JEDUMATIC

e-ISSN 3031-8408

Journal of Education and Informatics Research /Vol.7, No.2 2026

Penerapan Attention Mechanism Menggunakan Convolutional Block Attention Module (CBAM) pada Arsitektur ResNet50 Untuk Klasifikasi Penyakit Buah Kakao

Ahmad Wafi Fathurrahman[1*], I Gede Susrama Mas Diyasa[2], Alfan Rizaldy Pratama[3]

[1,2,3] *Program Studi Sains Data, Universitas Pembangunan Nasional "Veteran" Jawa Timur, Surabaya, Indonesia*
email: [1]21083010011@student.upnjatim.ac.id, [2]igsusrama.if@upnjatim.ac.id, [3]alfan.fasilkom@upnjatim.ac.id

ABSTRAK

Tanaman kakao (*Theobroma cacao L.*) merupakan salah satu komoditas perkebunan di Indonesia. Namun, produktivitas tanaman kakao ini sering menghadapi berbagai tantangan akibat dari serangan hama maupun penyakit seperti busuk buah, helopeltis serta penggerek buah kakao (PBK). Sementara, proses identifikasi dari serangan hama maupun penyakit pada buah kakao masih dilakukan secara manual, sehingga berpotensi bersifat subjektif, memakan waktu serta bergantung kepada pengalaman individu para petani. Penelitian ini bertujuan untuk melakukan klasifikasi buah kakao ke dalam empat kelas, yaitu Busuk Buah, Helopeltis, Kakao Sehat dan Penggerek Buah Kakao (PBK) menggunakan model arsitektur ResNet50 yang diintegrasikan *Convolutional Block Attention Module* (CBAM) pada setiap *stage residual*-nya. Dataset penelitian berjumlah 6.992 gambar buah kakao yang diperoleh melalui dataset publik serta pengamatan langsung di Dusun Gentungan Desa Gawang Kecamatan Kebonagung Kabupaten Pacitan. Tahapan *pre-processing* meliputi *resize* gambar menjadi 224 x 224 piksel dan *preprocessing* sesuai standar *input* ResNet50. Kemudian dataset dibagi dengan rasio 80% data *training*, 10% data validasi dan 10% data *testing*. Model dilatih menggunakan pendekatan *transfer learning* dengan memanfaatkan bobot pralatih ImageNet pada *backbone* ResNet50 yang dibekukan (*frozen*). Model kemudian dievaluasi menggunakan *classification report* dan *confusion matrix*. Hasil pengujian menunjukkan bahwa model ResNet50-CBAM memperoleh akurasi sebesar 94,29% pada 700 data *testing* dengan *macro average precision* sebesar 94,32%, *recall* 94,29%, dan *F1-Score* 94,29%. Hasil ini menunjukkan bahwa integrasi CBAM pada ResNet50 mampu menghasilkan performa klasifikasi yang tinggi dan konsisten pada dataset hama dan penyakit buah kakao, sehingga berpotensi menjadi pendekatan *deep learning* untuk mendukung proses identifikasi penyakit berbasis citra digital.

Kata Kunci: Kakao, Klasifikasi, ResNet50, *Convolutional Block Attention Module* (CBAM)

ABSTRACT

Cocoa plants (Theobroma cacao L.) are one of the plantation commodities in Indonesia. However, the productivity of cocoa plants often faces various challenges due to pest and disease attacks such as fruit rot, helopeltis, and cocoa pod borer (CPB). Meanwhile, the process of identifying pest and disease attacks on cocoa fruit is still done manually, which can be subjective, time-consuming, and dependent on the individual experience of farmers. This research aims to classify cocoa fruits into four classes, namely Fruit Rot, Helopeltis, Healthy Cocoa, and Cocoa Pod Borer (CPB), using the ResNet50 architecture model integrated with the Convolutional Block Attention Module (CBAM) at each of its residual stages. The research dataset consists of 6,992 images of cocoa fruit obtained from public datasets and direct observations in Gentungan Hamlet, Gawang Village, Kebonagung District, Pacitan Regency. The pre-processing stages include resizing the images to 224 x 224 pixels and preprocessing according to the ResNet50 input standards. Then the dataset is divided with a ratio of 80% training data, 10% validation data, and 10% testing data. The model was trained using a transfer learning approach by leveraging the pre-trained ImageNet weights on the frozen ResNet50 backbone. The model was then evaluated using a classification report and confusion matrix. The test results show that the ResNet50-CBAM model achieved an accuracy of 94.29% on 700 test data with a macro average precision of 94.32%, recall of 94.29%, and F1-Score of 94.29%. These results indicate that the integration of CBAM into ResNet50 can produce high and consistent classification performance on the cocoa fruit pest and disease dataset, making it a potential deep learning approach to support disease identification processes based on digital images.

