

## BAB V

### HASIL DAN PEMBAHASAN


Deteksi otomatis kekurangan unsur hara tanaman cabai telah berhasil dilakukan dan telah di uji menggunakan beberapa gambar yang telah disiapkan untuk pengujian dengan 3 arsitektur jaringan R-CNN. Dalam bab ini akan di paparkan hasil dari proses pelatihan data dari 3 arsitektur jaringan, lalu akan dilakukan perbandingan antara pelatihan dan testing akurasi 3 arsitektur jaringan tersebut.

#### A. Hasil Pelatihan

Pada bagian ini akan dipaparkan hasil pelatihan dari keseluruhan arsitektur jaringan dengan keseluruhan dataset menggunakan perangkat keras komputer seperti pada bagian alat dan bahan Bab III dan 5000 epoch

##### 1. Pelatihan Dataset Cabai-Exp-1 Mask\_RCNN\_Inception V2

Pada bagian ini akan dilihat hasil yang telah didapat setelah proses pelatihan dataset cabai-exp-1 menggunakan model jaringan Mask RCNN Inception V2 selesai dilakukan. Grafik total loss yang tersimpan pada log dapat dilihat pada Gambar 28.




**Gambar 28** Grafik Total Loss Cabai-Exp-1 Mask RCNN Inception V2

Pada Gambar 28 Grafik Total Loss Cabai-Exp-1 Mask RCNN Inception V2 dilihat bahwa nilai akhir dari total loss yang didapat pada saat pelatihan adalah 0.0588 Untuk durasi pelatihan dalam menyelesaikan epoch 5.000 adalah 17 menit 55 Detik.

## 2. Pelatihan Dataset Cabai-Exp-1 SSD Mobilenet V2

Pada bagian ini akan dilihat hasil yang telah didapat setelah proses pelatihan dataset cabai-exp-1 menggunakan model jaringan SSD Mobilenet V2 selesai dilakukan. Grafik total loss yang tersimpan pada log dapat dilihat pada Gambar 29.




**Gambar 29** Grafik Total Loss Cabai-Exp-1 SSD Mobilenet V2

Pada Gambar 29. Grafik Total Loss Cabai-Exp- SSD Mobilenet V2 dilihat bahwa nilai akhir dari total loss yang didapat pada saat pelatihan adalah 2.4124 Untuk durasi pelatihan dalam menyelesaikan epoch 5.000 adalah 43 menit 48 detik

## 3. Pelatihan Dataset Cabai-Exp-1 SSDLite Mobilenet V2

Pada bagian ini akan dilihat hasil yang telah didapat setelah proses pelatihan dataset cabai-exp-1 menggunakan model jaringan SSDLite Mobilenet V2 selesai dilakukan. Grafik total loss yang tersimpan pada log dapat dilihat pada Gambar 30.



**Gambar 30** Grafik Total Loss Cabai-Exp-1 SSDLite Mobilenet V2

Pada Gambar 30. Grafik Total Loss Cabai-Exp-1 SSDLite Mobilenet V2 dilihat bahwa nilai akhir dari total loss yang didapat pada saat pelatihan adalah 1.8347 Untuk durasi pelatihan dalam menyelesaikan epoch 5.000 adalah 41 Menit 45 Detik

### B. Analisa Hasil Pelatihan

Pada bagian ini akan di paparkan analisa dari keseluruhan hasil training yang telah dilakukan. Seperti yang telah di jelaskan pada bagian 5 bab 4, training data dilakukan menggunakan perangkat keras (GPU NVIDIA GeForce GTX 1080). Hasilnya waktu training arsitektur jaringan Mask RCNN Inception V2 2x lebih cepat dengan arsitektur SSD Mobilenet V2. Pada Tabel 11 di paparkan detail perbandingan training data jaringan inception V2.


**Tabel 11** Hasil Pelatihan

| SSD Mobilenet V2 |               | SSDLITE Mobilenet V2 |               | Mask RCNN Inception V2 |               |
|------------------|---------------|----------------------|---------------|------------------------|---------------|
| Total Loss       | Waktu (Menit) | Total Loss           | Waktu (Menit) | Total Loss             | Waktu (Menit) |
| 2.4124           | 43            | 1.8347               | 41            | <b>0.0588</b>          | <b>17</b>     |

Dilihat dari Tabel 11 proses pelatihan yang paling cepat dan loss paling kecil adalah Mask RCNN inception V2 dengan rata-rata 17 menit.

