

# PENGEMBANGAN *RESIDUAL NETWORK* DENGAN *ADAPTIVE MULTI-SCALE META-REPRESENTATION* PADA *META-LEARNING* UNTUK KLASIFIKASI PENYAKIT KERITING DAUN CABAI

RIZAL AMEGIA SAPUTRA



PROGRAM STUDI DOKTOR ILMU KOMPUTER  
SEKOLAH SAINS DATA, MATEMATIKA, DAN INFORMATIKA  
INSTITUT PERTANIAN BOGOR

BOGOR  
2026



## PERNYATAAN MENGENAI DISERTASI DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa disertasi dengan judul “Pengembangan *Residual Network* dengan *Adaptive Multi-Scale Meta-Representation* pada *Meta-Learning* untuk Klasifikasi Penyakit Keriting Daun Cabai” adalah karya saya dengan arahan dari dosen pembimbing dan belum diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka di bagian akhir disertasi ini.

Dengan ini saya melimpahkan hak cipta dari karya tulis saya kepada Institut Pertanian Bogor.

Bogor, Juli 2026

Rizal Amegia Saputra  
G6601231005

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

## RINGKASAN

RIZAL AMEGIA SAPUTRA. Pengembangan *Residual Network* dengan *Adaptive Multi-Scale Meta-Representation* pada *Meta-Learning* untuk Klasifikasi Penyakit Keriting Daun Cabai. Dibimbing oleh AGUS BUONO, KARLISA PRIANDANA, SAMSUZANA ABD AZIZ dan MUHAMAD SYUKUR.

Produksi tanaman cabai di Indonesia masih menghadapi berbagai kendala, salah satunya adalah penyakit keriting daun yang disebabkan oleh infeksi virus maupun serangan hama. Kemiripan gejala visual antarpenyakit menyebabkan proses identifikasi secara manual memerlukan keahlian pakar, bersifat subjektif, serta membutuhkan waktu yang relatif lama. Berbagai penelitian telah mengembangkan metode klasifikasi citra berbasis *deep learning*, khususnya menggunakan arsitektur CNN yang telah memberikan akurasi tinggi dalam mendeteksi penyakit tanaman. Namun, sebagian besar pendekatan tersebut memerlukan *dataset* berukuran besar agar model mampu mempelajari representasi fitur secara optimal. Pada kasus penyakit keriting daun cabai, ketersediaan *dataset* berlabel masih terbatas sehingga meningkatkan risiko *overfitting*, menurunkan kemampuan generalisasi model, dan menyebabkan proses pelatihan menjadi kurang optimal. Penelitian ini bertujuan mengembangkan metode klasifikasi penyakit keriting daun cabai pada kondisi *few-shot learning* melalui pengembangan ResNet-50Plus sebagai *domain-specific pretrained backbone*, integrasi *backbone* berbasis *Efficient Channel Attention* (ECA) ke dalam *framework meta-learning*, serta pengembangan *adaptive multi-scale meta-representation* berbasis *adaptive attention* dan *adaptive feature fusion* untuk menghasilkan representasi fitur (*embedding*) yang lebih adaptif dan diskriminatif. Evaluasi kinerja model dilakukan menggunakan *confusion matrix*, *precision*, *recall*, *F1-score*, waktu pelatihan, serta penggunaan memori GPU.

Penelitian tahap pertama difokuskan pada pengembangan ResNet-50Plus sebagai *domain-specific pretrained backbone* untuk meningkatkan kualitas representasi fitur pada klasifikasi penyakit keriting daun cabai. Pengembangan dilakukan dengan mengganti seluruh fungsi aktivasi ReLU pada ResNet-50 menjadi LeakyReLU, serta menambahkan lapisan *dropout* untuk meningkatkan kemampuan generalisasi model. Selain itu, proses pelatihan dioptimalkan menggunakan strategi *MixUp augmentation*, *Label Smoothing*, dan *Warmup-Cosine learning rate scheduler*. Hasil evaluasi berdasarkan rata-rata lima kali percobaan menggunakan *random seed* 42–46, konfigurasi lengkap ResNet-50Plus + *mixup* + *label smoothing* + *warmup (Full)* memperoleh akurasi rata-rata 83,08%, lebih tinggi dibandingkan ResNet-50 sebesar 79,37%. Model ini juga menunjukkan performa yang lebih stabil, dengan hasil standar deviasi akurasi 3,11 dan koefisien variasi 3,74%, lebih rendah dibanding ResNet-50. Hasil visualisasi menggunakan Grad-CAM juga menunjukkan bahwa ResNet-50Plus telah memfokuskan perhatian pada area daun yang mengalami gejala penyakit maupun serangan hama sehingga menghasilkan representasi fitur yang lebih relevan. Meskipun demikian, penelitian ini masih terbatas pada skenario *supervised learning*. ResNet-50Plus yang dikembangkan belum dimanfaatkan sebagai *domain-specific pretrained backbone* dalam *framework meta-learning*, sehingga kemampuan adaptasi model pada kondisi *few-shot learning* belum dievaluasi.