Keywords: *Cocoa, Classification, ResNet50, Convolutional Block Attention Module* (CBAM)

PENDAHULUAN

Tanaman kakao (*Theobroma cacao L.*) merupakan salah satu komoditas perkebunan di Indonesia. Tanaman kakao memiliki banyak manfaat, salah satunya adalah melalui biji kakao yang dapat digunakan sebagai bahan baku utama dalam pembuatan cokelat (Yusra dkk., 2026). Tanaman kakao memiliki peran penting dalam perekonomian Indonesia karena berpotensi menjadi salah satu penyumbang devisa negara (Roberto & Ilvira, 2026). Namun, dalam menghasilkan produktivitas dari tanaman kakao menghadapi beberapa tantangan akibat serangan dari hama dan penyakit. Beberapa serangan hama dan penyakit yang menyerang buah kakao di antaranya adalah hama penggerek buah kakao (*Conopomorpha cramella* Snellen), kepik penghisap buah (*Helopeltis sp.*), serta cendawan jamur parasit *Phytophthora palmivora* yang menjadi penyebab busuk pada buah kakao (Soge dkk., 2024; Karim dkk., 2024; Lea dkk., 2022).

Pada praktiknya di lapangan, para petani dalam mengidentifikasi buah kakao dari serangan hama maupun penyakit masih banyak dilakukan melalui pendekatan secara konvensional. Metode tersebut umumnya dilakukan melalui observasi visual secara langsung yang berpotensi memerlukan waktu, bersifat objektif dan sangat bergantung pada pengalaman individu petani (Rahmawati dkk., 2026; Wisnawa dkk., 2025; Rachmani dkk., 2025). Oleh karena itu, diperlukan pendekatan yang mampu membantu mendeteksi serta melakukan klasifikasi beberapa jenis serangan dari hama maupun penyakit pada buah kakao dengan tepat, cepat dan akurat. Beberapa pendekatan dapat dilakukan, salah satunya adalah melalui sebuah sistem pengolahan citra digital (Julyani & Khairullah, 2025). Citra digital merupakan representasi dari dua dimensi objek visual yang tersusun atas beberapa piksel serta dapat dimanfaatkan dalam berbagai ilmu seperti seni, *computer vision*, astronomi dan teknik rekayasa citra (Hidayat, 2025).

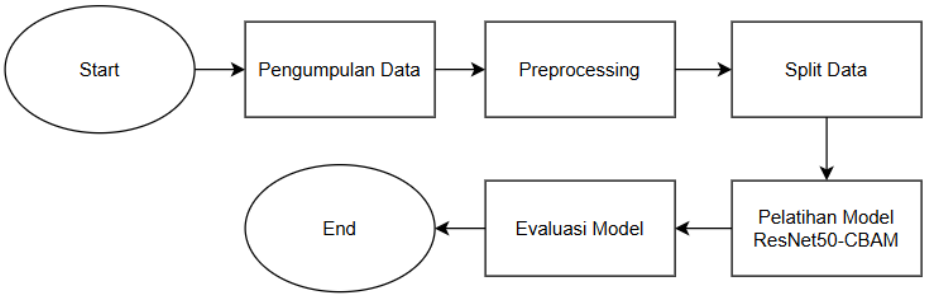
Convolutional Neural Network (CNN) merupakan salah satu teknik atau metode yang dapat digunakan dalam pengolahan citra digital. CNN pertama kali ditemukan oleh Yann LeCun pada tahun 1998 dengan arsitektur pertamanya LeNet-5 untuk pengenalan tulisan angka (Marasitua dkk., 2025; Hanggoro, 2025). CNN terus mengalami perkembangan semenjak arsitektur *AlexNet* ditemukan yang menjadi pemenang kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) pada tahun 2012 (Irfansyah dkk., 2021). Perkembangan tersebut mendorong CNN untuk diterapkan dalam mengatasi berbagai permasalahan, khususnya dalam pengolahan dan klasifikasi citra. Hal ini ditunjukkan dengan banyaknya arsitektur yang dikembangkan untuk meningkatkan kemampuan dalam mengekstraksi dan merepresentasikan fitur citra seperti ResNet, EfficientNet, dll.