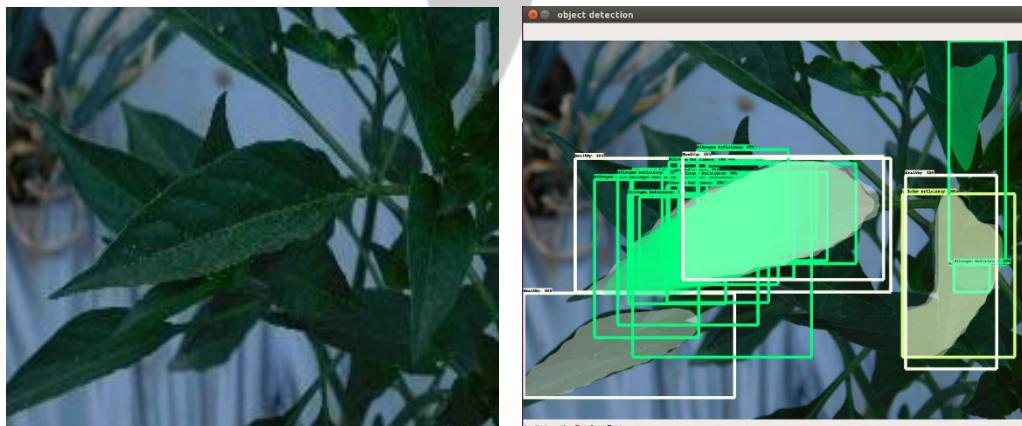
### C. Hasil pengujian

Hasil pengujian dengan 23 gambar testing sesuai dengan Bab 3 bagian 6. Hasil ini merupakan pencocokan antara deteksi otomatis dan manual. Pada gambar dibawah memaparkan beberapa gambar sebelum dan setelah di uji.



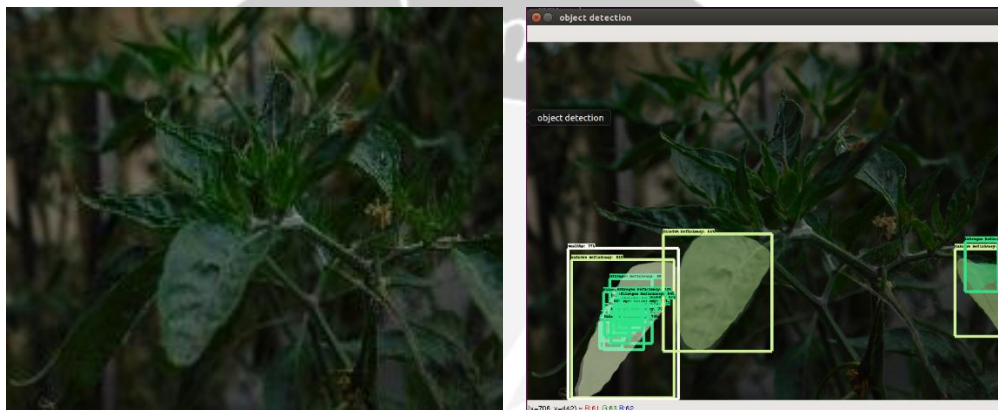
**Gambar 31** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan Mask RCNN Inception V2

Pada gambar 31 arsitektur jaringan mask rcnn inception v2 mampu mengenali objek.sebagai kekurangan nitrogen dan potassium. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri kekurangan nitrogen terlepas ada kekurangan potassium pada daun tersebut.




**Gambar 32** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan Mask RCNN Inception V2

Pada gambar 32 arsitektur jaringan mask rcnn inception v2 mampu mengenali objek.sebagai kekurangan sehat, potassium, nitrogen dan kalsium pada beberapa daun. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri daun sehat muncul pada daun yang di tandai oleh pakar.




**Gambar 33** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan Mask RCNN Inception V2

Pada gambar 33 arsitektur jaringan mask rcnn inception v2 mampu mengenali objek.sebagai kekurangan sehat, nitrogen dan kalsium. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri kekurangan kalsium pada daun yang di validasi oleh pakar.




**Gambar 34** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan Mask RCNN Inception V2

Pada gambar 34 arsitektur jaringan mask rcnn inception v2 mampu mengenali objek sebagai sehat kekurangan nitrogen, kalsium dan potassium. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri-ciri daun kekurangan potasium muncul pada daun yang di tandai oleh pakar.



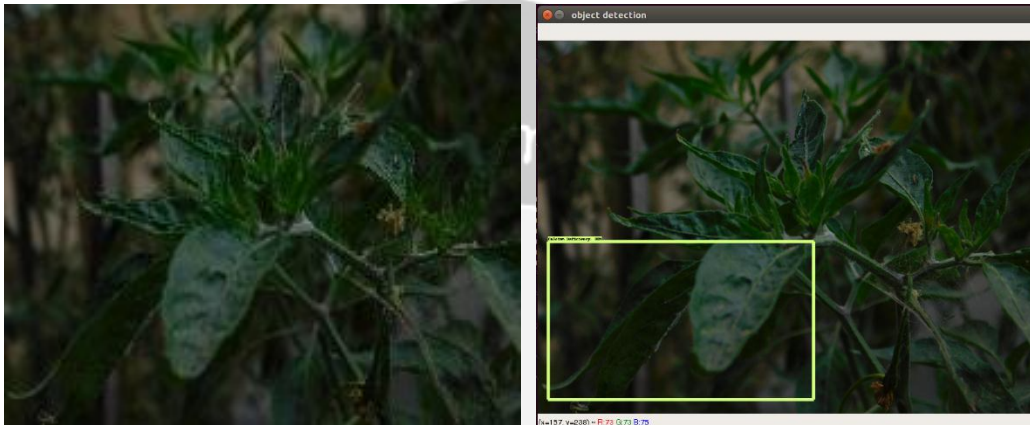
**Gambar 35** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan SSD Mobilenet V2

Pada gambar 35 arsitektur jaringan SSD mobilenet v2 mampu mengenali objek sebagai kekurangan potassium. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri-ciri daun kekurangan potasium muncul pada daun yang di tandai oleh pakar.




