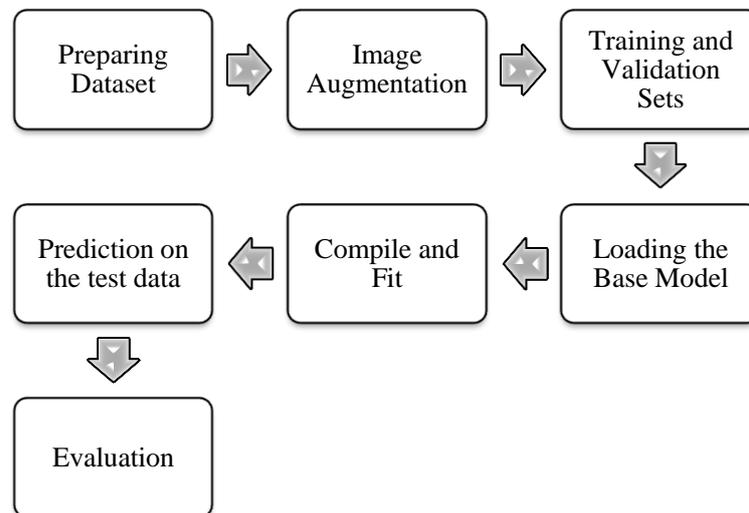
Penelitian lainnya yang berkaitan berjudul *evaluation of deep learning cnn model for land use land cover classification and crop identification using hyperspectral remote sensing images* [24]. Penelitian ini menggunakan dataset Indian Pines dataset dan dataset dari EO-1 Hyperion sensor. Penelitian ini mendapatkan hasil akurasi sebesar 97.58% untuk Indian Pines dataset dan 79.43% untuk data EO-1 Hyperion sensor [24].

Penelitian selanjutnya melakukan penelitian pada dataset remote sensing images menggunakan metode combining optimal feature selection (OFSM) dan hybrid convolutional neural network-random forest (CNN-RF) [25]. Penelitian ini menggunakan dataset Sentinel-2 untuk mengidentifikasi jenis hasil panen di China. Penelitian ini mendapatkan hasil akurasi sebesar 94.27% menggunakan metode Conv1D-RF [25].

Berdasarkan latar belakang diatas, penelitian ini akan melakukan agricultural crop type classification from digital images. Dataset yang digunakan adalah dataset tentang citra *agriculture crop* yang terdiri dari lima kelas yaitu *maize, wheat, jute, rice and sugarcane*.

2. METODE PENELITIAN

Pada penelitian ini, kami membandingkan performansi lima model transfer learning yaitu: VGG16, VGG19, ResNet50, InceptionV3, dan EfficientNetB0. Kelima model yang kami gunakan ini telah dilatih sebelumnya pada dataset ImageNet. Pada eksperimen ini kami menggunakan data *agricultural crop images*. Jenis kelas yang digunakan adalah corn, wheat, jute, rice and sugarcane. Tahapan penelitian dapat dilihat pada Gambar berikut ini.



