

PERBANDINGAN ARSITEKTUR ALEXNET DAN MOBILENETV3-SMALL MENGGUNAKAN ATTENTION MECHANISM PADA PENYAKIT CACAR

Fujianto, Meiriyama

Informatika, Universitas Multi Data Palembang
Jl. Rajawali 14 Palembang, Sumatera Selatan
Fujianto_2226250119@mhs.mdp.ac.id

ABSTRAK

Indonesia menghadapi tantangan diagnosis penyakit cacar seperti cacar air, cacar monyet, dan cacar sapi, yang sulit dibedakan secara visual. Permasalahan utama adalah kebingungan diagnosis di daerah terpencil, membebani sistem kesehatan akibat keterbatasan perangkat. Penelitian ini bertujuan membandingkan empat model CNN berbasis *transfer learning* pada AlexNet dan MobileNetV3-Small dengan integrasi Channel Attention Mechanism untuk meningkatkan akurasi deteksi lesi kulit. Metode menggunakan dataset MSLD v2.0 (755 citra, 6 kelas: Monkeypox, Chickenpox, Cowpox, Measles, HFMD, Healthy) dengan split 80-10-10, *preprocessing* 224x224 piksel, augmentasi data, *optimizer* Adam (lr 0.0001/0.001, batch 16/32), 50 *epoch*, serta *fine-tuning* dengan *custom head* (Global Average Pooling, Channel Attention, Dense 256, Dropout 0.5, Softmax). Hasil evaluasi via *confusion matrix* menunjukkan model optimal berakurasi tertinggi, *precision/recall/F1-score* superior, waktu inferensi rendah, dan kompleksitas ringan, cocok untuk perangkat terbatas.

Kata kunci : Alexnet, Attention Mechanism, MobileNetv3-Small, Penyakit Cacar, Transfer Learning

1. PENDAHULUAN

Cacar merupakan penyakit menular serius yang pernah menjadi wabah dan berhasil diberantas melalui program vaksinasi global. Pada tahun 1967, di Jakarta sebagai wilayah endemik Indonesia, program vaksinasi masif berhasil mendistribusikan 384.000 dosis vaksin untuk menekan wabah cacar yang mencapai sekitar 100.000 kasus di Jawa, dengan proporsi primer 9,2% dari populasi 1,4 juta jiwa [1].

Penyakit ini ditandai dengan munculnya benjolan berisi cairan pada kulit yang awalnya tampak di area wajah, kemudian menyebar ke seluruh tubuh [2]

Namun, meskipun vaksinasi telah berhasil menekan kasus cacar variola, penyakit cacar air (*varicella*) maupun cacar monyet (*monkeypox*) masih menjadi masalah kesehatan masyarakat di berbagai negara. Khususnya di Indonesia, kasus cacar air (*varicella*) masih sering ditemukan baik pada anak-anak maupun dewasa, dan dapat menjadi lebih berat bila dialami oleh kelompok dengan imunitas rendah [3].

Pencegahan dan penanganan *varicella* memerlukan perhatian khusus, terutama di lingkungan yang rawan penularan seperti sekolah, sementara imunisasi *varicella* belum menjadi program wajib nasional sehingga perlindungan masyarakat terhadap penyakit ini masih terbatas. Faktor lingkungan, pengetahuan masyarakat, dan pola pengobatan turut berperan dalam persebaran serta penanganan penyakit cacar air di Indonesia [4].

Salah satu permasalahan utama dalam penyakit cacar di Indonesia adalah kesulitan diagnosis diferensial penyakit cacar karena bisa meningkatkan risiko komplikasi dan penyebaran penyakit yang lebih luas, serta menimbulkan beban sosial dan ekonomi, terutama di wilayah dengan fasilitas kesehatan terbatas [4].

Deteksi dini memiliki peran krusial dalam pengelolaan penyakit secara efektif, karena identifikasi yang tepat waktu dapat membantu tenaga medis untuk memastikan pengobatan yang cepat dan sesuai, mengurangi risiko perkembangan komplikasi serius, meminimalkan transmisi ke masyarakat luas, serta meningkatkan efisiensi alokasi sumber daya kesehatan yang terbatas di wilayah tertinggal.