Penelitian tahap selanjutnya mengintegrasikan *backbone* ResNet-50Plus berbasis *chili-domain pretrained* ke dalam *framework meta-learning* untuk meningkatkan kemampuan adaptasi pada skenario *few-shot learning*. Hasil evaluasi menunjukkan bahwa penggunaan *chili-domain pretrained initialization* secara konsisten menghasilkan performa yang lebih baik dibandingkan *random initialization* pada seluruh skenario pengujian. Selanjutnya, pengembangan *backbone* melalui integrasi *Efficient Channel Attention* (ECA) meningkatkan akurasi FOMAML pada skenario 10-shot dari 95,94% menjadi 95,97%. Meskipun peningkatan akurasi tersebut belum signifikan secara statistik, integrasi ECA memberikan efisiensi komputasi yang lebih baik melalui penurunan waktu pelatihan dan penggunaan memori GPU, serta menghasilkan representasi fitur yang lebih berkualitas. Dari ketiga *framework meta-learning* yang dievaluasi, FOMAML secara konsisten memberikan performa terbaik dibandingkan ProtoNet dan RelationNet. Hasil *confusion matrix* dan visualisasi Grad-CAM, pengembangan *backbone* secara bertahap menghasilkan representasi fitur yang lebih relevan terhadap karakteristik penyakit. Meskipun demikian, masih terdapat kesalahan klasifikasi pada kelas dengan karakteristik visual yang serupa, sehingga penelitian selanjutnya difokuskan pada pengembangan *Adaptive Multi-Scale Efficient Channel Attention* (MS-AECA) untuk memanfaatkan representasi fitur multi-skala dan menghasilkan embedding yang lebih diskriminatif.

Selanjutnya pengembangan MS-AECA dengan mengintegrasikan representasi fitur multi-skala, *Adaptive Efficient Channel Attention* (AECA), dan *adaptive feature fusion* ke dalam *framework* FOMAML berbasis ResNet-50Plus. Berbeda dengan penelitian sebelumnya yang hanya menerapkan ECA pada representasi fitur satu skala, AECA yang diusulkan mengombinasikan mekanisme perhatian kanal lokal dari ECA dengan jalur MLP untuk memodelkan dependensi kanal global. Kontribusi jalur MLP dikendalikan menggunakan parameter skala  $\lambda$  sehingga perhatian kanal dapat dipelajari secara lebih adaptif sesuai karakteristik fitur. Selanjutnya, representasi fitur dari *layer 3* dan *layer 4* digabungkan melalui mekanisme *adaptive feature fusion* berbasis *learnable gating* sehingga kontribusi informasi lokal dan semantik dipelajari secara dinamis untuk menghasilkan *embedding* yang lebih diskriminatif. Hasil pengujian menunjukkan bahwa FOMAML dengan MS-AECA memperoleh performa terbaik dengan akurasi  $96,77 \pm 0,39\%$  pada skenario 10-shot, meningkat 0,80% dibandingkan *backbone* ResNet-50Plus+ECA  $95,97 \pm 1,53\%$ . Selain meningkatkan akurasi, pendekatan yang diusulkan juga mempercepat waktu pelatihan dari 88,31 menjadi 87,79 menit, dengan peningkatan penggunaan memori GPU yang relatif kecil dari 5,17 GB menjadi 5,2582 GB serta jumlah parameter dari 23,771 juta menjadi 24,610 juta. Nilai standar deviasi yang lebih rendah menunjukkan bahwa MS-AECA menghasilkan performa yang lebih stabil dan konsisten pada berbagai episode *few-shot learning*, sehingga dapat meningkatkan kualitas representasi fitur dibandingkan pendekatan pada penelitian sebelumnya.