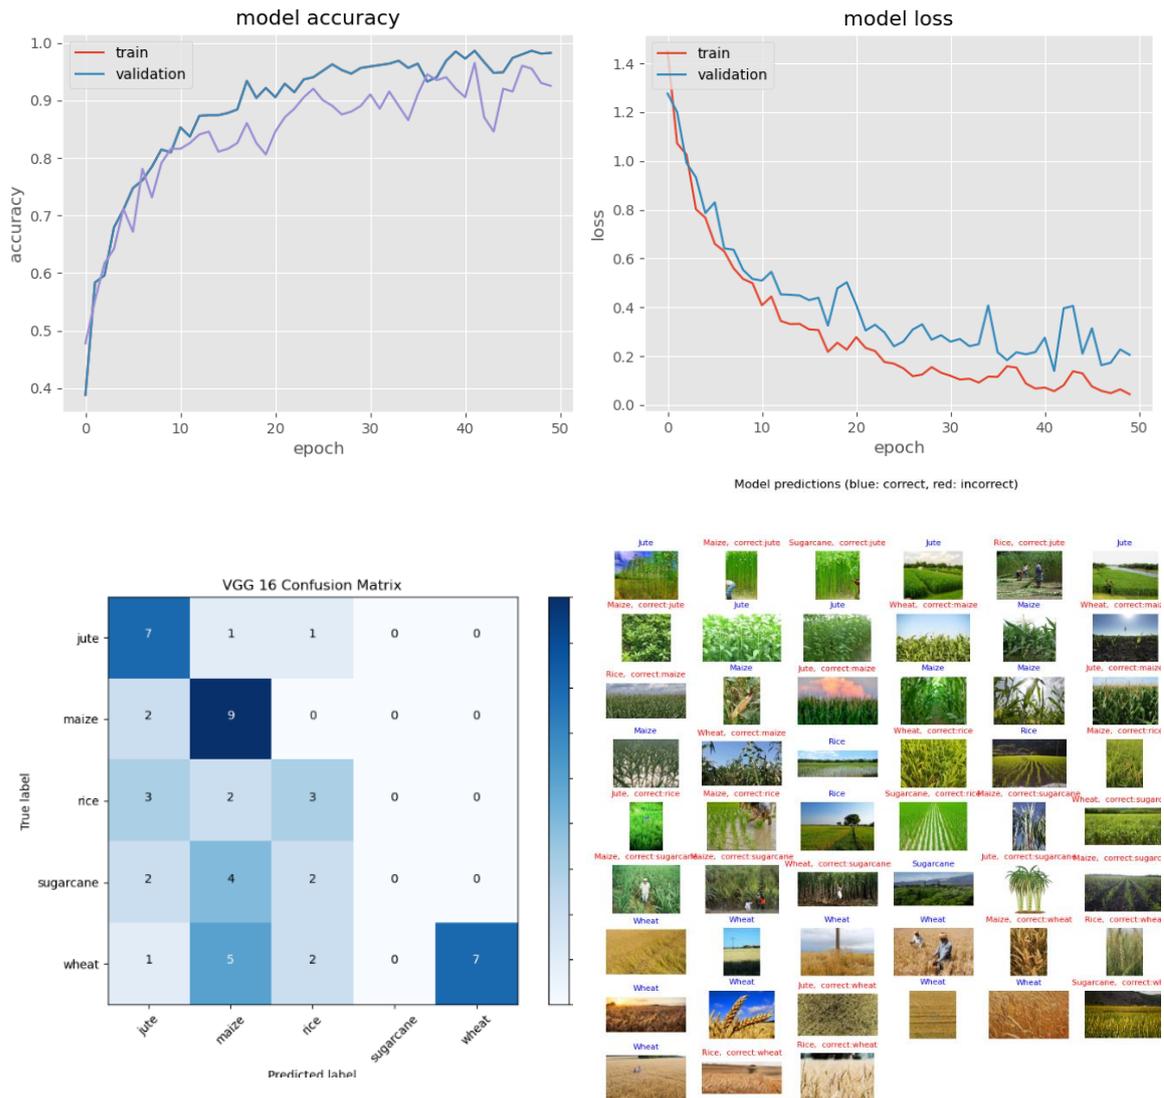
Gambar 1 Tahap Penelitian

Dataset merupakan hasil koleksi pengumpulan kamera dan proses augmentation antara lain *horizontal flip, rotation, horizontal shift* dan *vertical shift*. Data testing yang digunakan berupa 51 gambar diluar dengan masing-masing 10 gambar setiap kelasnya. Performa dari kelima model akan dibandingkan dengan menggunakan matriks konfusi dan akurasi rata-ratanya. Secara lengkap metodologi pada riset ini dapat dilihat pada Gambar berikut.