Mengingat pentingnya deteksi dini tersebut, pemahaman mendalam tentang epidemiologi penyakit cacar di Indonesia menjadi fondasi yang esensial untuk merancang strategi pencegahan dan pengendalian yang efektif. Penyakit cacar, khususnya cacar air (*varicella*) dan cacar monyet (*monkeypox*), menimbulkan dampak signifikan terhadap kesehatan masyarakat dan sistem kesehatan di Indonesia. Namun, data epidemiologi cacar air dan cacar sejenisnya di Indonesia masih terbatas, dengan angka insidensi dan prevalensi cacar air di Indonesia belum diteliti secara menyeluruh meskipun kasus cacar air telah terjadi secara sporadis [5].

Berbagai penelitian menunjukkan bahwa dampak klinis, ekonomi, dan sosial penyakit cacar cukup substansial [6], [7], terutama di wilayah dengan keterbatasan akses vaksinasi dan fasilitas kesehatan [6]

Proses identifikasi penyakit cacar umumnya dilakukan melalui pemeriksaan klinis dan visual oleh tenaga medis profesional. Cara ini membutuhkan banyak waktu, tenaga, dan keahlian khusus, namun tetap memiliki keterbatasan karena rawan kesalahan interpretasi manusia serta tidak efisien jika diterapkan pada populasi pasien yang besar atau dalam situasi wabah. Keterbatasan tersebut menegaskan perlunya sistem deteksi otomatis yang lebih cepat, akurat, dan konsisten. Salah satu pendekatan yang banyak digunakan adalah analisis citra digital untuk mengidentifikasi gejala penyakit cacar melalui

karakteristik lesi kulit, warna lesi, tekstur, maupun morfologi pustula. Di antara berbagai teknik, *Convolutional Neural Networks (CNN)* menjadi metode yang menonjol karena mampu mempelajari pola langsung dari data gambar lesi cacar tanpa perlu proses ekstraksi fitur secara manual [8].

Dalam perbandingan sistem penyakit cacar berbasis citra, pemilihan arsitektur model *CNN* yang tepat menjadi faktor penting dalam menentukan akurasi dan efisiensi proses pelatihan. Beberapa studi terkait telah mengimplementasikan metode *CNN* untuk klasifikasi penyakit cacar berbasis citra, seperti *AlexNet* mencapai akurasi 92% pada empat kelas (2024). Kemudian hasil evaluasi model pada arsitektur *MobileNetV3-Small* dalam pendekatan *transfer learning* untuk klasifikasi deteksi penyakit cacar monyet dari lesi kulit mencapai akurasi 96.8%. Perbandingan ini akan mengungkap *trade-off* antara akurasi dan efisiensi yang krusial untuk sistem deteksi lapangan di wilayah tertinggal Indonesia.

Berdasarkan persoalan tersebut pada perbandingan performa arsitektur *AlexNet* dan *MobileNetV3-Small* untuk penyakit cacar. Perbandingan ini diharapkan dapat memberikan gambaran mengenai pengaruh pemilihan arsitektur terhadap akurasi dan efisiensi model terhadap penyakit cacar. Hasil penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam perbandingan sistem citra berbasis *CNN*, sehingga dapat mendukung proses diagnosis yang cepat dan akurat bagi tenaga medis serta meningkatkan efektivitas deteksi dini penyakit cacar di masyarakat.

2. TINJAUAN PUSTAKA


Landasan teori berguna sebagai pijakan ilmiah dalam pelaksanaan penelitian ini. Bagian tersebut memuat kajianteori, konsep dasar, serta temuan penelitian sebelumnya yang berkaitan dengan topik perbandingan arsitektur *alexnet* dan *mobilenetv3-small* menggunakan *attention mechanism* pada penyakit cacar. Teori-teori yang dipaparkan didalamnya mencakup Penyakit Cacar, *Convolutional Neural Network*, *Transfer Learning*, *AlexNet*, *MobileNetV3*, *Attention Mechanism*, *Deep Learning*.

2.1. MobileNet V3

MobileNetV3 merupakan generasi terbaru dari keluarga arsitektur *MobileNet* yang dirancang khusus untuk meningkatkan efisiensi komputasi pada perangkat mobile. *MobileNetV3* merupakan penggabungan teknik-teknik pencarian arsitektur jaringan yang saling melengkapi dengan inovasi desain arsitektur baru untuk mencapai pertukaran optimal antara akurasi dan latensi pada perangkat mobile dengan CPU terbatas [9].