Kata kunci: *dropout*, *fomaml*, *leaky relu*, penyakit keriting, *resnet*.

## SUMMARY

RIZAL AMEGIA SAPUTRA. Development of a Residual Network with Adaptive Multi-Scale Meta-Representation for Meta-Learning-Based Classification of Chili Leaf Curl Disease. Supervised by AGUS BUONO, KARLISA PRIANDANA, SAMSUZANA ABD AZIZ and MUHAMAD SYUKUR.

Chili pepper production in Indonesia still faces various challenges, one of which is leaf curl disease caused by viral infections or hama infestations. The similarity in visual symptoms across different diseases means that manual identification requires expert knowledge, is subjective, and takes a relatively long time. Various studies have developed image classification methods based on deep learning, particularly using CNN architectures, which have demonstrated high accuracy in detecting plant diseases. However, most of these approaches require large datasets for the model to optimally learn feature representations. In the case of chili leaf curl disease, the availability of labeled datasets remains limited, thereby increasing the risk of overfitting, reducing the model's generalization ability, and resulting in a suboptimal training process. This study aims to develop a classification method for chili leaf curl disease under few-shot learning conditions by developing ResNet-50Plus as a domain-specific pretrained backbone, integrating an Efficient Channel Attention (ECA)-based backbone into a meta-learning framework, and developing an adaptive multi-scale meta-representation based on adaptive attention and adaptive feature fusion to produce more adaptive and discriminative feature representations (embeddings). Model performance was evaluated using the confusion matrix, precision, recall, F1-score, training time, and GPU memory usage.

The first phase of the research focused on developing ResNet-50Plus as a domain-specific pretrained backbone to improve the quality of feature representations in the classification of chili leaf curl disease. This was achieved by replacing all ReLU activation functions in ResNet-50 with LeakyReLU and adding a dropout layer to enhance the model's generalization ability. Additionally, the training process was optimized using the MixUp augmentation strategy, label smoothing, and the warm-up-cosine learning rate scheduler. The evaluation results are based on an average of five trials using random seeds 42–46, the complete configuration of ResNet-50Plus + mixup + label smoothing + warmup (Full) obtained an average accuracy of 83.08%, higher than ResNet-50 at 79.37%. This model also showed more stable performance, with an accuracy standard deviation of 3.11 and a coefficient of variation of 3.74%, lower than ResNet-50. Visualization results using Grad-CAM also show that ResNet-50Plus can focus attention on areas of leaves exhibiting disease symptoms or pest infestations, thereby producing more relevant feature representations. However, this study is still limited to supervised learning scenarios. The developed ResNet-50Plus has yet to be utilized as a domain-specific pretrained backbone within a meta-learning framework; therefore, the model's adaptability under few-shot learning conditions remains unevaluated.

The next phase of the research integrated a ResNet-50Plus backbone based on chili-domain pretraining into a meta-learning framework to enhance adaptability in few-shot learning scenarios. Evaluation results show that the use of a zero-domain pretrained initialization consistently yields better performance than random



initialization across all test scenarios. Furthermore, the development of the backbone through the integration of Efficient Channel Attention (ECA) improved FOMAML's accuracy in the 10-shot scenario from 95.94% to 95.97%. Although this increase in accuracy is not yet statistically significant, the integration of ECA provides better computational efficiency by reducing training time and GPU memory usage, while also producing higher-quality feature representations. Of the three meta-learning frameworks evaluated, FOMAML consistently delivered the best performance compared to ProtoNet and RelationNet. Based on the confusion matrix results and Grad-CAM visualizations, the gradual development of the backbone produced feature representations that were more relevant to disease characteristics. However, classification errors still occurred in classes with similar visual characteristics; therefore, future research will focus on developing Adaptive Multi-Scale Efficient Channel Attention (MS-AECA) to leverage multi-scale feature representations and generate more discriminative embeddings. Next, we developed MS-AECA by integrating multiscale feature representations, Adaptive Efficient Channel Attention (AECA), and adaptive feature fusion into the ResNet-50Plus-based FOMAML framework. Unlike previous studies that only applied ECA to single-scale feature representations, the proposed AECA combines ECA's local channel attention mechanism with an MLP path to model global channel dependencies. The contribution of the MLP path is controlled using the scale parameter  $\lambda$  (lambda) so that channel attention can be learned more adaptively according to feature characteristics. Furthermore, the feature representations from layer 3 and layer 4 are fused via an adaptive feature fusion mechanism based on learnable gating, allowing the contributions of local and semantic information to be learned dynamically to produce more discriminative embeddings. Test results show that FOMAML with MS-AECA achieves the best performance with an accuracy of  $96.77 \pm 0.39\%$  in the 10-shot scenario, an improvement of 0.80% compared to the ResNet-50Plus+ECA backbone  $95.97 \pm 1.53\%$ . In addition to improving accuracy, the proposed approach also reduces training time from 88.31 to 87.79 minutes, with a relatively small increase in GPU memory usage from 5.17 GB to 5.2582 GB and in the number of parameters from 23.771 million to 24.610 million. The lower standard deviation shows that MS-AECA gives more stable and consistent performance across different few-shot learning episodes. This makes the quality of feature representations better than in previous studies.