3. HASIL DAN PEMBAHASAN

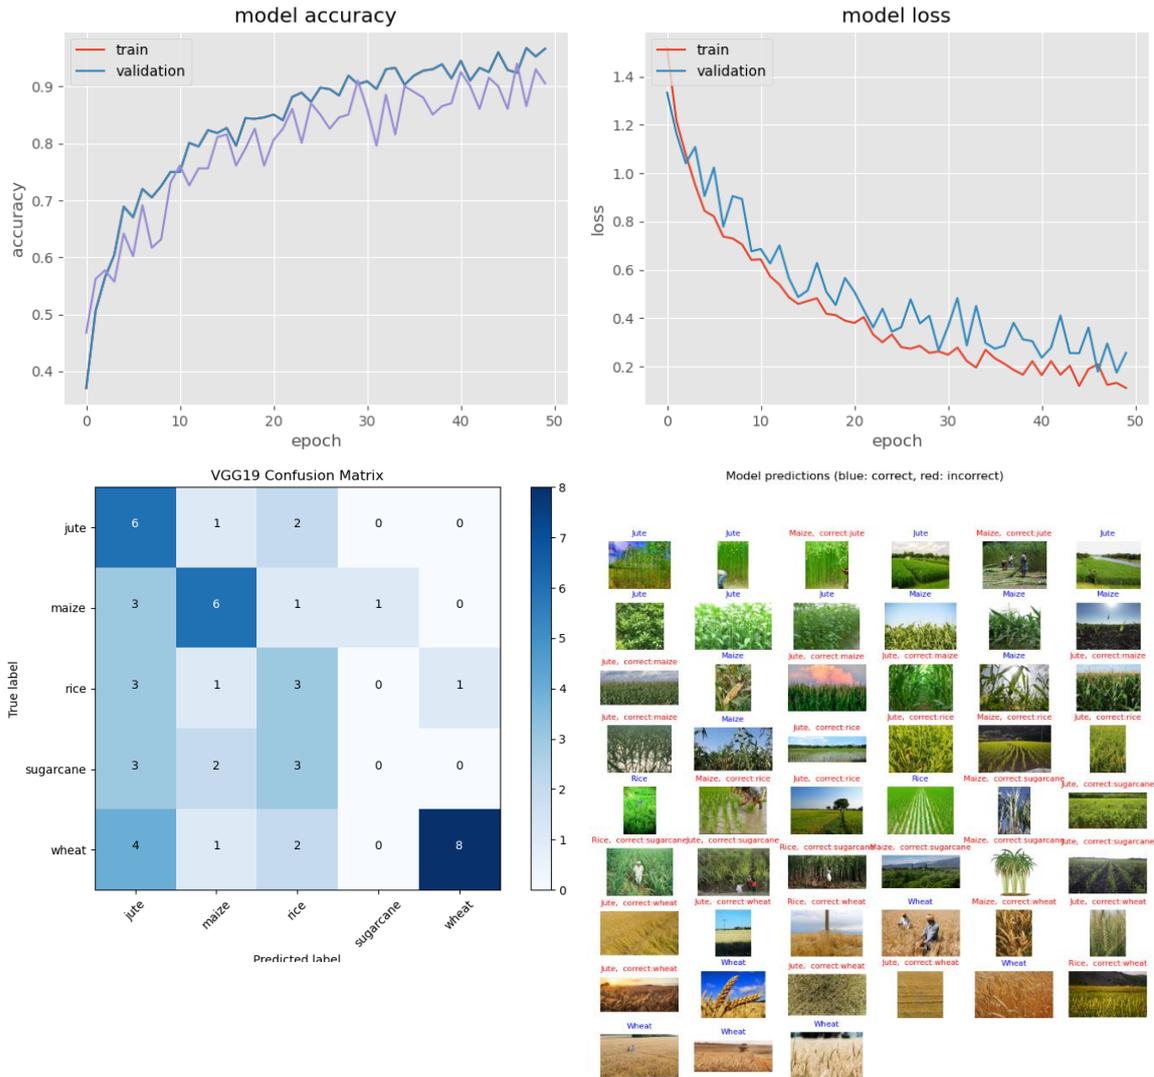
Pada penelitian ini dilakukan perbandingan performa 5 model transfer learning yaitu: VGG16, VGG19, ResNet50, InceptionV3, dan EfficientNetB0. Kelima model yang kami gunakan ini telah dilatih sebelumnya pada dataset ImageNet. Pada eksperimen ini kami menggunakan data *agricultural crop images*. Performa dari kelima model akan dibandingkan dengan menggunakan matriks *confusion* dan akurasi rata-ratanya.

Berdasarkan evaluasi dari kinerja model VGG16 didapatkan hasil akurasi training sebesar 98.63%, akurasi validasi sebesar 96.52%, akurasi testing sebesar 50.98% dan nilai Cohens kappa sebesar 0.382865. Hasil kinerja dari algoritma berupa grafik akurasi, grafik loss, confusion matrix dan hasil prediksi dari model arsitektur VGG16 dapat dilihat pada Gambar 2 berikut.