Pengembangan *MobileNetV3* menggunakan dua teknik pencarian utama. *Platform-Aware Neural Architecture Search (NAS)* menemukan struktur jaringan global yang optimal dengan menyesuaikan faktor bobot untuk keseimbangan antara akurasi dan

latensi. *NetAdapt* kemudian melakukan penyetelan halus pada lapisan individual untuk memaksimalkan rasio antara peningkatan akurasi dan pengurangan latensi. Selain itu, inovasi dalam desain lapisan akhir, pengoptimalan filter awal, dan pengenalan fungsi nonlinear *hard swish (h-swish)* berkontribusi pada peningkatan efisiensi keseluruhan. *MobileNetV3 block* merupakan komponen utama dalam arsitektur *MobileNetV3* yang dirancang untuk mengekstraksi fitur citra secara efisien dengan kompleksitas komputasi yang rendah. Proses dimulai dengan penggunaan konvolusi 1×1 untuk memperluas dan memperkaya representasi fitur. Fitur diproses menggunakan konvolusi *depthwise* 3×3 yang berfungsi mengekstraksi informasi spasial dengan jumlah parameter yang lebih sedikit dibandingkan konvolusi standar. Untuk meningkatkan kualitas fitur yang dihasilkan, *MobileNetV3* mengintegrasikan mekanisme perhatian berbasis *channel (Squeeze-and-Excitation)* yang berfungsi menekankan fitur penting dan menekan fitur yang kurang relevan. Pada tahap akhir, konvolusi 1×1 digunakan untuk menyesuaikan kembali jumlah *channel* keluaran, serta dapat ditambahkan *residual connection* untuk menjaga stabilitas pelatihan dan meningkatkan kinerja model. Dapat dilihat pada gambar 2.



Gambar 1. Block MobileNet V3 [9]

2.2. MobileNet V3-Small

MobileNetV3-Small dirancang untuk perangkat dengan sumber daya terbatas dengan struktur yang lebih kompak. Expansion size pada model ini berkisar dari 16 hingga 576 (lebih rendah dari *Large* yang mencapai 960), mencerminkan upaya untuk mengurangi beban komputasi. Model ini berakhir pada 1.024 *channel* output sebelum klasifikasi, dibandingkan 1.280 pada *Large* [9].

Modul *Squeeze-and-Excitation* diterapkan pada hampir semua layer di *MobileNetV3-Small*, menunjukkan bahwa *selective attention channel* sangat kritis untuk efisiensi representasi pada model berukuran kecil. Penempatan *h-swish* juga lebih agresif pada *Small* dibandingkan *Large*, diterapkan sejak layer awal untuk memaksimalkan manfaat efisiensi pada model yang dibatasi sumber daya.

Hasil pengujian menunjukkan *MobileNetV3-Small* mencapai akurasi 67,5% dengan hanya 2,5 juta parameter dan 57 juta MAdds, meningkat 6,6% dibanding *MobileNetV2* dengan latensi serupa. Untuk deteksi objek pada COCO, model ini mencapai 16,1 mAP dengan latensi 43 milidetik, yaitu 2,4 mAP lebih tinggi dan 35% lebih cepat dari *MobileNetV2* 0.35.

[9]. Spesifikasi detail dari arsitektur *MobileNetV3-Small* dapat dilihat pada Tabel 2.


Tabel 2. Spesifikasi arsitektur *MobileNetV3-Small* [9]

Input	Operator	Exp size	#out	SE	NL	S
$224^2 \times 3$	conv2d, 3x3	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	✓	RE	2
$56^2 \times 16$	bneck, 3x3	72	24	-	RE	2
$28^2 \times 24$	bneck, 3x3	88	24	-	RE	1
$28^2 \times 24$	bneck, 5x5	96	40	✓	HS	2
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	120	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	144	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	288	96	✓	HS	2
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	conv2d, 1x1	-	576	✓	HS	1
72×576	pool, 7x7	-	-	-	-	1
12×576	conv2d, 1x1, NBN	-	1024	-	HS	1
12×1024	conv2d, 1x1, NBN	-	k	-	-	1

2.3. Alexnet

Arsitektur *AlexNet* merupakan salah satu dari arsitektur *CNN* yang berhasil menjadi pemenang kompetisi *ILSVRC (ImageNet Large-Scale Visual Recognition Competition)* yang diselenggarakan oleh *ImageNet* pada tahun 2012 [10].