Beberapa arsitektur CNN telah diterapkan untuk klasfikasi penyakit pada tanaman, khususnya buah kakao dengan hasil kinerja model yang beragam. Penelitian (Sykes dkk., 2025) yang melakukan klasifikasi penyakit pada buah kakao dengan lima kelas yaitu “Black Pod Rot (BPR)”, “Frosty Pod Rot (FPR)”, “Withches’ Broom Disease (WBD)”, “Healthy” dan “Non-Cocoa” menggunakan ResNet18 menghasilkan akurasi sebesar 84%. Penelitian lain (Soh dkk., 2024) yang melakukan klasifikasi penyakit pada buah kakao dengan tiga kelas, yaitu “Healthy Cocoa”, “Black Pod” dan “Pod Borer” menggunakan ResNet50 menghasilkan akurasi sebesar 86,20%. Sementara itu, penelitian (Techie-Menson dkk., 2026) yang melakukan klasifikasi penyakit buah kakao ke dalam tiga kelas, yaitu “Phyto”, “Moni” dan “Healthy” dengan membandingkan beberapa arsitektur CNN seperti ResNet50 tanpa mekanisme *attention* memperoleh akurasi sebesar 82,15% dan ketika ResNet50 diintegrasikan dengan *Convolutional Block Attention Module* (CBAM) hasil akurasi yang diperoleh meningkat menjadi 98,12%. Berdasarkan hasil penelitian tersebut, penambahan *Convolutional Block Attention Module* (CBAM) pada ResNet50 menjadi salah satu pendekatan yang berpotensi untuk meningkatkan performa klasifikasi penyakit pada buah kakao.

Penelitian ini bertujuan untuk melakukan klasifikasi penyakit pada buah kakao yang terbagi dalam empat kelas, yaitu "Busuk Buah", "Helopeltis", "Kakao Sehat" dan "Penggerek Buah Kakao (PBK) menggunakan ResNet50 yang diintegrasikan *Convolutional Block Attention Module* (CBAM) di setiap *output residual stage*-nya (conv2_x, conv3_x, conv4_x, dan conv5_x). Dataset yang digunakan dalam penelitian ini diperoleh melalui data publik dan pengamatan langsung di Dusun Gentungan Desa Gawang Kecamatan Kebonagung Kabupaten Pacitan. Model dilatih dengan pendekatan *transfer learning* dan memanfaatkan bobot pralatih ImageNet pada *backbone* ResNet50. Kinerja model akan dievaluasi menggunakan *accuracy*, *precision*, *recall* dan *F1-Score*. Hasil dari penelitian ini diharapkan dapat memberikan bukti empiris mengenai kinerja dari integrasi *Convolutional Block Attention Module* (CBAM) pada ResNet50 yang menjadi acuan dalam pemilihan arsitektur untuk pengembangan sistem berbasis citra digital.

METODE

Metode penelitian ini dimulai dari pengumpulan citra buah kakao yang memiliki beberapa kelas penyakit seperti "Busuk Buah", "Helopeltis", "Kakao Sehat" dan "Penggerek Buah Kakao (PBK)" sebagai data penelitian. Kemudian citra buah kakao tersebut dilakukan *preprocessing* serta dibagi menjadi data *training*, data *validation* dan data *testing*. Model lalu dikembangkan dengan menggunakan arsitektur ResNet50 yang diintegrasikan *Convolutional Block Attention Module* (CBAM) di setiap *output stage residual*-nya (conv2_x, conv3_x, conv4_x dan conv5_x). Selanjutnya evaluasi dilakukan untuk menguji kinerja model. Adapun alur penelitian secara keseluruhan ditunjukkan pada Gambar 1 berikut.



Gambar 1. Alur penelitian

2.1. Pengumpulan Data



Gambar 2. Contoh *dataset* penelitian

Dataset yang digunakan dalam penelitian ini berjumlah 6.992 gambar yang diperoleh melalui dataset publik https://universe.roboflow.com/itera-zghl1/tugas-akhir-hama-penyakit-kakao serta pengamatan langsung di Dusun Gentungan Desa Gawang Kecamatan Kebonagung Kabupaten Pacitan.

Dataset terdiri dari 4 kategori, diantaranya adalah 1.748 citra "Busuk Buah", 1.748 citra "Helopeltis", 1.748 citra "Kakao Sehat" dan 1.748 citra "Penggerek Buah Kakao (PBK)".