**Gambar 36** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan SSD Mobilenet V2

Pada gambar 36 arsitektur jaringan SSD mobilenet v2 mampu mengenali objek sebagai daun sehat. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri-ciri daun sehat muncul pada daun yang di tandai oleh pakar.



**Gambar 37** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan SSD Mobilenet V2

Pada gambar 37 arsitektur jaringan SSD mobilenet v2 mampu mengenali objek sebagai daun kekurangan kalsium. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri-ciri daun kekurangan kalsium muncul pada daun yang di tandai oleh pakar.



**Gambar 38** Kiri : Sebelum Pengujian, Kanan : Setelah Pengujian Menggunakan SSDLITE Mobilenet V2

Pada gambar 38 arsitektur jaringan SSDLITE mobilenet v2 mampu mengenali objek sebagai daun sehat. Hasil ini sesuai dengan validasi pakar bahwa pada daun tersebut memiliki ciri-ciri daun sehat muncul pada daun yang di tandai oleh pakar.

Dari hasil testing ini di cocokan dengan data validasi dari pakar sehingga rincian hasilnya dapat dilihat pada tabel 12.

**Tabel 12 Hasil Pengujian**

| No | Image                | Expert Identification | Detection Result |                        |                      |
|----|----------------------|-----------------------|------------------|------------------------|----------------------|
|    |                      |                       | SSD Mobilenet V2 | Mask RCNN Inception V2 | SSDLITE Mobilenet V2 |
| 1  | DSCN6086             | Calcium Deficiency    | T                | T                      | N                    |
| 2  | DSCN6126             | Calcium Deficiency    | N                | T                      | N                    |
| 3  | DSCN6127             | Calcium Deficiency    | N                | T                      | N                    |
| 4  | DSCN6136             | Calcium Deficiency    | N                | T                      | N                    |
| 5  | DSCN6144             | Calcium Deficiency    | N                | T                      | N                    |
| 6  | Bahtiar-DK-NIT-(110) | Nitrogen Deficiency   | F                | T                      | N                    |
| 7  | Bahtiar-DK-NIT-(111) | Nitrogen Deficiency   | F                | T                      | N                    |
| 8  | Bahtiar-DK-NIT-(113) | Nitrogen Deficiency   | N                | T                      | N                    |
| 9  | Bahtiar-DK-NIT-(114) | Nitrogen Deficiency   | F                | T                      | N                    |
| 10 | Bahtiar-DK-NIT-(115) | Nitrogen Deficiency   | F                | T                      | N                    |
| 11 | Bahtiar-DK-NIT-(116) | Nitrogen Deficiency   | F                | T                      | N                    |
| 12 | Bahtiar-DK-POT-(107) | Potassium Deficiency  | T                | F                      | N                    |
| 13 | Bahtiar-DK-POT-(108) | Potassium Deficiency  | T                | F                      | N                    |
| 14 | Bahtiar-DK-POT-(109) | Potassium Deficiency  | T                | F                      | N                    |
| 15 | Bahtiar-DK-POT-(110) | Potassium Deficiency  | N                | F                      | N                    |
| 16 | Bahtiar-DK-POT-(111) | Potassium Deficiency  | N                | T                      | N                    |



|                                  |                     |                      |        |        |       |
|----------------------------------|---------------------|----------------------|--------|--------|-------|
| 17                               | Bahtiar-DK-POT-(33) | Potassium Deficiency | N      | T      | N     |
| 18                               | DSCN6118            | Healthy              | N      | T      | N     |
| 19                               | DSCN6119            | Healthy              | N      | T      | N     |
| 20                               | DSCN6123            | Healthy              | N      | T      | N     |
| 21                               | DSCN6124            | Healthy              | F      | T      | N     |
| 22                               | DSCN6125            | Healthy              | T      | T      | N     |
| 23                               | DSCN6128            | Healthy              | F      | T      | T     |
| Correct Detection Per Topology   |                     |                      | 5      | 19     | 1     |
| Incorrect Detection Per Topology |                     |                      | 7      | 4      | 0     |
| Not Detected Per Topology        |                     |                      | 11     | 0      | 22    |
| Testing Accuracy                 |                     |                      | 21,74% | 82,61% | 4,35% |

Information :


- T : True Computer Detection
- F : Incorrect Computer Detection
- N : Computer Cannot Detect

Tabel 12 menunjukkan perbandingan dua topologi, topologi Mask RCNN Inception V2 memiliki hasil akurasi testing tertinggi sebesar 82.61% pada 23 gambar testing. Pada gambar dengan identifikasi kekurangan potassium memiliki 4 kesalahan deteksi. Waktu dan pengambilan pengambilan gambar untuk testing sangat mempengaruhi hasil deteksi