Keywords: curly leaf disease, dropout, fomaml, leaky relu, resnet.



Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

© Hak Cipta milik IPB, tahun 2026  
Hak Cipta dilindungi Undang-Undang

*Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan atau menyebutkan sumbernya. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik, atau tinjauan suatu masalah, dan pengutipan tersebut tidak merugikan kepentingan IPB.*

*Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apa pun tanpa izin IPB.*



# **PENGEMBANGAN *RESIDUAL NETWORK* DENGAN *ADAPTIVE MULTI-SCALE META-REPRESENTATION* PADA *META-LEARNING* UNTUK KLASIFIKASI PENYAKIT KERITING DAUN CABAI**

@Hak cipta milik IPB University

**RIZAL AMEGIA SAPUTRA**

Disertasi  
sebagai salah satu syarat untuk memperoleh gelar  
Doktor pada  
Program Studi Ilmu Komputer

**PROGRAM STUDI DOKTOR ILMU KOMPUTER  
SEKOLAH SAINS DATA, MATEMATIKA, DAN INFORMATIKA  
INSTITUT PERTANIAN BOGOR  
BOGOR  
2026**



@Hak cipta milik IPB University

IPB University



Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

Penguji Luar Komisi Pembimbing pada Ujian Tertutup Disertasi:

- 1 Prof. Dr. Ir. Mochamad Wahyudi, M.Kom, MM, M.Pd, IPU, ASEAN Eng
- 2 Dr. Aziz Kustiyo, S.Si., M.kom

Promotor Luar Komisi Pembimbing pada Sidang Promosi Terbuka Disertasi:

- 1 Prof. Dr. Ir. Mochamad Wahyudi, M.Kom, MM, M.Pd, IPU, ASEAN Eng
- 2 Dr. Aziz Kustiyo, S.Si., M.kom



Judul Disertasi : Pengembangan *Residual Network* dengan *Adaptive Multi-Scale Meta-Representation* pada *Meta-Learning* untuk Klasifikasi Penyakit Keriting Daun Cabai

Nama : Rizal Amegia Saputra  
NIM : G6601231005

Disetujui oleh

Pembimbing 1:  
Prof. Dr. Ir. Agus Bueno, M.Si, M.Kom

Pembimbing 2:  
Dr. Karlisa Priandana, S. T, M.Eng

Pembimbing 3:  
Prof. Madya Dr. Samsuzana Abd Aziz, B.Eng,  
M.Sc, SMIEEE

Pembimbing 4:  
Prof. Dr. Muhamad Syukur, S.P., M. Si

**DR. SAMSUZANA ABD AZIZ**  
Associate Professor  
Department of Biological and Agricultural Engineering  
Faculty of Engineering  
Universiti Putra Malaysia  
43400 UPM Serdang, Selangor D.E

Diketahui oleh

Ketua Program Studi:  
Prof. Dr. Imas Sukaesih Sitanggang, S.Si., M.Kom.  
NIP 197501301998022001

Dekan Sekolah Sains Data, Matematika, dan Informatika  
Prof. Dr. Ir. Agus Bueno, M.Si, M.Kom  
NIP 196607021993021001

Tanggal Ujian:  
17 Juli 2026

Tanggal Lulus:



## PRAKATA

Puji dan syukur penulis panjatkan kepada Allah subhanaahu wa ta'ala atas segala karunia-Nya sehingga karya ilmiah ini berhasil diselesaikan. Tema yang dipilih dalam penelitian yang dilaksanakan sejak bulan Februari 2024 sampai bulan Mei 2026, dengan judul “Pengembangan *Residual Network* dengan *Adaptive Multi-Scale Meta-Representation* pada *Meta-Learning* untuk Klasifikasi Penyakit Keriting Daun Cabai”.