Arsitektur *AlexNet* memiliki jumlah layer sebanyak 8 lapisan yang terdiri dari 5 lapisan konvolusi dan 3 lapisan *fully-connected layer* dapat dilihat pada gambar 3.



Gambar 2. Arsitektur *AlexNet* [10]

3. METODE PENELITIAN

Pada Gambar 4 tahapan penelitian diatas dapat dilihat serangkaian tahapan dan langkah-langkah penelitian ini. Dalam penelitian ini, metode penelitian yang digunakan dirancang secara sistematis agar hasil penelitian dapat terarah dan sesuai dengan tujuan yang telah ditetapkan. Tahapan penelitian dimulai dari studi literatur, pengumpulan dataset, perancangan model klasifikasi menggunakan *Convolutional Neural Network* dengan pendekatan *transfer learning* dan menggunakan *attention mechanism* untuk *mobilenet v3-small* dan *alexnet* serta implementasi pengujian.



Gambar 3. Metode Penelitian

3.1. Studi Literatur

Tahapan ini diawali dengan melakukan kajian literatur terhadap berbagai jurnal dan buku yang berkaitan dengan topik penelitian, yaitu perbandingan arsitektur *Alexnet* dan *Mobilenetv3-Small* menggunakan *Attention Mechanism* pada penyakit cacar.

3.2. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini adalah *Mpox Skin Lesion Dataset Version 2.0 (MSLD v2.0)* yang bersifat publik dan diakses dari Kaggle. Dataset ini terdiri dari 755 citra lesi kulit yang diklasifikasikan ke dalam enam kategori, yaitu *Monkeypox*, *Chickenpox*, *Measles*, *Cowpox*, *HFMD*, dan *Healthy* yang dapat dilihat pada Tabel 3.

Tabel 3. Dataset Penyakit Cacar

No	Kelas Dataset	Contoh Citra
1	Mpox	
2	Chickenpox	
3	Measles	
4	Cowpox	
5	HFMD	
6	Healthy	

3.3. Perancangan

Tahap awal penelitian dilakukan dengan merancang sistem arsitektur *AlexNet* dan *MobileNetV3-Small* yang diintegrasikan dengan *Channel Attention Mechanism* untuk penyakit cacar. Perancangan sistem dimulai dengan menyiapkan dataset citra cacar yang digunakan sebagai data pelatihan, pengujian, dan validasi. Dataset yang digunakan telah memiliki ukuran citra 224×224 piksel, sehingga telah sesuai dengan spesifikasi input kedua arsitektur model. Pada tahap *preprocessing*, tidak dilakukan proses image resizing, melainkan hanya dilakukan verifikasi kesesuaian ukuran citra untuk memastikan kompatibilitas dengan *AlexNet* dan *MobileNetV3-Small*. Tahap *preprocessing* difokuskan pada peningkatan kualitas data dan penyesuaian format input model yang akan diproses melalui *backbone CNN* dan modul *Attention*.

Tahap augmentasi data bertujuan untuk meningkatkan keragaman dan kualitas dataset pelatihan dengan augmentasi mencakup transformasi

geometri (*rotation, translation, reflection, shear, scaling*), penyesuaian warna (*hue adjustment, saturation adjustment, contrast adjustment, brightness jitter*), dan penambahan *noise*. Augmentasi ini dirancang untuk mensimulasikan variabilitas alami dalam pengambilan citra penyakit cacar sehingga dapat meningkatkan keragaman citra, mengurangi risiko overfitting, dan membantu model belajar fitur-fitur yang robust pada berbagai kondisi capture.

Dataset dibagi menjadi tiga bagian, yaitu training, validation, dan testing dengan rasio 80:10:10. Tahap selanjutnya adalah pemodelan *CNN* dengan memanfaatkan arsitektur *AlexNet* dan *MobileNetV3-Small* sebagai *backbone* yang telah dilatih sebelumnya pada dataset *ImageNet*. Pada tahap ini, dilakukan integrasi *Channel Attention Mechanism* yang berfungsi untuk meningkatkan fokus model pada fitur-fitur kritis dari lesi cacar. *Channel Attention* bekerja dengan menghitung *attention weights* untuk setiap *channel feature map*, sehingga channel yang relevan dengan karakteristik lesi cacar (seperti warna, tekstur, dan morfologi pustula) akan diberi bobot lebih tinggi, sedangkan channel yang tidak relevan akan ditekan. Mekanisme ini membantu model mengidentifikasi region dan channel yang paling penting untuk membedakan antar kelas penyakit cacar.