### 1. Evaluasi Dataset Cabai-Exp-1 Arsitektur Jaringan Mask RCNN

#### Inception V2

Pada bagian ini akan dilihat hasil yang telah didapat setelah proses evaluasi dataset cabai-exp-1 menggunakan model jaringan Mask RCNN Inception V2 selesai dilakukan. mAP yang tersimpan pada log dapat dilihat pada Gambar 39




**Gambar 39** Grafik mAP Cabai-Exp-1 Mask RCNN Inception V2

Pada Gambar 39 Grafik mAP Cabai-Exp-1 Mask RCNN Inception V2 dilihat bahwa nilai akhir mAP yang didapat pada saat pelatihan adalah 0.146 Untuk durasi pelatihan dalam menyelesaikan epoch 5.000 adalah 14 menit.

## 2. Evaluasi Dataset Cabai-Exp-1 Arsitektur Jaringan SSD Mobilenet V2

Pada bagian ini akan dilihat hasil yang telah didapat setelah proses evaluasi dataset cabai-exp-1 menggunakan model jaringan SSD Mobilenet V2 selesai dilakukan. mAP yang tersimpan pada log dapat dilihat pada Gambar 40




**Gambar 40** Grafik mAP Cabai-Exp-1 SSD Mobilenet V2

Pada Gambar 40 Grafik mAP Cabai-Exp-1 SSD Mobilenet V2 dilihat bahwa nilai akhir mAP yang didapat pada saat pelatihan adalah 0.1557 Untuk durasi pelatihan dalam menyelesaikan epoch 5.000 adalah 19 menit.

### 3. Evaluasi Dataset Cabai-Exp-1 Arsitektur Jaringan SSDLITE Mobilenet V2

Pada bagian ini akan dilihat hasil yang telah didapat setelah proses evaluasi dataset cabai-exp-1 menggunakan model jaringan SSDLite Mobilenet V2 selesai dilakukan. mAP yang tersimpan pada log dapat dilihat pada Gambar 41



**Gambar 41** Grafik mAP Cabai-Exp-1 SSDLite Mobilenet V2


Pada Gambar 41 Grafik mAP Cabai-Exp-1 SSDLite Mobilenet V2 dilihat bahwa nilai akhir mAP yang didapat pada saat pelatihan adalah 0.0588 Untuk durasi pelatihan dalam menyelesaikan epoch 5.000 adalah 20 menit. Berikut ini rincian hasil pengujian dengan 3 models dengan 5000 epoch menghasilkan mAP yang dapat di pada tabel 13

**Tabel 13** Rincian Hasil mAP

| Dataset     | SSD Mobilenet V2 |               | SSDLITE Mobilenet V2 |               | Mask RCNN Inception V2 |               |
|-------------|------------------|---------------|----------------------|---------------|------------------------|---------------|
|             | mAP (%)          | Waktu (Menit) | mAP (%)              | Waktu (Menit) | mAP (%)                | Waktu (Menit) |
| Cabai-EXP-1 | <b>0.1557</b>    | 19            | 0.05826              | 20            | 0.146                  | <b>14</b>     |

Berdasarkan tabel 13 SDD Mobilenet V2 memiliki nilai mAP tertinggi dan Mask RCNN memiliki waktu tercepat dalam mendeteksi objek secara presisi. mAP merupakan salah satu cara untuk evaluasi terhadap suatu model. Nilai mAP berasal dari nilai deteksi positif dibagi semua nilai deteksi positif seperti persamaan 3 dibawah ini.

$$mAP = \frac{1}{N} \sum_{n=1}^N \frac{\text{Positive Detections}}{\text{All Positive Detections}} \quad (3)$$



## **BAB VI**

### **KESIMPULAN DAN SARAN**

#### **A. Kesimpulan**

Dari penelitian ini diperoleh beberapa kesimpulan yaitu :

1. Hasil pelatihan dan pengujian menunjukan Mask RCNN inception V2 menjadi model terbaik dari 3 model yang digunakan.
2. Teknologi deep learning mampu mengenali kekurangan unsur hara tanaman cabai berdasarkan citra dengan akurasi 82.61%. Presisi dan waktu pengambilan gambar akan mempengaruhi hasil deteksi.
3. Hasil mAP untuk dataset ini tertinggi sebesar 15.57 %.