Terima kasih penulis ucapkan kepada para pembimbing, Prof. Dr. Ir. Agus Bueno, M.Si, M.Kom selaku ketua komisi pembimbing, Dr. Karlisa Priandana, S. T, M.Eng, Prof. Madya Dr. Samsuzana Abd Aziz, B.Eng, M.Sc, SMIEEE, Prof. Dr. Muhamad Syukur, S.P., M. Si selaku anggota komisi pembimbing, yang telah membimbing dan banyak memberi saran. Ucapan terima kasih juga disampaikan kepada moderator seminar, dan penguji luar komisi pembimbing. Di samping itu, penghargaan penulis sampaikan kepada:

1. Dekan Sekolah Sains Data, Matematika dan Informatika, Prof. Dr. Ir. Agus Bueno, M.Si., M.Kom.
2. Prof. Dr. Ir. Mochamad Wahyudi, M.Kom, MM, M.Pd, IPU, ASEAN Eng selaku penguji 1 luar komisi ujian tertutup dan ujian terbuka.
3. Dr. Aziz Kustiyo, S.Si., M.Kom selaku penguji 2 luar komisi ujian tertutup dan ujian terbuka.
4. Prof. Dr. Ika Amalia Kartika, S.TP., M.T selaku moderator pada seminar hasil.
5. Ketua Program Studi S3 Ilmu Komputer SSMI IPB, Prof. Dr. Imas Sukaesih Sitanggang, M.Kom dan Sekretaris Program Studi S3 Ilmu Komputer, Dr. Hendra Rahmawan, M.T. beserta segenap dosen yang telah banyak memberikan ilmu dan pencerahan serta arahan selama masa perkuliahan.
6. Tenaga Kependidikan Program Studi S3 Ilmu Komputer SSMI IPB yang telah banyak membantu penulis dalam masalah administrasi dan informasi.
7. Yayasan Bina Sarana Informatika yang telah memberikan beasiswa pendidikan kepada penulis untuk studi lanjut S3.
8. Rektor Universitas Bina Sarana Informatika Prof. Dr. Ir. Mochamad Wahyudi, M.Kom, MM, M.Pd, IPU, ASEAN Eng yang telah memberikan beasiswa untuk studi lanjut S3.
9. Ayahanda Zaenal Arifin dan Ibunda Nyi Sumarni, Kakak-kakak Tercinta Bambang Supanda, Irma Rachmawati, serta Dicky Hemawandi yang telah memberi dukungan dan doa untuk penulis.
10. Istri tercinta penulis, Devi Shohifah dan anak-anak penulis, Adzra Aqila Marwah, M. Arkhan, Fatimah Az-zahra, dan M. Emir Satria yang penuh pengorbanan dan kesabaran serta doa dan kasih sayang dalam kebersamaan penulis.
11. Teman-teman angkatan 6 tahun 2023 S3 Program Studi Ilmu Komputer SSMI IPB yang telah bersama-sama berjuang menimba ilmu dan saling memotivasi selama studi.
12. Pihak lainnya yang tidak penulis sebutkan namun turut mendukung dalam penyelesaian penelitian ini.

Penulis menyadari bahwa disertasi ini tentunya masih memiliki keterbatasan dan kekurangan. Namun, penulis berharap disertasi dapat bermanfaat bagi pihak-

pihak yang memerlukan dan bagi pengembangan ilmu pengetahuan. Semoga karya ilmiah ini bermanfaat bagi pihak yang membutuhkan dan bagi kemajuan ilmu pengetahuan.