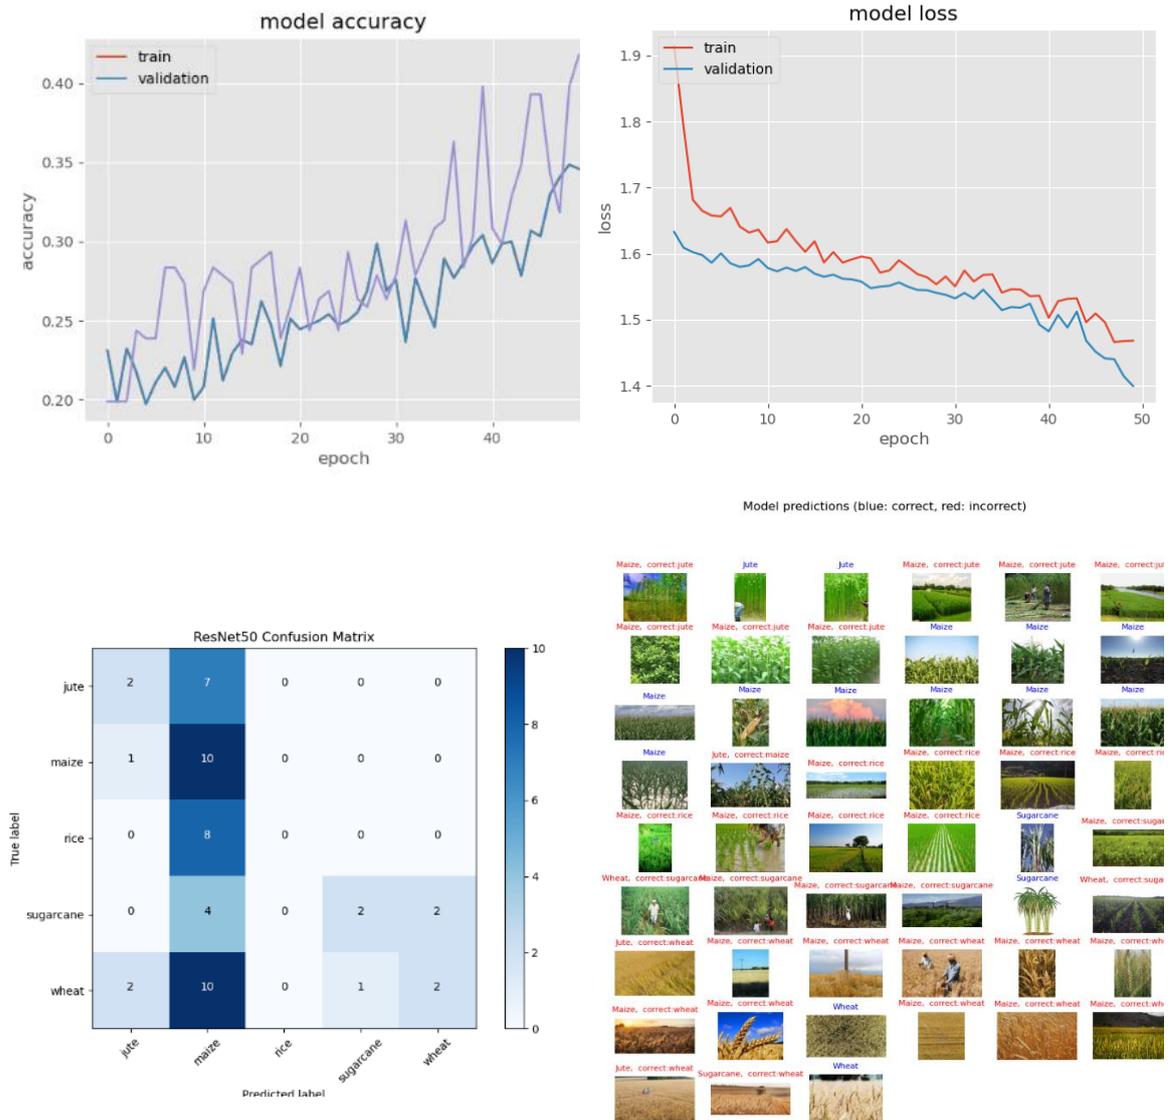
Gambar 2 Hasil Performa VGG16

Berdasarkan evaluasi dari kinerja model VGG19 didapatkan hasil akurasi training sebesar 92.41%, akurasi validasi sebesar 94.03%, akurasi testing sebesar 45.10% dan nilai Cohens kappa sebesar 0.312801. Hasil kinerja dari algoritma berupa grafik akurasi, grafik loss, confusion matrix dan hasil prediksi dari model arsitektur VGG19 dapat dilihat pada Gambar 3 berikut.