2.2. *Preprocessing*

Tahapan *preprocessing* dilakukan dalam penelitian ini agar citra yang digunakan sesuai dengan model *deep learning* yang akan digunakan. Tahapan *preprocessing* yang dilakukan seperti:

1. *Resize* citra, merupakan tahapan yang mengubah seluruh ukuran citra menjadi 224 x 224 piksel, sehingga sesuai dengan ukuran *input* citra model *deep learning* yang dibutuhkan.
2. *Preprocessing* skema ResNet50 (ImageNet), merupakan tahapan penyesuaian nilai piksel citra menggunakan fungsi preprocess_input milik ResNet50, yang mencakup beberapa tahapan seperti konversi urutan kanal warna dari RGB ke BGR serta pengurangan nilai piksel dengan rata-rata (*mean*) kanal warna dari dataset ImageNet. Tahapan ini bertujuan untuk menyelaraskan distribusi nilai piksel citra input dengan distribusi data yang digunakan saat pralatih (*pretraining*) ResNet50 pada ImageNet, sehingga bobot pralatih dapat dimanfaatkan secara optimal.

2.3. *Split* dataset

Pembagian datasest atau *split* dataset merupakan tahapan yang bertujuan untuk memisahkan menjadi tiga bagian yang berbeda, yaitu data *training* sebesar 80%, data *validation* sebesar 10% dan data *testing* sebesar 10%. Data *training* digunakan untuk melatih model agar mampu mengenali dan mempelajari pola, tekstur serta karakteristik visual dari setiap kelas citra. Sedangkan data *validation* digunakan untuk mengukur kinerja model selama proses pelatihan berlangsung serta mencegah terjadinya *overfitting*. Sementara itu, data *testing* digunakan untuk mengevaluasi kinerja model setelah proses pelatihan model selesai dilakukan. Pada penelitian ini, sebanyak 5.593 citra digunakan sebagai data *training*, 699 citra sebagai data *validation* dan 700 citra sebagai data *testing*.

2.4. Arsitektur Model

Arsitektur model yang digunakan dalam penelitian ini adalah arsitektur ResNet50 yang diintegrasikan *Convolutional Block Attention Module* (CBAM) di setiap *output stage residual*-nya (conv2_x, conv3_x, conv4_x dan conv5_x).

Tabel 1. Arsitektur layer model ResNet50-CBAM

Layer (Type)	Output Shape	Param#
input_image(InputLayer)	(None, 224, 224, 3)	0
resnet50_stem_conv2 (Functional)	(None, 56, 56, 256)	229, 760
cbam_conv2 (ConvolutionalBlockAttentionModule)	(None, 56, 56, 256)	8, 562
resnet50_conv3 (Functional)	(None, 28, 28, 512)	1, 230, 336
cbam_conv3 (ConvolutionalBlockAttentionModule)	(None, 28, 28, 512)	33, 410
resnet50_conv4 (Functional)	(None, 14, 14, 1024)	7, 129, 088
cbam_conv4 (ConvolutionalBlockAttentionModule)	(None, 14, 14, 1024)	132, 258
resnet50_conv5 (Functional)	(None, 7, 7, 2048)	14, 998, 528
cbam_conv5 (ConvolutionalBlockAttentionModule)	(None, 7, 7, 2048)	526, 562
global_average_pooling (GlobalAveragePooling2D)	(None, 2048)	0
fc1 (Dense)	(None, 256)	524, 544
dropout (Dropout)	(None, 256)	0
classifier (Dense)	(None, 4)	1,028

Berdasarkan Tabel 1, model *deep learning* pada penelitian ini dimulai dari *input layer* yang menerima citra berukuran 224 *x* 224 *x* 3. Citra input kemudian diteruskan ke bagian *stem* dan *stage*

residual pertama ResNet50 (resnet50_stem_conv2) hingga menghasilkan *feature map* berukuran 56 *x* 56 *x* 256. Keluaran dari setiap *stage residual* (conv2_x, conv3_x, conv4_x dan conv5_x) selanjutnya diproses oleh modul CBAM yang bersesuaian (cbam_conv2, cbam_conv3, cbam_conv4, cbam_conv5) sebelum diteruskan ke *stage residual* berikutnya. Modul CBAM disini bekerja dengan menerapkan *reduction ratio* sebesar 16 pada mekanisme *channel attention* dan ukuran kernel konvolusi 7 *x* 7 pada mekanisme *spatial attention*, sehingga model dapat memperkuat fitur – fitur yang paling relevan pada setiap tahap sebelum diteruskan ke tahap berikutnya. Setelah melalui empat *stage residual* dan empat modul CBAM, *feature map* akhir berukuran 7 *x* 7 *x* 2048 diringkas menggunakan *Global Average Pooling* (GAP) menjadi vektor berdimensi 2048, kemudian dilanjutkan ke lapisan *fully connected* (fc1) berukuran 256 *neuron* dengan fungsi aktivasi ReLU, dilanjutkan dengan lapisan *dropout* sebesar 0.5 untuk mengurangi *overfitting*, dan akhirnya diklasifikasikan oleh lapisan *classifier* menggunakan fungsi aktivasi softmax ke dalam empat kelas keluaran.