Integrasi *Channel Attention* dilakukan setelah setiap blok konvolusi utama dalam *backbone* model. Untuk *AlexNet*, modul *Attention* disisipkan di tengah-tengah *fully connected layers*, sedangkan untuk *MobileNetV3-Small*, *Channel Attention* diintegrasikan pada akhir setiap *bottleneck block* (*Inverted Residual Block*) untuk memaksimalkan efisiensi komputasi pada model yang compact. Implementasi *Channel Attention* menggunakan *squeeze-and-excitation (SE) mechanism* dengan struktur: *Global Average Pooling* $\rightarrow$ *Dense* (dengan dimensi reduction) $\rightarrow$ *ReLU* $\rightarrow$ *Dense* (restore to original dimension) $\rightarrow$ *Sigmoid*, yang menghasilkan *channel-wise attention weights*.

Dua pendekatan utama digunakan dalam penelitian ini, yakni *feature extraction* dan *fine-tuning*. Pada tahap *feature extraction*, lapisan-lapisan awal (*early layers*) dari *pre-trained* model yang telah dibekukan (*frozen*) dimanfaatkan untuk mengidentifikasi dan mengekstraksi fitur-fitur dasar (tepi, tekstur, warna) yang umum dalam berbagai citra. Fitur-fitur ini kemudian diproses melalui lapisan-lapisan mid-level dan high-level, di mana *Channel Attention Mechanism* mulai berperan untuk menonjolkan channel yang relevan dengan karakteristik spesifik lesi cacar.

Pada tahap *fine-tuning*, lapisan-lapisan atas dari *backbone* model beserta seluruh modul *Attention Mechanism* diperbarui melalui proses pembelajaran iteratif dengan learning rate yang lebih rendah. Strategi ini memungkinkan model untuk secara bertahap menyesuaikan (adapt) bobot-bobot konvolusi dan parameter *attention* untuk meningkatkan kekhususan dalam mengenali pola-pola visual yang karakteristik pada citra penyakit cacar di dataset target (transfer

learning). Kombinasi antara *frozen early layers* dan *trainable high-level layers* + *Attention* modules ini terbukti mempercepat konvergensi dan meningkatkan generalisasi model.

Lapisan akhir dari arsitektur model dimodifikasi dengan menambahkan custom head network yang terdiri dari *Global Average Pooling* untuk mengurangi dimensionalitas feature maps, *Channel Attention* sekali lagi untuk *re-weighting channel* yang paling relevan sebelum klasifikasi, lapisan *Dense* dengan 256 unit dan aktivasi *ReLU* untuk pembelajaran fitur non-linear yang lebih tinggi, *Dropout* (rate 0.5) sebagai teknik regularisasi untuk mencegah overfitting dan output layer dengan aktivasi *Softmax* untuk semua 6 kelas dataset penyakit cacar (*Monkeypox*, *Chickenpox*, *Measles*, *Cowpox*, *HFMD*, *Healthy*). Rancangan head ini dirancang khusus untuk memanfaatkan representasi yang telah di-enrich oleh *Attention Mechanism* di backbone, sehingga keputusan klasifikasi final didasarkan pada fitur-fitur yang telah terbukti relevan. Hal ini diharapkan dapat meningkatkan akurasi dibanding model tanpa *Attention*, khususnya dalam membedakan penyakit cacar yang memiliki gejala visual yang mirip



Gambar 4. Skema Perancangan

Selanjutnya dilakukan tahap evaluasi menggunakan *classification report* dan *confusion matrix* untuk menilai kemampuan model dalam mengenali penyakit cacar. Evaluasi khusus juga dilakukan untuk mengukur dampak penambahan *Attention Mechanism* terhadap performa (akurasi, *precision*, *recall*, *F1-score*) dan efisiensi (waktu inferensi, jumlah parameter) pada masing-masing arsitektur (*AlexNet* + *Attention Mechanism*, *MobileNetV3-Small* + *Attention Mechanism*). Rancangan ini diharapkan dapat menghasilkan model yang optimal untuk penyakit cacar serta membantu masyarakat Indonesia dalam pengenalan jenis-jenis penyakit cacar melalui sistem diagnosis berbasis citra

yang cepat dan akurat. Skema rancangan tersebut dapat dilihat pada gambar 5.

