

## Bab 5

# Simpulan dan Saran

Pada bagian ini akan dibahas mengenai kesimpulan dari penelitian yang sudah dilakukan. Selain itu, akan dibahas juga mengenai saran untuk penelitian kedepannya berdasarkan penelitian yang sudah dilakukan.

### 5.1 Simpulan

Simpulan dari penelitian yang sudah dilakukan adalah sebagai berikut.

1. Teknik *machine learning* yang sesuai untuk tujuan klasifikasi adalah *Convolution Neural Network* dengan arsitektur AlexNet. Hasil pelatihan dengan variabel arsitektur MobileNetV2 serta EfficientNetB0 yang merupakan arsitektur yang sudah lebih berkembang dari arsitektur AlexNet tidak menunjukkan performa yaitu akurasi dan *loss* yang sesuai dengan kompleksitas parameter yang dimiliki kedua arsitektur tersebut. Terlepas dari kompleksitas parameter yang lebih rendah, hasil pengujian arsitektur membuktikan AlexNet lebih sesuai untuk tugas klasifikasi tingkat kematangan TBKS.
2. Variabel pelatihan model yang sesuai untuk kebutuhan klasifikasi tingkat kematangan tandan buah kelapa sawit adalah sebagai berikut.
  - Variabel *LRate*  $10^{-4}$  cenderung menghasilkan performa akurasi dan *loss* yang lebih baik dibandingkan nilai *LRate* lainnya saat menggunakan *optimizer* Adam. Sedangkan, *optimizer* SGD memiliki kencenderungan

untuk menghasilkan performa yang optimal saat menggunakan variabel  $LRate 10^{-2}$ .

- Variabel *Optimizer* SGD cenderung menghasilkan performa akurasi dan *loss* yang lebih baik dari Adam. Hal tersebut dapat dilihat saat membandingkan hasil prediksi kedua *optimizer* pada nilai *LRate* yang sama di mana SGD cenderung lebih banyak menghasilkan performa model yang lebih tinggi.
  - Pada pengujian pengaruh variabel set data, pelatihan yang menggunakan set data 1 yang berupa gambar yang dikondisikan agar objek berada di dalam gambar menghasilkan performa akurasi dan *loss* yang lebih baik dibandingkan set data 2 dan 3. Sehingga pemrosesan set data dengan melakukan segmentasi baik menggunakan algoritma segmentasi maupun aplikasi Removebg terbukti tidak efektif dalam meningkatkan performa model terlatih.
  - Perbedaan performa yang ditemukan pada set data 4 dan 5 yang merupakan set data yang sama namun menghasilkan performa akurasi dan *loss* yang berbeda. Set data 5 yang sudah disesuaikan dimensi *pixel* dibandingkan set data 4 yang dimensinya berbeda dengan format gambar yang digunakan.
3. Performa klasifikasi tingkat kematangan tandan buah kelapa sawit terbaik dengan menggunakan model *machine learning* adalah sebagai berikut.
- Performa akurasi terbaik dalam pengujian model terlatih adalah 87,1% (model terlatih 1-4). Namun performanya turun menjadi 45,7% saat digunakan untuk memprediksi set data baru (set data 5). Hal tersebut juga dapat dilihat pada hasil prediksi set data 6 yang merupakan gabungan set data 1 yang digunakan dalam pelatihan dan set data 5 yang merupakan set data baru, hasil prediksi dapat menghasilkan nilai akurasi yaitu 70,9%.
  - Pelatihan bertahap dengan melatih kembali model terlatih mampu meningkatkan nilai performa model terlatih dengan menggunakan variabel yang sama saat pelatihan, kecuali set data yang digunakan dalam pelatihan. Akurasi tertinggi didapatkan menggunakan model terlatih 1-4 yang dilatih kembali sehingga nilai akurasi bertambah 7,9% menjadi 78,8% saat menguji set data 6.

- Pelatihan bertahap yang mengimplementasikan LearningRateScheduler dengan set data 6 yang dibagi untuk proses pelatihan menghasilkan performa terbaik pada penelitian ini dengan akurasi 92,4% dan *loss* 0,349.

## 5.2 Saran

Pada bagian ini, akan dibahas mengenai saran yang diusulkan berdasarkan pertimbangan hasil pengujian sebagai berikut.

1. Mencoba variabel lain untuk mendapatkan model dengan performa yang lebih tinggi.
2. Mengambil lebih banyak data untuk menyusun set data yang lebih besar untuk menambah variasi data.
3. Memasang model terlatih pada perangkat keras seperti Raspberry Pi yang dilengkapi dengan kamera untuk melakukan prediksi secara *real-time*.
4. Membuat susunan lapisan arsitektur secara khusus untuk kasus klasifikasi kematangan TBKS.