2.5. Evaluasi Model

Tahapan evaluasi dilakukan dengan tujuan untuk menilai kinerja akhir dari model ResNet50-CBAM. Evaluasi dalam penelitian ini dilakukan dengan menggunakan metrik *accuracy*, *precision*, *recall* dan *F1-Score*. Selain itu, *confusion matrix* juga digunakan dalam penelitian ini untuk melihat distribusi prediksi di setiap kelasnya.

$$Accuracy = \frac{TP+TN}{TP+FN+FP+TN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{FN+TP} \quad (3)$$

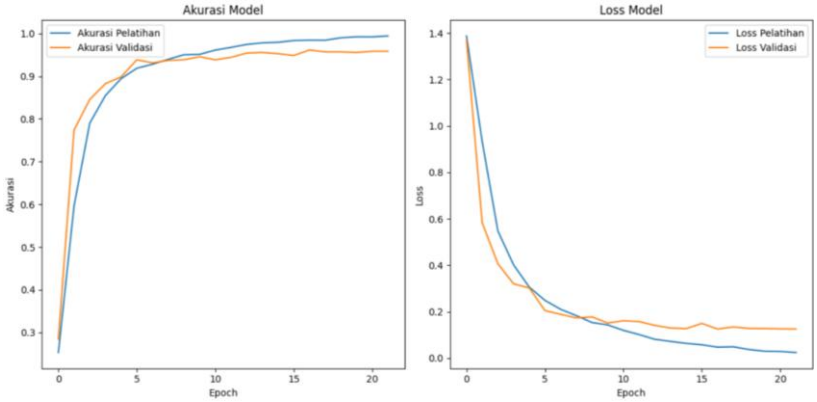
$$F1\text{-}Score = 2\ x \frac{Precision\ x\ Recall}{Precision+Recall} \quad (4)$$

HASIL DAN PEMBAHASAN

3.1. Analisis Hasil Pelatihan Model

Pada penelitian ini, model ResNet50-CBAM dilatih dengan pendekatan *transfer learning* yang dimana seluruh lapisan (*layer*) pada *backbone* ResNet50 dibekukan (*frozen*) dan hanya modul CBAM beserta lapisan klasifikasi (*fully connected layer*) yang diperbarui bobotnya selama proses pelatihan berjalan. Model ResNet50-CBAM dilatih dengan konfigurasi maksimum 30 *epoch*, menggunakan optimasi Adam dengan *learning rate* awal sebesar $1\ x\ 10^{-4}$. Selain itu, pada proses pelatihan model ResNet50-CBAM juga memanfaatkan tiga *callback*, yaitu ModelCheckpoint (menyimpan bobot terbaik berdasarkan val_accuracy), ReduceLROnPlateau (menurunkan *learning rate* sebesar 50% apabila val_loss tidak membaik dalam 2 *epoch*) dan EarlyStopping (menghentikan pelatihan model apabila val_loss tidak membaik dalam 5 *epoch* berturut-turut).

Berdasarkan log pelatihan, proses *training* model berlangsung secara efektif hanya hingga *epoch* ke-22, dimana mekanisme *early stopping* aktif untuk menghentikan pelatihan lebih awal sebelum mencapai batas maksimum 30 *epoch*. Bobot model dengan performa terbaik diperoleh pada *epoch* ke-17 dengan nilai val_loss terendah sebesar 0,125 dan val_accuracy sebesar 96,14%. Hasil dari bobot *epoch* ke-17 tersebut yang dikembalikan (*restore best weights*) serta akan digunakan sebagai model final.



Gambar 3. Grafik akurasi dan loss dari training dan validasi model ResNet50-CBAM

Grafik akurasi pada Gambar 3 menunjukkan bahwa akurasi pelatihan (*training accuracy*) meningkat tajam pada 5 *epoch* pertama, dari sekitar 0,25 hingga mencapai 0,89. Kemudian, grafik akurasi dari pelatihan (*training accuracy*) terus meningkat secara stabil hingga mendekati 0,99 pada *epoch* ke-22. Grafik akurasi dari validasi (*validation accuracy*) juga menunjukkan pola peningkatan yang serupa, mencapai kisaran 0,93 – 0,96 setelah *epoch* ke-10 dan relatif stabil hingga akhir pelatihan. Kesamaan tren antara kurva pelatihan dan validasi ini mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan, meskipun terdapat kesenjagan (*gap*) antara akurasi pelatihan yang mendekati sempurna (lebih dari 0,98 setelah *epoch* ke-14) dengan akurasi dari validasi yang cenderung stabil di kisaran 0,95 – 0,96.