3.4. Implementasi

Pada tahapan ini dilakukan implementasi model *CNN* dengan arsitektur *AlexNet* dan *MobileNetV3-Small* dengan menggunakan *Attention Mechanism*. Model dilatih menggunakan data latih yang telah di tahap *preprocessing*. Parameter pelatihan seperti *learning rate*, *batch size*, dan *optimizer* yang digunakan diatur sesuai kebutuhan untuk mendapatkan hasil yang optimal.

Tabel 4. Skenario Pengujian

Parameter	Configuration
Arsitektur	MobileNetV3-Small, AlexNet
Attention Models	AlexNet dengan Channel Attention, MobileNetV3-Small dengan Channel Attention
Input Image Size	224
Dense	20
Batch Size	16 dan 32
Optimizer	Adam
Epoch	50
Learning Rate	0,001 dan 0,0001
Activation Function	Softmax

3.5. Pengujian

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan melakukan uji coba terhadap data uji. Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan metode yang digunakan dengan *Confusion Matrix* dalam menghitung nilai *precision*, *recall*, dan *accuracy* yang dapat dilihat pada Persamaan (2), (3), dan (4).

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (4)$$

Keterangan:

TP: Jumlah data positif yang terklasifikasi dengan benar oleh sistem

TN: Jumlah data negatif yang terklasifikasi dengan benar oleh sistem

FN: Jumlah data negatif yang terklasifikasi dengan salah oleh sistem

FP: Jumlah data positif yang terklasifikasi dengan salah oleh sistem

Untuk waktu komputasi dan kompleksitas model yang dapat dilihat pada (5) dan (6).

$$T_{train} = \frac{Total\ FLOPs \times epochs \times B \times 3}{Hardware\ FLOPs} \quad (5)$$

Keterangan:

- B: batch size
- Faktor 3: forward + backward pass

- Hardware FLOPS: GPU/TPU capacity (GFLOPS)

$$Total\ FLOPs = \sum_{conv\ layers} FLOPs_{conv} + \sum_{FC\ layers} (2 \times N_{in} \times N_{out}) \quad (6)$$

Keterangan:

- FLOPs conv: Jumlah operasi floating-point
- Fully Connected (FC) layer: N_{in} neuron input, N_{out} neuron output.

Skenario pengujian yang dilakukan adalah sebagai berikut:

- perbandingan dengan arsitektur MobileNetV3-Small dan AlexNet dengan menggunakan Attention Mechanism.
- Learning rate 0.001 dan 0.0001.
- Batch Size 16 dan 32
- Epoch 50.
- Optimizer Adam.

4. HASIL DAN PEMBAHASAN

Pada bab ini menyajikan hasil implementasi, pengujian, dan analisis kinerja model dalam perbandingan penyakit cacar menggunakan arsitektur AlexNet dan MobileNetV3-Small dengan integrasi Channel Attention Mechanism melalui pendekatan transfer learning. Pengujian dilakukan melalui serangkaian skenario dengan variasi pelatihan (*batch size* 16/32, *learning rate* 0.0001/0.001, *optimizer* Adam, 50 *epoch*) untuk menilai kestabilan dan

efektivitas model. Hasil yang diperoleh kemudian dianalisis berdasarkan metrik akurasi, *precision*, *recall*, *F1-score*, *loss*, serta waktu inferensi guna melihat sejauh mana model mampu melakukan perbandingan performa arsitektur AlexNet dan MobileNetV3-Small dengan Channel Attention Mechanism pada dataset penyakit cacar.