# Daftar Pustaka

- [1] A. Goodfellow, Ian; Bengio, Yoshua; C ourville, “index @ d2l.ai-Dive into Deep Learning-2021,” 2016.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, p. 84–90, may 2017. [Online]. Available: <https://doi.org/10.1145/3065386>
- [3] Ditjenbun, “Kementerian pertanian direktorat jenderal perkebunan : Kontribusi minyak kelapa sawit indonesia mengatasi krisis pangan global,” Nov 2022. [Online]. Available: <https://ditjenbun.pertanian.go.id/kontribusi-minyak-kelapa-sawit-indonesia-mengatasi-krisis-pangan-global/>
- [4] O. M. B. Saeed, S. Sankaran, A. R. M. Shariff, H. Z. M. Shafri, R. Ehsani, M. S. Alfatni, and M. H. M. Hazir, “Classification of oil palm fresh fruit bunches based on their maturity using portable four-band sensor system,” *Computers and electronics in agriculture*, vol. 82, pp. 55–60, 2012.
- [5] S. Zolfagharnassab, A. R. B. M. Shariff, R. Ehsani, H. Z. Jaafar, and I. B. Aris, “Classification of oil palm fresh fruit bunches based on their maturity using thermal imaging technique,” *Agriculture*, vol. 12, no. 11, p. 1779, 2022.
- [6] J. Q. Goh, A. R. Mohamed Shariff, and N. Mat Nawi, “Application of optical spectrometer to determine maturity level of oil palm fresh fruit bunches based on analysis of the front equatorial, front basil, back equatorial, back basil and apical parts of the oil palm bunches,” *Agriculture*, vol. 11, no. 12, p. 1179, 2021.
- [7] N. Fadilah, J. Mohamad-Saleh, Z. A. Halim, H. Ibrahim, and S. S. S. Ali, “Intelligent color vision system for ripeness classification of oil palm fresh fruit bunch,” *Sensors*, vol. 12, no. 10, pp. 14 179–14 195, 2012.

- [8] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, “Identifikasi kematangan buah kelapa sawit berdasarkan warna rgb dan hsv menggunakan metode k-means clustering,” *Jurnal Sains Dan Informatika*, vol. 6, no. 2, pp. 193–202, 2020.
- [9] S. Ashari, G. J. Yanris, and I. Purnama, “Oil palm fruit ripeness detection using deep learning,” *Sinkron: jurnal dan penelitian teknik informatika*, vol. 7, no. 2, pp. 649–656, 2022.
- [10] F. Wardana, “Sistem deteksi tingkat kematangan tandan buah segar kelapa sawit menggunakan metode convnet berbasis android.”
- [11] M. S. M. Alfatni, S. Khairunniza-Bejo, M. H. B. Marhaban, O. M. B. Saaed, A. Mustapha, and A. R. M. Shariff, “Towards a real-time oil palm fruit maturity system using supervised classifiers based on feature analysis,” *Agriculture*, vol. 12, no. 9, p. 1461, 2022.
- [12] d. A. W. Astuti, M., Hafiza, E. Yuningsih, I.M. Nasuiton, D. Mustikawati, *Pedoman Budidaya Kelapa Sawit (*Elaeis guineensis*) yang Baik*. Direktorat Jendral Perkebunan, 2014.
- [13] “Dinas lingkungan hidup.” [Online]. Available: <https://dlh.probolinggokab.go.id/kelapa-sawit/>
- [14] J. Supriyono, “Sejarah kelapa sawit indonesia,” May 2019. [Online]. Available: <https://gapki.id/news/3652/video-sejarah-kelapa-sawit-indonesia>
- [15] S. Zolfagharnassab, A. R. B. M. Shariff, R. Ehsani, H. Z. Jaafar, and I. B. Aris, “Classification of Oil Palm Fresh Fruit Bunches Based on Their Maturity Using Thermal Imaging Technique,” *Agriculture (Switzerland)*, vol. 12, no. 11, pp. 1–20, 2022.
- [16] M. S. M. Alfatni, S. Khairunniza-Bejo, M. H. B. Marhaban, O. M. Saaed, A. Mustapha, and A. R. M. Shariff, “Towards a Real-Time Oil Palm Fruit Maturity System Using Supervised Classifiers Based on Feature Analysis,” *Agriculture (Switzerland)*, vol. 12, no. 9, 2022.
- [17] S. Ashari, G. J. Yanris, and I. Purnama, “Oil Palm Fruit Ripeness Detection using Deep Learning,” *Sinkron*, vol. 7, no. 2, pp. 649–656, 2022.
- [18] A. Saxena, “An Introduction to Convolutional Neural Networks,” *International Journal for Research in Applied Science and Engineering Technology*, vol. 10, no. 12, pp. 943–947, 2022.

- [19] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [20] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1–9.
- [21] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” in *International conference on machine learning*. pmlr, 2015, pp. 448–456.
- [22] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” *arXiv preprint arXiv:1704.04861*, 2017.
- [23] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, “Mobilenetv2: Inverted residuals and linear bottlenecks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2018.
- [24] A. Howard, M. Sandler, G. Chu, L.-C. Chen, B. Chen, M. Tan, W. Wang, Y. Zhu, R. Pang, V. Vasudevan *et al.*, “Searching for mobilenetv3,” in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 1314–1324.
- [25] M. Tan and Q. Le, “Efficientnet: Rethinking model scaling for convolutional neural networks,” in *International conference on machine learning*. PMLR, 2019, pp. 6105–6114.
- [26] L. eon Bottou, “Online learning and stochastic approximations,” *Online learning in neural networks*, vol. 17, no. 9, p. 142, 1998.
- [27] X. Glorot and Y. Bengio, “Understanding the difficulty of training deep feedforward neural networks,” in *Proceedings of the thirteenth international conference on artificial intelligence and statistics*. JMLR Workshop and Conference Proceedings, 2010, pp. 249–256.
- [28] J. Canny, “A computational approach to edge detection,” *IEEE Transactions on pattern analysis and machine intelligence*, no. 6, pp. 679–698, 1986.