Pola serupa juga terlihat pada grafik *loss*, dimana nilai *loss* dari pelatihan maupun validasi sama-sama menurun tajam dari nilai awal sekitar 1,39 menjadi dibawah 0,3 dalam 5 *epoch* pertama. Setelah *epoch* ke-5 tersebut, *loss* dari pelatihan terus menurun secara konsisten hingga mencapai 0,024 pada *epoch* ke-22, sedangkan *loss* dari validasi menunjukkan penurunan yang lebih landai dan sedikit fluktuatif yang mencapai titik terendah 0,125 pada *epoch* ke-17 sebelum stabil di kisaran 0,125 – 0,135 pada *epoch-epoch* selanjutnya. Fluktuasi kecil pada *loss* dari validasi ini turut dipengaruhi oleh tiga kali penurunan *learning rate* secara otomatis oleh ReduceLROnPlateau, yakni pada *epoch* ke-12, *epoch* ke-19 dan *epoch* ke-21 yang membantu proses konvergensi model menjadi lebih halus menjelang akhir pelatihan.

Secara keseluruhan, hasil pelatihan ini menunjukkan bahwa integrasi dari CBAM pada ResNet50 mampu membantu model dalam mempelajari pola fitur secara efektif dan mencapai konvergensi yang baik hanya dalam 22 *epoch* dengan performa yang stabil dan konsisten antara data *training* dan data *validation*.

3.2. Hasil Evaluasi Model

Evaluasi kinerja model ResNet50-CBAM dengan bobot terbaik (hasil *restore* dari *epoch* ke-17) dilakukan menggunakan data *testing* yang berjumlah 700 citra, dimana terbagi rata ke dalam empat kelas dengan masing-masing 175 citra per kelas, yakni “Busuk Buah”, “Helopeltis”, “Kakao Sehat” dan “Penggerek Buah Kakao”. Hasil evaluasi disajikan dalam bentuk *confusion matrix* pada Tabel 2 serta *classification report* pada Tabel 3 yang mencakup nilai *precision*, *recall*, *F1-Score* dan *support* untuk setiap kelasnya.

Tabel 2. Confusion matrix

Busuk Buah	**163**	4	4	4
Helopeltis	5	**163**	4	3
Kakao Sehat	5	0	**168**	2
Penggerek Buah Kakao	0	3	6	**166**

	Busuk Buah	Helopeltis	Kakao Sehat	Penggerek Buah Kakao

Confusion Matrix pada Tabel 2 tersebut memperlihatkan sebaran prediksi model ResNet50-CBAM terhadap label sebenarnya untuk setiap kelas. Kelas "Kakao Sehat" menunjukkan performa klasifikasi terbaik dengan jumlah prediksi benar (*true positive*) tertinggi, yakni 168 dari 175 citra. Sedangkan kelas "Busuk Buah" dan "Helopeltis" masing-masing memperoleh 163 prediksi benar. Sementara itu, kelas "Penggerek Buah Kakao" memperoleh 166 prediksi benar.

Kesalahan klasifikasi (*misclassification*) yang paling menonjol terjadi antara kelas "Kakao Sehat" dan "Penggerek Buah Kakao", dimana sebanyak 6 citra kelas "Penggerek Buah Kakao" secara salah diklasifikasikan sebagai Kakao Sehat. Hal ini bisa disebabkan oleh gejala awal dari serangan Penggerek Buah Kakao yang secara visual belum menunjukkan kerusakan yang signifikan pada permukaan buah, sehingga fitur visualnya masih menyerupai buah kakao yang sehat. Sebaliknya, tidak ada satupun citra dari kelas "Busuk Buah" yang salah diklasifikasikan sebagai Penggerek Buah Kakao, mengindikasikan bahwa kedua kelas ini memiliki karakteristik visual yang cukup berbeda sehingga mudah untuk dibedakan oleh model ResNet50-CBAM.

Kelas "Busuk Buah" menunjukkan pola kesalahan klasifikasi yang merata di tiga kelas lainnya, yakni masing-masing 4 citra yang salah diklasifikasikan sebagai Helopeltis, Kakao Sehat dan Penggerek Buah Kakao. Pola ini mengindikasikan bahwa gejala penyakit Busuk Buah pada beberapa citra memiliki kemiripan visual dengan ketiga kondisi lainnya yang kemungkinan disebabkan oleh variasi tingkat keparahan penyakit atau kualitas citra yang menyulitkan model dalam mengekstraksi fitur pembeda secara konsisten. Sementara itu, kelas Helopeltis paling banyak tertukar dengan kelas Busuk Buah sebanyak 5 citra yang disebabkan oleh kemiripan visual antara luka bekas serangan hama Helopeltis dengan lesi awal Busuk Buah pada permukaan kulit kakao.