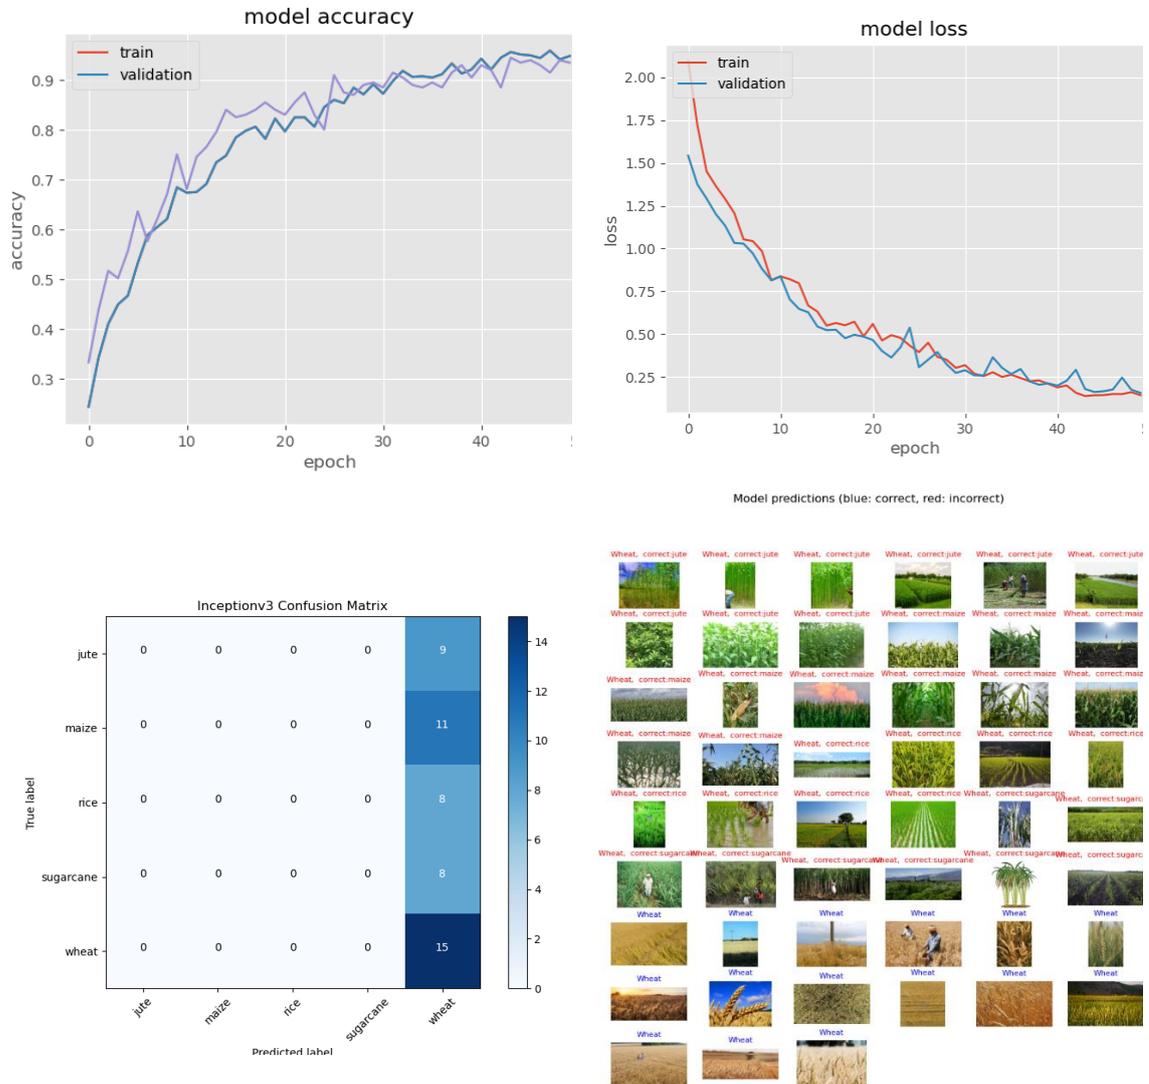
Gambar 2 Hasil Performa VGG19

Berdasarkan evaluasi dari kinerja model Resnet50 didapatkan hasil akurasi training sebesar 34.59%, akurasi validasi sebesar 41.79%, akurasi testing sebesar 31.37% dan nilai Cohens kappa sebesar 0.126285. Hasil kinerja dari algoritma berupa grafik akurasi, grafik loss, confusion matrix dan hasil prediksi dari model arsitektur Resnet50 dapat dilihat pada Gambar berikut.