Bogor, Juli 2026

*Rizal Amegia Saputra*

@Hak cipta milik IPB University

IPB University



Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

## DAFTAR ISI

|                                                                                                                                       |      |
|---------------------------------------------------------------------------------------------------------------------------------------|------|
| DAFTAR TABEL                                                                                                                          | xiii |
| DAFTAR GAMBAR                                                                                                                         | xiii |
| DAFTAR LAMPIRAN                                                                                                                       | xv   |
| I PENDAHULUAN                                                                                                                         | 1    |
| 1.1 Latar Belakang                                                                                                                    | 1    |
| 1.2 Rumusan Masalah                                                                                                                   | 5    |
| 1.3 Tujuan                                                                                                                            | 5    |
| 1.4 Manfaat                                                                                                                           | 5    |
| 1.5 Ruang Lingkup                                                                                                                     | 6    |
| 1.6 Kebaruan ( <i>novelty</i> )                                                                                                       | 6    |
| II TINJAUAN PUSTAKA                                                                                                                   | 7    |
| 2.1 Tanaman Cabai                                                                                                                     | 7    |
| 2.2 Augmentasi Data                                                                                                                   | 8    |
| 2.3 Convolution Neural Network (CNN)                                                                                                  | 9    |
| 2.4 Model-Model Arsitektur CNN                                                                                                        | 16   |
| 2.5 Mekanisme Perhatian <i>Efficient Channel Attention</i> (ECA)                                                                      | 19   |
| 2.6 <i>Meta-Learning</i>                                                                                                              | 20   |
| 2.7 <i>Multi-Scale Feature Representation</i>                                                                                         | 21   |
| 2.8 <i>Feature Fusion</i>                                                                                                             | 22   |
| 2.9 Analisis dan evaluasi                                                                                                             | 22   |
| III METODE                                                                                                                            | 24   |
| 3.1 Tahapan dan Waktu Penelitian                                                                                                      | 24   |
| 3.2 Data Penelitian                                                                                                                   | 28   |
| 3.3 Lingkungan Penelitian dan Spesifikasi Perangkat                                                                                   | 31   |
| IV MODEL RESNET-50PLUS DENGAN PENINGKATAN STRATEGI PELATIHAN                                                                          | 32   |
| 4.1 Pendahuluan                                                                                                                       | 32   |
| 4.2 Metode                                                                                                                            | 32   |
| 4.3 Arsitektur Model                                                                                                                  | 34   |
| 4.4 Hasil dan Pembahasan                                                                                                              | 35   |
| 4.5 Kesimpulan                                                                                                                        | 40   |
| V <i>META-LEARNING</i> BERBASIS RESNET-50PLUS UNTUK KLASIFIKASI <i>FEW-SHOT</i> PENYAKIT DAUN CABAI                                   | 41   |
| 5.1 Latar Belakang                                                                                                                    | 41   |
| 5.2 Metode                                                                                                                            | 42   |
| 5.3 Hasil dan Pembahasan                                                                                                              | 44   |
| 5.4 Kesimpulan                                                                                                                        | 52   |
| VI <i>ADAPTIVE MULTI-SCALE CHANNEL ATTENTION</i> UNTUK PENINGKATAN <i>FEATURE REPRESENTASI</i> PADA KLASIFIKASI CITRA BERBASIS FOMAML | 54   |
| 6.1 Latar Belakang                                                                                                                    | 54   |
| 6.2 Metode                                                                                                                            | 55   |



|                        |    |
|------------------------|----|
| 6.3 Hasil              | 58 |
| 6.4 Kesimpulan         | 67 |
| VII SIMPULAN DAN SARAN | 68 |
| 7.1 Simpulan           | 68 |
| 7.2 Saran              | 69 |
| DAFTAR PUSTAKA         | 70 |
| LAMPIRAN               | 80 |