#### **B. Saran**

Adapun saran dari penulis untuk penelitian berikutnya adalah :

1. Konsep arsitektur jaringan Mask RCNN dapat dilakukan penelitian lebih lanjut yang kompetebel dalam bentuk mobile apps.
2. Penambahan dataset yang lebih banyak dan dalam berbagai kondisi cuaca (normal, cerah, mendung) serta waktu (pagi, siang, malam) akan menghasilkan hasil yang lebih variatif dan akurat.
3. Modifikasi hyperparameter di masing-masing arsitektur jaringan dapat menjadikan penemuan baru untuk hasil *inference* yang lebih baik

## DAFTAR PUSTAKA

- Alan Turing. (1953). Digital Computers Applied To Games. In *B. Bowden (Ed)* (pp. 286–310). London: Pitman.
- Brandoli, B., Orue, J. P. M., Arruda, M. S., Santos, C. V., Sarath, D. S., Goncalves, W. N., ... Rodrigues-jr, J. F. (2016). BioLeaf : A professional mobile application to measure foliar damage caused by insect herbivory. *Computers and Electronics in Agriculture*, *129*, 44–55. <https://doi.org/10.1016/j.compag.2016.09.007>
- Breck, E., Polyzotis, N., Roy, S., Whang, S. E., & Zinkevich, M. (2019). Data Validation for Machine Learning. *Proc. of the 2nd SysML Conference, 2019*.
- Cao, Y., Niu, X., & Dou, Y. (2016). Region-based Convolutional Neural Networks for Object Detection in Very High Resolution Remote Sensing Images. *2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 548–554. <https://doi.org/10.1109/FSKD.2016.7603232>
- Chen, Q., Shinozaki, D., Luo, J., Pottier, M., Have, M., Marmagne, A., ... Masclaux-Daubresse, C. (2019). Autophagy and Nutrients Management in Plants. *Cells*, *8*(11), 1–17. <https://doi.org/10.3390/cells8111426>
- Cheng, G., Wan, Y., Saudagar, A. N., & Jan, C. V. (2015). Advances in Human Action Recognition : A Survey. *CoRR*, 1–30.
- Farhadi, F. (2017). *Learning Activation Functions in Deep Neural Networks*. *Doctoral dissertation, École Polytechnique de Montréal*. UNIVERSITÉ DE MONTRÉAL ÉCOLE. Retrieved from <https://publications.polymtl.ca/2945/>
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2016). Region-based Convolutional Networks for Accurate Object Detection and Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *38*(1), 142–158. <https://doi.org/10.1109/TPAMI.2015.2437384>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Adaptive Computation and Machine Learning Thomas (Deep Learn)*. London, England: Massachusetts Institute of Technology.
- Google. (2017, January 26). Tensorflow Detection Model Zoo. Retrieved from [https://github.com/tensorflow/models/blob/master/research/object\\_detection/g3doc/detection\\_model\\_zoo.md](https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/detection_model_zoo.md)

- Gurney, K. (1997). *An introduction to neural networks*. London: UCL Press.
- Hakak, S., Kamsin, A., Palaiahnakote, S., & Tayan, O. (2018). Residual-based approach for authenticating pattern of multi-style diacritical Arabic texts, 4–6.
- He, K., Gkioxari, G., Dollar, P., & Girshick, R. (2017). Mask R-CNN. In *The IEEE International Conference on Computer Vision (ICCV)* (pp. 2961–2969).
- He, K., Zhang, X., Ren, S., & Jian, S. (2016). Deep Residual Learning for Image Recognition. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (pp. 770–778).  
<https://doi.org/10.1109/CVPR.2016.90>
- Hijazi, S., Kumar, R., Rowen, C., Group, I., & Cadence. (2015). Using Convolutional Neural Networks for Image Recognition, 1–12.
- Hu, W., Huang, Y., Wei, L., Zhang, F., & Li, H. (2015). Deep Convolutional Neural Networks for Hyperspectral Image Classification. *Journal of Sensors, 2015*. <https://doi.org/http://dx.doi.org/10.1155/2015/258619>
- Indolia, S., Kumar, A., Mishra, S. P., & Asopa, P. (2018). ScienceDirect Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. *Procedia Computer Science, 132*, 679–688.  
<https://doi.org/10.1016/j.procs.2018.05.069>
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift. *CoRR, abs/1502.0*. Retrieved from <http://arxiv.org/abs/1502.03167>
- Jalled, F., & Voronkov, I. (2016). Object Detection Using Image Processing, 1–6. Retrieved from <https://arxiv.org/abs/1611.07791>
- Kestur, R., Meduri, A., & Narasipura, O. (2019). Engineering Applications of Artificial Intelligence MangoNet : A deep semantic segmentation architecture for a method to detect and count mangoes in an open orchard. *Engineering Applications of Artificial Intelligence, 77*(April 2018), 59–69.  
<https://doi.org/10.1016/j.engappai.2018.09.011>
- Khandelwal, R. (2019). No Title. Retrieved January 27, 2020, from <https://towardsdatascience.com/computer-vision-instance-segmentation-with-mask-r-cnn-7983502fcad1>
- Kim, P. (2017). *MATLAB Deep Learning With Machine Learning, Neural*

*Networks and Artificial Intelligence*. Apress. <https://doi.org/10.1007/978-1-4842-2845-6>