Tabel 3. *Classification report*

Kelas	***Precision***	***Recall***	***F1-Score***	***Support***
Busuk Buah	0.9422	0.9314	0.9368	175
Helopeltis	0.9588	0.9314	0.9449	175
Kakao Sehat	0.9231	0.9600	0.9412	175
Penggerek Buah Kakao	0.9486	0.9486	0.9486	175
Accuracy			0.9429	700
Macro Avg	0.9432	0.9429	0.9429	700
Weighted Avg	0.9432	0.9429	0.9429	700

Berdasarkan *Classification Report* pada Tabel 3 menunjukkan bahwa kelas "Helopeltis" memperoleh nilai *precision* tertinggi sebesar 0,9588 yang mengindikasikan bahwa dari seluruh citra yang diprediksi sebagai Helopeltis oleh model ResNet50-CBAM, sebagian besar merupakan prediksi yang benar dan model jarang salah mengenali kelas lain sebagai Helopeltis. Disisi lain, kelas "Kakao Sehat" memperoleh nilai *precision* terendah sebesar 0,9231, dimana dengan temuan pada *confusion matrix* pada kelas "Kakao Sehat" ini paling banyak menerima kesalahan klasifikasi dari kelas lain (5 dari kelas "Busuk Buah" dan 6 dari kelas "Penggerek Buah Kakao"), sehingga total 11 citra bukan kelas "Kakao Sehat" yang salah diprediksi sebagai kelas "Kakao Sehat".

Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa integrasi CBAM pada arsitektur ResNet50 mampu menghasilkan model klasifikasi penyakit dan hama buah kakao dengan performa

yang tinggi serta seimbang di setiap kelasnya, dengan tantangan utama terletak pada pembedaan antara gejala awal Penggerek Buah Kakao dengan kondisi buah kakao yang tampak sehat.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model ResNet50-CBAM mampu mengklasifikasikan citra buah kakao ke dalam empat kelas dengan baik, yaitu "Busuk Buah", "Helopeltis", "Kakao Sehat" dan "Penggerek Buah Kakao (PBK)". Model ResNet50-CBAM yang dilatih dengan menggunakan pendetakan *transfer learning* dan bobot pralatih ImageNet pada *backbone* yang dibekukan (*frozen*) mencapai *validation accuracy* tertinggi sebesar 96,14% pada *epoch* ke-17 dengan proses pelatihan berhenti secara otomatis pada *epoch* ke-22 melalui mekanisme *early stopping*. Pada tahap pengujian menggunakan 700 citra data *testing*, model menghasilkan akurasi keseluruhan sebesar 94,29% dengan nilai *precison*, *recall* dan *F1-Score* rata-rata diatas 0,93 untuk seluruh kelas, sehingga menunjukkan bahwa integrasi *Convolutional Block Attention Module* (CBAM) pada setiap *stage residual* ResNet50 mampu mengenali fitur-fitur penting terkait gejala serangan hama dan penyakit pada buah kakao secara konsisten dan seimbang di setiap kelasnya.

Untuk penelitian selanjutnya, terdapat beberapa hal yang dapat dikembangkan lebih lanjut dari penelitian ini, diantaranya adalah melakukan perbandingan model ResNet50-CBAM dengan arsitektur *backbone* lain seperti EfficientNet, DenseNet dll. maupun dengan modul *attention* lain seperti *Squeeze-and-Excitation Network*/SE-Net. Selain itu, bisa juga dilakukan penambahan tahapan *fine-tuning* dengan cara membuka (*unfreeze*) sebagian lapisan akhir *backbone* ResNet50 dan melatihnya kembali menggunakan *learning rate* yang lebih kecil.

.

UCAPAN TERIMAKASIH

Pada kesempatan ini saya mengucapkan terima kasih kepada dosen pembimbing serta seluruh pihak yang telah berperan dalam proses penyusunan penelitian ini.

REFERENSI

Hanggoro, D. B. D. (2025). Analisis Komparatif Arsitektur Deep Learning Untuk Aplikasi Computer Vision: Studi Literature Review. *Jurnal Komputer Teknologi Informasi Sistem Komputer (JUKTISI)*, *4*(2), 1001–1008. https://doi.org/10.62712/juktisi.v4i2.542

Irfansyah, D., Mustikasari, M., & Suroso, A. (2021). Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi. *Politeknik Harapan Bersama*, *Vol 6, No 2 (2021): JPIT, Mei 2021*.