## DAFTAR TABEL

|    |                                                                                                                                 |    |
|----|---------------------------------------------------------------------------------------------------------------------------------|----|
| 1  | <i>State of the art</i> penelitian mengenai klasifikasi penyakit daun cabai                                                     | 3  |
| 2  | <i>State of the art</i> penelitian pengembangan representasi fitur                                                              | 4  |
| 3  | Struktur ResNet-50                                                                                                              | 17 |
| 4  | Distribusi <i>dataset</i> pada setiap tahapan penelitian                                                                        | 29 |
| 5  | Konfigurasi <i>few-shot learning</i>                                                                                            | 30 |
| 6  | Spesifikasi lingkungan penelitian                                                                                               | 31 |
| 7  | Distribusi data keriting daun cabai tahap awal                                                                                  | 33 |
| 8  | Performa dan stabilitas model pada data uji berdasarkan lima kali pengujian ( <i>seeds</i> 42–46)                               | 35 |
| 9  | Performa pengujian pada setiap <i>seed</i> acak yang berbeda (42–46)                                                            | 35 |
| 10 | Studi ablasi strategi pelatihan                                                                                                 | 38 |
| 11 | Distribusi <i>dataset</i> penyakit keriting daun cabai                                                                          | 43 |
| 12 | Perbandingan strategi inisialisasi <i>backbone</i>                                                                              | 44 |
| 13 | Evaluasi arsitektur <i>backbone</i> pada FOMAML                                                                                 | 45 |
| 14 | Perbandingan performa metode <i>meta-learning</i> untuk klasifikasi                                                             | 46 |
| 15 | Hasil uji <i>t</i> berpasangan untuk perbandingan <i>backbone</i> pada <i>Framework</i> FOMAML                                  | 48 |
| 16 | Hasil uji <i>t</i> berpasangan untuk perbandingan performa antar metode <i>meta-learning</i> pada berbagai skenario <i>shot</i> | 49 |
| 17 | Distribusi <i>dataset</i> penyakit keriting daun cabai                                                                          | 56 |
| 18 | Perbandingan <i>baseline meta-learning</i>                                                                                      | 58 |
| 19 | Studi ablasi komponen penyusun MS-AECA                                                                                          | 59 |
| 20 | Perbandingan kebutuhan komputasi pada setiap konfigurasi                                                                        | 61 |
| 21 | Analisis komparatif pengembangan model                                                                                          | 62 |

## DAFTAR GAMBAR

|    |                                                                                                 |    |
|----|-------------------------------------------------------------------------------------------------|----|
| 1  | Negara-negara produksi cabai terbesar dunia Tahun 2022                                          | 1  |
| 2  | Data konsumsi cabai per kapita di Indonesia 2019 - 2023                                         | 2  |
| 3  | Penyakit keriting tanaman cabai, (a) karena virus (b) karena hama                               | 8  |
| 4  | Taksonomi metode augmentasi                                                                     | 9  |
| 5  | Diagram <i>block</i> arsitektur CNN                                                             | 9  |
| 6  | Ilustrasi <i>input</i> RGB                                                                      | 10 |
| 7  | Ilustrasi operasi konvolusi                                                                     | 11 |
| 8  | Jenis fungsi aktivasi                                                                           | 12 |
| 9  | Ilustrasi dari <i>max pooling</i> dan <i>average pooling</i>                                    | 13 |
| 10 | Proses <i>flatten</i>                                                                           | 13 |
| 11 | (a) Sebelum <i>dropout</i> dan (b) setelah <i>dropout</i>                                       | 14 |
| 12 | Taksonomi arsitektur <i>CNN</i>                                                                 | 16 |
| 13 | Konsep <i>residual learning</i> dalam jaringan <i>ResNet</i> beserta <i>shortcut connection</i> | 18 |
| 14 | Modul ECA                                                                                       | 20 |
| 15 | Gambaran umum tugas dari <i>meta-learning</i>                                                   | 20 |