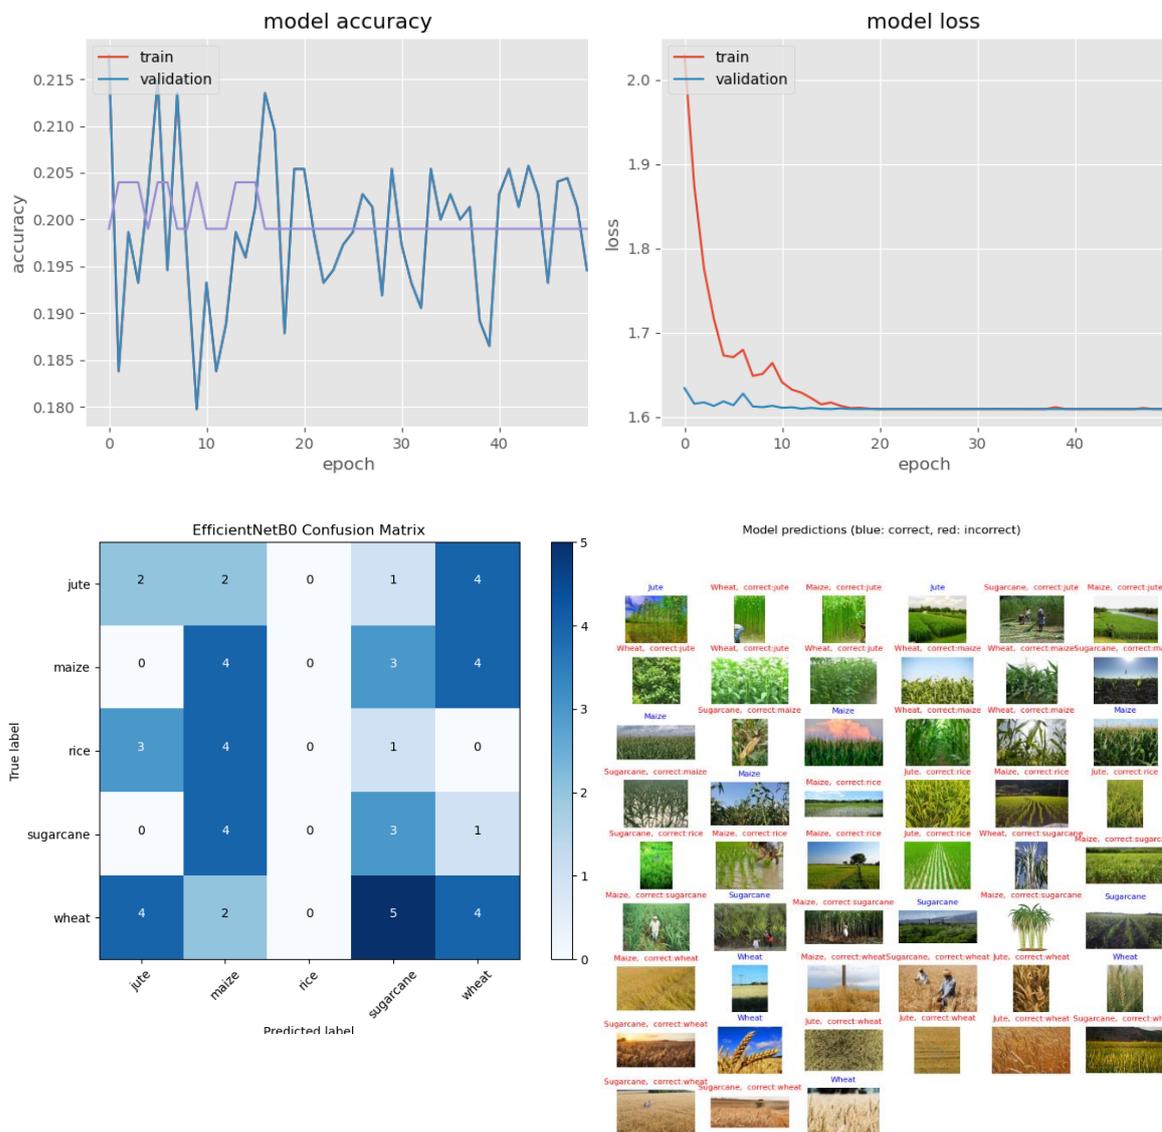
Gambar 3 Hasil Performa Resnet50

Berdasarkan evaluasi dari kinerja model Inceptionv3 didapatkan hasil akurasi training sebesar 95.68%, akurasi validasi sebesar 94.53%, akurasi testing sebesar 29.41%. Hasil kinerja dari algoritma berupa grafik akurasi, grafik loss, confusion matrix dan hasil prediksi dari model arsitektur Inceptionv3 dapat dilihat pada Gambar berikut.



Gambar 4 Hasil Performa Inceptionv3

Berdasarkan evaluasi dari kinerja model EfficientNetB0 didapatkan hasil akurasi training sebesar 18.38%, akurasi validasi sebesar 20.40%, akurasi testing sebesar 25.49% dan nilai Cohens kappa sebesar 0.052323. Hasil kinerja dari algoritma berupa grafik akurasi, grafik loss, confusion matrix dan hasil prediksi dari model arsitektur EfficientNetB0 dapat dilihat pada Gambar 6 berikut.