- Lin, T., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... Zitnick, C. L. (2014). Microsoft COCO : Common Objects in Context. In *Lecture Notes in Computer Science* (pp. 740–755). Computer Vision – ECCV 2014. [https://doi.org/https://doi.org/10.1007/978-3-319-10602-1\\_48](https://doi.org/https://doi.org/10.1007/978-3-319-10602-1_48)
- Liu, B., Yun, Z., He, D., & Yuxiang, L. (2018). Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks. *Symmetry*, *10*(1), 1–16. <https://doi.org/https://doi.org/10.3390/sym10010011>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., & Berg, A. C. (2016). SSD : Single Shot MultiBox Detector. *Lecture Notes in Computer Science*, 21–37. [https://doi.org/10.1007/978-3-319-46448-0\\_2](https://doi.org/10.1007/978-3-319-46448-0_2)
- Miller, A. J., & Centre, J. I. (2016). *Plant Mineral Nutrition*. eLS. JohnWiley & Sons. <https://doi.org/10.1002/9780470015902.a0023717>
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, *7*, 1419. <https://doi.org/10.3389/fpls.2016.01419>
- Muliana, V. A. (2017). 8 Negara Produsen Cabai Terbesar di Dunia, RI Termasuk? Retrieved June 26, 2019, from <https://www.liputan6.com/bisnis/read/2819761/8-negara-produsen-cabai-terbesar-di-dunia-ri-termasuk>
- Müller, A. C., & Sarah, G. (2017). *Introduction to Machine Learning with Python*. United States of America: O'Reilly Media.
- Nie, S., Leeman-munk, S., Healey, C. G., Padia, K., Benson, J. R., & Devarajan, R. (2018). Visualizing Deep Neural Networks for Text Analytics. *2018 IEEE Pacific Visualization Symposium (PacificVis)*, 180–189. <https://doi.org/10.1109/PacificVis.2018.0003>
- Olgac, A. V., & Karlik, B. (2011). Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. *International Journal of Artificial Intelligence And Expert Systems*, *1*(4), 111–122.
- Pertanian, P. D. dan S. I. (2016). *OUTLOOK KOMODITAS PERTANIAN SUB SEKTOR HORTIKULTURA* (Cabai Mera). Jakarta: Pusat Data dan Sistem Informasi Pertanian Sekretariat Jenderal Kementerian Pertanian Republik



Indonesia Tahun 2016.

- Petrellis, N. (2018). A Review of Image Processing Techniques Common in Human and Plant Disease Diagnosis. *Symmetry*, *10*(270), 2–35. <https://doi.org/10.3390/sym10070270>
- Potamianos, G., Neti, C., Gravier, G., Garg, A., Member, S., Senior, A. W., & Member, S. (2003). Recent Advances in the Automatic Recognition of Audio-Visual Speech. *Proceedings of the IEEE*, *91*(9), 1–18.
- Qin, F., Liu, D., Sun, B., Ruan, L., Ma, Z., & Wang, H. (2016). Identification of Alfalfa Leaf Diseases Using Image Recognition Technology. *PLOS ONE*, *11*(12), 1–26. <https://doi.org/https://doi.org/10.1371/journal.pone.0168274>
- Rahnemoonfar, M., & Sheppard, C. (2017). Deep Count : Fruit Counting Based on Deep Simulated Learning. *Sensors*, *17*(4), 1–12. <https://doi.org/10.3390/s17040905>
- Ramcharan, A., Mccloskey, P., Baranowski, K., Mbilinyi, N., Mrisho, L., Ndalahwa, M., ... Hughes, D. P. (2019). A Mobile-Based Deep Learning Model for Cassava Disease Diagnosis. *Frontiers in Plant Science*, *10*, 272. <https://doi.org/10.3389/fpls.2019.00272>
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN : Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *39*(6), 1137–1149.
- Robbins, W. J. (1944). THE IMPORTANCE OF PLANTS. *Science*, *100*(2603), 440–443.
- Rompas, J. P. (2001). Efek Isolasi Bertingkat Colletorichum Capsici Terhadap Penyakit Antraknosa Pada Cabai. *Prosiding Kongres Nasional XVI Dan Seminar Ilmiah*, 163.
- Sahare, P., & Dhok, S. B. (2017). Review of Text Extraction Algorithms for Scene- text and Document Images. *IETE Technical Review*, *34*(2), 144–164. <https://doi.org/10.1080/02564602.2016.1160805>
- Schillaci, G., Pennisi, A., Franco, F., & Longo, D. (2012). Detecting tomato crops in greenhouses using a vision based method. *International Conference on Safety Health and Welfare in Agriculture and in Agro-Food Systems*, (1), 252–258. Retrieved from [http://www.ragusashwa.it/CD\\_2012/lavori/TOPIC5/orale/topic\\_5\\_252\\_258.pdf](http://www.ragusashwa.it/CD_2012/lavori/TOPIC5/orale/topic_5_252_258.pdf)

- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*, 2016. <https://doi.org/https://doi.org/10.1155/2016/3289801>
- Snyder, J. A., & Fedorovskaya, E. A. (2011). Digital Image Processing and Analysis : Human and Computer Vision Applications with CVPtools , Second Edition. *Jour Nal of Electronic I Maging*, 20(3), 039901–1 – 039901–039903. <https://doi.org/10.1117/1.3628179>
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2016). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Computer Vision and Pattern Recognition*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2014). Going deeper with convolutions. *CoRR*, abs/1409.4, 1–12.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (pp. 2818–2826). IEEE. <https://doi.org/10.1109/CVPR.2016.308>
- Venkatachalam, Y. K. R. (2018). Human and Machine Learning. *Computational Economics*, (February). <https://doi.org/10.1007/s10614-018-9803-z>
- Victoria, A. O. (2019). BPS: Inflasi Juni Capai 0,55% Akibat Tingginya Harga Cabai Merah. Retrieved July 5, 2019, from <https://katadata.co.id/berita/2019/07/01/bps-inflasi-juni-capai-055-akibat-tingginya-harga-cabai-merah>
- Wakhyono, S. (2018). Jateng Jadi Penyangga Terbesar Bawang Merah dan Cabai Nasional. Retrieved June 26, 2019, from <https://fajar.co.id/2018/08/20/jateng-jadi-penyangga-terbesar-bawang-merah-dan-cabai-nasional-2/>
- worldofchillies. (n.d.). chilli-plant-nutrient-guide. Retrieved April 16, 2019, from [https://www.worldofchillies.com/growing\\_chillies/growing-tips/chilli-plant-nutrient-guide/chilliplantnutrientguide.html](https://www.worldofchillies.com/growing_chillies/growing-tips/chilli-plant-nutrient-guide/chilliplantnutrientguide.html)
- Yamashita, R., Nishio, M., Kinh, R., Do, G., & Togashi, K. (2018). Convolutional neural networks : an overview and application in radiology. *Insights into Imaging*, 9(4), 611–629. <https://doi.org/https://doi.org/10.1007/s13244-018-0639-9>

## LAMPIRAN

### Lampiran 1 Surat Ijin Penelitian Di Kelompok Tani Argoayuningtani



**UNIVERSITAS ATMA JAYA YOGYAKARTA**  
Program Pascasarjana

Nomor: 563 /Eks/PPS/VI/2019  
Lamp. : -  
Perihal: Permohonan Izin Penelitian

Kepada Yth.  
Ketua Kelompok Tani Argoayuningtani  
Desa Senden, Kecamatan Selo, Kabupaten Boyolali

Dengan hormat,

Yang bertandatangan di bawah ini, Ketua Program Studi Magister Teknik Informatika Program Pascasarjana Universitas Atma Jaya Yogyakarta, memohon izin bagi mahasiswa kami :

Nama : Arief Rais Bahtiar  
No. Mahasiswa : 185302898

Untuk mengadakan pencarian data di instansi yang Bapak/Ibu pimpin, guna pengumpulan data penelitian sebagai salah satu syarat menyelesaikan studi di Magister Teknik Informatika Program Pascasarjana Universitas Atma Jaya Yogyakarta.


Adapun Judul Penelitian mahasiswa kami adalah *Deep Learning Untuk Deteksi Jenis Unsur Hara Yang Dibutuhkan Tanaman Cabai*.

Demikian permohonan kami. Atas perhatian dan kerjasama Bapak/Ibu, kami mengucapkan terima kasih.

Yogyakarta, 18 September 2019  
Kaprodi Magister Teknik Informatika,

Ir. Djoko Budiyanto.,M.Eng.,Ph.D

## Lampiran 2 Surat Rekomendasi Penelitian Dari Pemerintah Kabupaten Boyolali



**PEMERINTAH KABUPATEN BOYOLALI**  
**KANTOR KESATUAN BANGSA DAN POLITIK**  
 Kompleks Perkantoran Terpadu Kabupaten Boyolali  
 Jl. Merdeka Timur Kemiri, Boyolali 57321, Provinsi Jawa Tengah  
 Telp. (0276) 321087 Fax. (0276) 321087, e-mail [kankesbangpol@boyolali.go.id](mailto:kankesbangpol@boyolali.go.id)  
 Website: [www.boyolali.go.id](http://www.boyolali.go.id)

---

**SURAT REKOMENDASI PENELITIAN**  
 NOMOR : 070/422/VII/39/2019

I. **DASAR** : Peraturan Menteri Dalam Negeri Republik Indonesia. Nomor 7 Tahun 2014 Tanggal 21 Desember 2014 Tentang Perubahan Atas Permendagri Nomor 64 Tahun 2014 Tentang Pedoman Penerbitan Rekomendasi Penelitian;

II. **MEMBACA** : 1. Surat dari BP3D Kab. Boyolali, Nomor : 070/445/35/2019, tanggal 24 Juni 2019, Perihal : **Rekomendasi Teknis Penelitian**.  
 2. Surat dari Program Pascasarjana Universitas Atma Jaya Yogyakarta, Nomor : 486/PPS/VI/2019, tanggal 18 Juni 2019, Perihal : **Permohonan Izin Penelitian**.

III. Prinsipnya **TIDAK** **KEBERATAN** / Dapat Menerima atas pelaksanaan Penelitian / Magang/ KKN di Kabupaten Boyolali.