|    |                                                                                                                                                                                                                        |    |
|----|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 16 | <i>Receptive field</i> pada proses ekstraksi fitur                                                                                                                                                                     | 22 |
| 17 | Visualisasi <i>heatmap</i> dengan Grad-CAM                                                                                                                                                                             | 23 |
| 18 | Teknik <i>confusion matrix</i>                                                                                                                                                                                         | 23 |
| 19 | Tahapan penelitian                                                                                                                                                                                                     | 24 |
| 20 | Struktur modifikasi arsitektur ResNet-50 menjadi ResNet-50Plus                                                                                                                                                         | 26 |
| 21 | <i>Pipeline</i> integrasi ResNet-50Plus dengan <i>framework meta-</i>                                                                                                                                                  | 27 |
| 22 | <i>Pipeline adaptive multi-scale meta-representation</i> pada <i>framework meta-learning</i>                                                                                                                           | 28 |
| 23 | Contoh citra <i>dataset</i> daun cabai yang digunakan pada penelitian: (a) Daun sehat, (b) Daun keriting akibat serangan hama, dan (c) Daun keriting akibat infeksi virus                                              | 30 |
| 24 | Tahapan penelitian                                                                                                                                                                                                     | 33 |
| 25 | Perbandingan akurasi pelatihan pada <i>epoch</i> maksimum                                                                                                                                                              | 36 |
| 26 | Perbandingan kerugian pelatihan                                                                                                                                                                                        | 36 |
| 27 | Perbandingan akurasi validasi                                                                                                                                                                                          | 37 |
| 28 | Perbandingan kerugian validasi                                                                                                                                                                                         | 37 |
| 29 | <i>Confusion matrix</i> untuk model ResNet-50 ResNet-50 berdasarkan konfigurasi terbaik pada data pengujian.                                                                                                           | 39 |
| 30 | <i>Confusion matrix</i> model ResNet-50Plus berdasarkan konfigurasi                                                                                                                                                    | 39 |
| 31 | Visualisasi Grad-CAM ResNet-50 dan ResNet-50Plus pada klasifikasi daun cabai untuk setiap kelas                                                                                                                        | 40 |
| 32 | Tahapan penelitian                                                                                                                                                                                                     | 42 |
| 33 | <i>Backbone</i> arsitektur ResNet-50Plus berbasis <i>attention</i> ECA                                                                                                                                                 | 43 |
| 34 | Perbandingan performa antara <i>backbone</i> ResNet-50 dan ResNet-50Plus berbasis <i>attention</i> ECA dengan <i>framework</i> FOMAML.                                                                                 | 46 |
| 35 | Perbandingan tren akurasi FOMAML, <i>ProtoNet</i> , dan <i>RelationNet</i> pada berbagai skenario <i>shot</i> .                                                                                                        | 47 |
| 36 | <i>Confusion matrix</i> pada FOMAML menggunakan <i>backbone</i> ResNet-50 berdasarkan lima <i>seed</i> pengujian (42–46) pada skenario 10- <i>shot</i>                                                                 | 50 |
| 37 | <i>Confusion matrix</i> pada FOMAML menggunakan <i>backbone</i> ResNet-50Plus berdasarkan lima <i>seed</i> pengujian (42–46) pada skenario 10- <i>shot</i> .                                                           | 51 |
| 38 | <i>Confusion matrix</i> pada FOMAML menggunakan <i>backbone</i> ResNet-50Plus berbasis <i>attention</i> ECA berdasarkan lima <i>seed</i> pengujian (42–46) pada skenario 10- <i>shot</i>                               | 51 |
| 39 | Perbandingan visualisasi Grad-CAM pada hasil klasifikasi FOMAML menggunakan <i>backbone</i> yang berbeda, yaitu: (a) citra asli, (b) ResNet-50, (c) ResNet-50Plus dan (d) ResNet-50Plus berbasis <i>attention</i> ECA. | 52 |
| 40 | Tahapan penelitian menggunakan FOMAML ResNet-50Plus                                                                                                                                                                    | 55 |
| 41 | Perbandingan performa studi ablasi MS-AECA pada skenario <i>few-shot learning</i>                                                                                                                                      | 60 |
| 42 | <i>Normalized aggregate confusion matrix</i> model FOMAML dengan <i>backbone</i> ResNet-50Plus+MS-AECA pada skenario 10- <i>shot</i> .                                                                                 | 63 |
| 43 | Perbandingan visualisasi Grad-CAM: (a) citra asli, (b) ResNet-50, (c) ResNet-50Plus, (d) ResNet-50Plus + ECA, (e) ResNet-50Plus + MS-AECA                                                                              | 64 |
| 44 | Tampilan awal aplikasi MS-AECA Chili Leaf Disease. (a) <i>Splash Screen</i> yang ditampilkan saat aplikasi pertama kali dijalankan. (b) Halaman Utama yang menyediakan menu untuk memilih gambar dari galeri atau      |    |



menggunakan kamera sebagai masukan proses klasifikasi penyakit daun cabai. 65

|                                                                                                                                                           |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 45 Tahapan Implementasi Aplikasi Android <i>ChiliScan</i> yang Meliputi (a) Analisis Citra Daun Cabai dan (b) Hasil Klasifikasi Menggunakan Model MS-AECA | 66 |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------|----|

## DAFTAR LAMPIRAN

|                                                      |    |
|------------------------------------------------------|----|
| 1 Beberapa contoh citra penyakit keriting daun cabai | 81 |
| 2 Kode program untuk ResNet-50Plus                   | 82 |
| 3 Kode program untuk MS-AECA                         | 84 |
| 4 Struktur ResNet-50Plus                             | 88 |