Gambar 5 Hasil Performa EfficientNetB0

Dataset *crop images* terdiri dari 40 lebih gambar untuk setiap kelas yang ada yaitu kelas *maize*, *wheat*, *jute*, *rice* dan *sugarcane*. Dataset kemudian dilakukan augmentasi sehingga menghasilkan gambar untuk setiap kelas. Proses augmentasi dilakukan dengan proses horizontal flip, rotation, horizontal shift dan vertical shift. Data pengujian dipersiapkan dengan jumlah terdiri dari 51 gambar dengan masing-masing 10 gambar setiap kelasnya.

Berdasarkan dari hasil eksperimen, hasil akurasi validasi terbesar didapatkan dengan implementasi metode VGG16 sebesar 96.52%, sedangkan VGG19 mendapatkan akurasi sebesar 94.03%, Resnet50 mendapatkan akurasi sebesar 41.79%, Inceptionv3 mendapatkan akurasi sebesar 94.53% dan EfficientNetB0 mendapatkan akurasi sebesar 20.40%. Perbandingan kinerja model transfer learning model diperlihatkan pada Tabel sebagai berikut.

Tabel 1 Hasil Eksperimen

Transfer Learning Model	Training Accuracy	Training Loss	Validation Accuracy	Validation Loss	Testing Accuracy	Cohens kappa
VGG16	0.9863	0.0562	0.9652	0.1390	0.509804	0.382865
VGG19	0.9241	0.2094	0.9403	0.1795	0.450980	0.312801
Resnet50	0.3459	1.4681	0.4179	1.3996	0.313725	0.126285
Inceptionv3	0.9568	0.1389	0.9453	0.1800	0.294118	0.000000
EfficientNetB0	0.1838	1.8738	0.2040	1.6157	0.254902	0.052323

4. KESIMPULAN

Klasifikasi tanaman telah diterapkan selama bertahun-tahun sebagai salah satu komponen utama pemantauan pertanian. Klasifikasi jenis tanaman merupakan teknik penting untuk menyediakan informasi tersebut. Berdasarkan latar belakang diatas, penelitian ini akan melakukan agricultural crop type classification from digital images. Dataset yang digunakan adalah dataset tentang citra *agriculture crop* yang terdiri dari lima kelas yaitu maize, wheat, jute, rice and sugarcane. Pada penelitian ini, kami membandingkan performansi 5 model transfer learning yaitu: VGG16, VGG19, ResNet50, InceptionV3, dan EfficientNetB0. Model yang memiliki kinerja terbaik adalah VGG16 dengan valication accuracy 96.52%. Selain itu, VGG19 mendapatkan akurasi sebesar 94.03%, Resnet50 mendapatkan akurasi sebesar 41.79%, Inceptionv3 mendapatkan akurasi sebesar 94.53% dan EfficientNetB0 mendapatkan akurasi sebesar 20.40%. Perbandingan kinerja model transfer learning model diperlihatkan pada Tabel sebagai berikut.

UCAPAN TERIMA KASIH

Terima kasih kepada Pusat Penelitian dan Fakultas Ilmu Komputer, Universitas Mercu Buana yang telah mendukung pelaksanaan penelitian ini.

REFERENSI

- [1] J. Fan, X. Zhang, C. Zhao, Z. Qin, M. De Vroey, and P. Defourny, "Evaluation of Crop Type Classification with Different High Resolution Satellite Data Sources," *Remote Sens.*, vol. 13, no. 5, p. 911, 2021.
- [2] M. Rahman, L. Di, E. Yu, C. Zhang, and H. Mohiuddin, "In-season major crop-type identification for US cropland from landsat images using crop-rotation pattern and progressive data classification," *Agriculture*, vol. 9, no. 1, p. 17, 2019.
- [3] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine learning in agriculture: A review," *Sensors*, vol. 18, no. 8, p. 2674, 2018.
- [4] B. Priambodo, N. Ani, and Y. Jumaryad, "Predict Next User Location to Improve Accuracy of Mobile Advertising," *J. Phys. Conf. Ser.*, vol. 1175, no. 1, 2019.
- [5] A. A. Pratama, D. I. Sensuse, and H. Noprisson, "A systematic literature review of business process improvement," in *Information Technology Systems and Innovation (ICITSI), 2017 International Conference on*, 2017, pp. 26–31.
- [6] A. Setiyoko, D. I. Sensuse, and H. Noprisson, "A systematic literature review of environmental management information system (EMIS) development: Research trends, datasets, and methods," in *2017 International Conference on Information Technology Systems and Innovation (ICITSI)*, 2017, pp. 20–25.
- [7] D. I. Sensuse, Y. G. Sucahyo, M. Silalahi, I. A. Wulandari, I. F. Akmaliah, and H. Noprisson, "Toward to operationalization of socio-technical ontology engineering methodology," in *2017 5th International Conference on Cyber and IT Service Management (CITSM)*, 2017, pp. 1–7.
- [8] S. Murmu and S. Biswas, "Application of fuzzy logic and neural network in crop classification: a review," *Aquat. Procedia*, vol. 4, pp. 1203–1210, 2015.