1. **N a m a / NIM** : **ARIEF RAIS BAHTIAR / 185302898**

2. **Alamat** : Rejosari RT 06 RW 01, Glonggong, Nogosari, Boyolali

3. **No HP** : 085819701530

4. **Pekerjaan** : Mahasiswa

5. **Penanggung Jawab** : Ir. A. Djoko Budiyanto, M.Eng., Ph.D.

6. **Judul Kegiatan** : **"DEEP LEARNING UNTUK DETEKSI JENIS UNSUR HARA YANG DIBUTUHKAN TANAMAN CABAI"**

7. **L o k a s i** : - Dinas Pertanian Kab. Boyolali  
 - Wilayah Kecamatan Selo, Cepogo, Sawit, dan Mojosongo Kab. Boyolali

8. **Peserta** : 1 orang.

IV. Ketentuan-ketentuan sebagai berikut:

1. Sebelum melakukan kegiatan terlebih dahulu melaporkan kepada Pejabat Setempat / Lembaga Swasta yang akan dijadikan objek lokasi untuk mendapatkan petunjuk seperlunya dengan menunjukkan Surat Pemberitahuan ini.

2. Pelaksanaan Penelitian/ Magang/ KKN tidak disalahgunakan untuk tujuan tertentu yang dapat mengganggu kestabilan pemerintahan. Untuk Penelitian/Magang yang mendapat dukungan dana dari sponsor baik dari dalam negeri maupun luar negeri, agar dijelaskan pada saat mengajukan perijinan. Tidak membahas masalah politik dan / atau agama yang dapat menimbulkan terganggunya stabilitas keamanan dan ketertiban.

3. Surat Rekomendasi dapat dicabut dan dinyatakan tidak berlaku apabila pemegang Surat Rekomendasi ini tidak mentaati / mengindahkan peraturan yang berlaku atau obyek Penelitian / Magang / Pengabdian Masyarakat / KKN menolak untuk menerima Peserta Penelitian / Magang / Pengabdian Masyarakat / KKN.


4. Setelah Penelitian/ Magang / Pengabdian Masyarakat / KKN selesai, supaya menyerahkan hasilnya kepada Kantor Kesatuan Bangsa dan Politik Kabupaten Boyolali.

V. Surat Rekomendasi Penelitian/Magang berlaku :

1. **Berlaku** : Dari tanggal : **22 Juli 2019** S/d tanggal : **22 Oktober 2019**

2. **Perpanjangan** : Dari tanggal : S/d tanggal :

Dikeluarkan di : **BOYOLALI**  
 Pada tanggal : 08 Juli 2019  
 An. **KEPALA KANTOR KESBANGPOL**  
**KABUPATEN BOYOLALI**  
 Kasubag Tata Usaha

  
**YUNI, SH, M.Si**  
 Pembina  
 NIP. 19620810 199103 2 004

**TEMBUSAN** Kepada Yth:

- Bupati Boyolali (sebagai laporan);
- Kapolres Boyolali;
- Kepala BP3D Kab. Boyolali;
- Kepala Dinas Pertanian Kab. Boyolali;
- Camat Selo Kab. Boyolali;
- Camat Cepogo Kab. Boyolali;
- Camat Sawit Kab. Mojosongo;
- Camat Mojosongo Kab. Boyolali;
- Kepala Desa di Wilayah Kec. Selo;
- Kepala Desa di Wilayah Kec. Cepogo;
- Kepala Desa di Wilayah Kec. Sawit;
- Kepala Desa di Wilayah Kec. Mojosongo.

### Lampiran 3 Surat Permintaan Menjadi Pakar Pertanian



**UNIVERSITAS ATMA JAYA YOGYAKARTA**  
Program Pascasarjana

Nomor: 560/Eks/VI/PPS/2019  
Lamp. : -  
Perihal: Permohonan menjadi pakar pertanian

Kepada Yth.  
Ibu Jujuk Juhariah, S.Pd. M.Sc.  
Dosen Fakultas Pertanian  
Universitas Boyolali  
Jalan Pendaran 405, Boyolali

Dengan hormat,

Sehubungan dengan penulisan tesis mahasiswa Program Studi Magister Teknik Informatika Program Pascasarjana Universitas Atma Jaya Yogyakarta, dengan ini kami mohon Ibu berkenan menjadi pakar pertanian dalam penyusunan tesis :

Nama : Arief Rais Bahtiar  
No. Mahasiswa : 185302898  
Judul tesis : *Deep Learning* untuk Deteksi Jenis Unsur Hara yang Dibutuhkan Tanaman Cabai.

Demikian permohonan kami. Atas perhatian dan bantuan Ibu, kami mengucapkan terima kasih.

Yogyakarta, 18 September 2019  
Program Studi Magister Teknik Informatika  
Ketua,



Ir. Djoko Budiyanto S., M.Eng., Ph.D.

#### Lampiran 4 Dokumentasi Pengambilan Dataset



### Lampiran 5 Dokumentasi Pelabelan Dengan Pakar Pertanian



### Lampiran 6 Peta Lokasi Pengambilan Dataset Tanaman Cabai Keriting