Julyani, S., & Khairullah, K. (2025). Pemanfaatan Pengolahan Citra Untuk Deteksi dan Identifikasi Hama pada Tanaman Secara Otomatis. *Ranah Research : Journal of Multidisciplinary Research and Development*, *7*(5), 3518–3525. https://doi.org/10.38035/rrj.v7i5.1661

Karim, H. A., Depparaba, F., Iinnaninengseh, I., Kusmiah, N., & Ihsan, M. (2024). Studi Penentuan Jenis Spesies Baru Penggerek Buah Kakao (PBK) dari Genus Conopomorpha (Lepidoptera ; Litocolletidae). *AGROVITAL : Jurnal Ilmu Pertanian*, *9*(2), 140–144. https://doi.org/10.35329/agrovital.v9i2.5126

Lea, V. C., Triwidodo, H., & Supramana, S. (2022). Hama Dan Penyakit Penting Tanaman Kakao Di Kabupaten Nagekeo, Provinsi Ntt. *Jurnal Agrotek Tropika*, *10*(4), 509–515. https://doi.org/10.23960/jat.v10i4.5860

Marasitua, W. V., Yudistira, N., & Rahman, M. A. (2025). Pengenalan Plat Nomor Kendaraan Indonesia Menggunakan Convolutional Neural Network dan BiLSTM. *Jurnal Pengembangan Teknologi dan Ilmu Komputer*, *9*(5). https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/14766

Rachmani, M. K. P., Akmal, & Haruna, N. (2025). Strategis dan Efektifitas Pengendalian Hama Penggerek Buah Kakao di Kecamatan Kodeoha Kabupaten Kolaka Utara. *SINTA Journal (Science, Technology, and Agricultural)*, *6*(2), 583–592. https://doi.org/10.37638/sinta.6.2.583-592

Rahmawati, R., Arifin, N., & Firgiawan, W. (2026). Perbandingan SVM dan CNN MobileNetV2 untuk Klasifikasi Residu Insektisida pada Citra Buah Kakao. *Jambura Journal of Informatics*, *8*(1), 77–91. https://doi.org/10.37905/jji.v8i1.37972

Roberto, J., & Ilvira, R. F. (2026). Faktor-Faktor yang Mempengaruhi Produksi Kakao di Kecamatan Semadam Kabupaten Aceh Tenggara. *Jurnal Agrisep*, *26*(2), 57–68. https://doi.org/10.17969/agrisep.v26i2.241

Soge, F. P., Deta, B., & Watomakin, D. B. (2024). Penerapan Logika Fuzzy dalam Sistem Pakar Deteksi Hama dan Penyakit Tanaman Kakao Kecamatan Wulanggitang Flores Timur. *Jurnal Kridatama Sains dan Teknologi*, *6*(01), 212–234. https://doi.org/10.53863/kst.v6i01.1115

Soh, K. S., Moung, E. G., Danker, K. J. J., Dargham, J. A., & Farzamnia, A. (2024). Cocoa Diseases Classification using Deep Learning Algorithm. *ITM Web of Conferences*, *63*, 01014. https://doi.org/10.1051/itmconf/20246301014

Sykes, J. R., Denby, K. J., & Franks, D. W. (2025). Improving computer vision for plant pathology through advanced training techniques. *Applications in Plant Sciences*, *13*(3), e70010. https://doi.org/10.1002/aps3.70010

Techie-Menson, H., Asante, M., Missah, Y. M., Abdul-Salaam, G., & Oppong, S. O. (2026). Enhanced convolutional block attention module with Learnable Gated Fusion (LGF-CBAM) for cocoa pod disease identification. *PLOS ONE*, *21*(4), e0348147. https://doi.org/10.1371/journal.pone.0348147

Wisnawa, I. P. O., Puspita, N. N. H., Pradnyana, I. P. B. A., Wiratama, I. K., & Sulastra, I. M. D. J. (2025). *Deep Learning-Based Computer Vision Framework for Early Detection of Cocoa Plant Diseases in Precision Agriculture*. 233–242. https://doi.org/10.2991/978-94-6463-878-3_27

Yusra, S., Amilda, P., Putri, E., & Raini, U. (2026). Economic Strategy for Cocoa Bean Downstream Productivity in Alur Cucur Village, Aceh Tamiang: Strategi Ekonomi Produktivitas Hilirisasi Biji Kakao di Kampung Alur Cucur Aceh Tamiang. *JATI EMAS (Jurnal Aplikasi Teknik Dan Pengabdian Masyarakat)*, *10*(1), 1–6. https://doi.org/10.36339/je.v10i1.415