- [9] Z. P. Putra, D. Setiawan, B. Priambodo, Y. Jumaryadi, and M. DesiAnasanti, "Multi-touch gesture of mobile auditory device for visually impaired users," in *2020 2nd International Conference on Broadband Communications, Wireless Sensors and Powering (BCWSP)*, 2020, pp. 90–95.
- [10] M. Lavreniuk, N. Kussul, and A. Novikov, "Deep learning crop classification approach based on sparse coding of time series of satellite data," in *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*, 2018, pp. 4812–4815.
- [11] B. Darwin, P. Dharmaraj, S. Prince, D. E. Popescu, and D. J. Hemanth, "Recognition of Bloom/Yield in Crop Images Using Deep Learning Models for Smart Agriculture: A Review," *Agronomy*, vol. 11, no. 4, p. 646, 2021.
- [12] V. Ayumi, E. Ermatita, A. Abdiansah, H. Noprisson, M. Purba, and M. Utami, "A Study on Medicinal Plant Leaf Recognition Using Artificial Intelligence," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 40–45.
- [13] E. Hidayat, Lukman, H. Noprisson, D. I. Sensuse, Y. G. Suchayo, and E. D. Putra, "Development of mobile application for documenting traditional knowledge in Indonesia: A Case Study of Traditional Knowledge in Using Medicinal Plant," in *Proceedings - 14th IEEE Student Conference on Research and Development: Advancing Technology for Humanity, SCORED 2016*, 2017.
- [14] I. Nurhaida, V. Ayumi, D. Fitriannah, R. A. M. Zen, H. Noprisson, and W. Hong, "Implementation of deep neural networks (DNN) with batch normalization for batik pattern recognition," *Int. J. Electr. Comput. Eng.*, vol. 10, no. 2, p. 2045, 2020.
- [15] H. Yalcin, "An approximation for a relative crop yield estimate from field images using deep learning," in *2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*, 2019, pp. 1–6.
- [16] P. S. Nishant, P. S. Venkat, B. L. Avinash, and B. Jabber, "Crop yield prediction based on indian agriculture using machine learning," in *2020 International Conference for Emerging Technology (INCET)*, 2020, pp. 1–4.
- [17] D. H. Timbadia, S. Sudhanvan, P. J. Shah, and S. Agrawal, "Crop Yield Prediction for India Using Regression Algorithms," in *International Conference on Advances in Computing and Data Sciences*, 2021, pp. 241–251.
- [18] A. Tidake, D. Sharma, Y. Kumar, and D. Deshpande, "Implementation of Farmer Informative System for Maximizing the Farming Yield Using Machine Learning Approach," in *2nd International Conference on Communication & Information Processing (ICCIP)*, 2020.
- [19] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and M. Utami, "Hand-Woven Fabric Motif Recognition Methods: A Systematic Literature Review," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 90–95.
- [20] I. Nurhaida *et al.*, "Implementation of Deep Learning Predictor (LSTM) Algorithm for Human Mobility Prediction," *Int. J. Interact. Mob. Technol.*, vol. 14, no. 18, p. 132, Nov. 2020.
- [21] V. Ayumi, "Application of Machine Learning for SARS-CoV-2 Outbreak," *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 7, no. 5, 2020.
- [22] D. P. Kuchipudi and T. R. Babu, "A Review on Segmentation of Plant Maladies and Pathological Parts from the Leaf Images in Agriculture Crop," in *2019 2nd International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICT)*, 2019, vol. 1, pp. 927–934.
- [23] V. Mazzia, A. Khaliq, and M. Chiaberge, "Improvement in land cover and crop classification based on temporal features learning from Sentinel-2 data using recurrent-convolutional neural network (R-CNN)," *Appl. Sci.*, vol. 10, no. 1, p. 238, 2020.
- [24] K. Bhosle and V. Musande, "Evaluation of deep learning CNN model for land use land cover classification and crop identification using hyperspectral remote sensing images," *J. Indian Soc. Remote Sens.*, vol. 47, no. 11, pp. 1949–1958, 2019.
- [25] S. Yang, L. Gu, X. Li, T. Jiang, and R. Ren, "Crop classification method based on optimal feature selection and hybrid CNN-RF networks for multi-temporal remote sensing imagery," *Remote Sens.*, vol. 12, no. 19, p. 3119, 2020.