4.1. Skenario Pengujian

Pengujian pada penelitian ini dilakukan menggunakan dataset sebanyak 755 citra asli yang dikelompokkan ke dalam 6 kelas (*Monkeypox*, *Chickenpox*, *Cowpox*, *Measles*, *HFMD*, *Healthy*) dengan pembagian rasio 80-10-10 untuk *training*, *validation*, dan *testing*. Pengujian fokus pada dua skenario utama: AlexNet+Channel Attention dan MobileNetV3-Small+Channel Attention menggunakan pendekatan transfer learning dengan lapisan awal beku dan *fine-tuning custom head* (*Global Average Pooling*, *Channel Attention*, *Dense 256*, *Dropout 0.5*, *Softmax*). Konfigurasi pelatihan mencakup *optimizer* Adam, *batch size* 16/32, *learning rate* 0.0001/0.001, 50 *epoch*, input size 224×224 piksel, serta augmentasi data untuk mencegah overfitting, diikuti evaluasi melalui *confusion matrix* (*accuracy*, *precision*, *recall*, *F1-score*), kurva training/validation, waktu inferensi, dan kompleksitas model (parameter count, FLOPs), sebagaimana dapat dirangkum pada Tabel 5.

Tabel 5. Skenario Pengujian Batch Size dan Learning Rate

Skenario Pengujian	Model	Batch Size	Learning Rate
Pengujian Ke-1	AlexNet + Attention Mechanism	16	0.001
Pengujian Ke-2	AlexNet + Attention Mechanism	16	0.0001
Pengujian Ke-3	AlexNet + Attention Mechanism	32	0.001
Pengujian Ke-4	AlexNet + Attention Mechanism	32	0.0001
Pengujian Ke-5	MobileNetV3-Small + Attention Mechanism	16	0.001
Pengujian Ke-6	MobileNetV3-Small + Attention Mechanism	16	0.0001
Pengujian Ke-7	MobileNetV3-Small + Attention Mechanism	32	0.001
Pengujian Ke-8	MobileNetV3-Small + Attention Mechanism	32	0.0001

4.2. Hasil Pengujian


Hasil pengujian dalam penelitian ini dimanfaatkan untuk mengukur performa model AlexNet + Attention Mechanism dan MobileNetV3-Small + Attention Mechanism melalui 8 skenario pelatihan yang berbeda, dengan variasi *batch size* 16/32 dan *learning rate* 0.001/0.0001 menggunakan *optimizer* Adam. Semua skenario mengikuti parameter

yang sudah ditentukan di Tabel 6, sehingga perbedaan kinerja antar konfigurasi bisa dibandingkan secara jelas dan terukur. Pengukuran dilakukan dengan mencatat nilai akurasi, *precision*, *recall*, *F1-score*, serta waktu training selama 50 *epoch* guna melihat dampak perubahan *hyperparameter* terhadap hasil akhir model. Rincian hasil dari seluruh pengujian dapat dilihat pada Tabel 6 berikut.

Tabel 6. Hasil Pengujian

Skenario Pengujian	Accuracy	Precision	Recall	F1	Time
Pengujian Ke-1	85.08%	0.8775	0.8385	0.8576	78m 33s
Pengujian Ke-2	97.92%	0.9801	0.9783	0.9792	80m 31s
Pengujian Ke-3	94.62%	0.9495	0.9415	0.9455	71m 48s
Pengujian Ke-4	98.02%	0.9802	0.9792	0.9797	75m 59s
Pengujian Ke-5	97.26%	0.9735	0.9717	0.9726	88m 55s
Pengujian Ke-6	86.40%	0.8843	0.8517	0.8677	86m 50s
Pengujian Ke-7	97.45%	0.9754	0.9726	0.9740	87m 12s
Pengujian Ke-8	85.93%	0.8781	0.8300	0.8534	84m 51s

Hasil tersebut menunjukkan bahwa variasi batch size dan learning rate memberikan pengaruh signifikan terhadap performa model. *Learning rate* 0.0001 secara konsisten menghasilkan akurasi lebih tinggi pada kedua arsitektur dibandingkan *learning rate* 0.001, dengan performa terbaik dicapai pada *AlexNet* + *Attention* (Pengujian Ke-4) mencapai 98.02% dan *MobileNetV3-Small* + *Attention* (Pengujian Ke-5) 97.26%. Sementara itu, meskipun *batch size* 32 pada *AlexNet* lebih optimal, *MobileNetV3-Small* justru menunjukkan performa lebih stabil dengan *batch size* 16. Temuan ini menegaskan bahwa kombinasi *learning rate* rendah (0.0001) dengan *batch size* yang disesuaikan lebih efektif dalam meningkatkan kemampuan generalisasi model pada dataset penyakit cacar. Visualisasi *confusion matrix* pada konfigurasi terbaik untuk kedua model dapat dilihat pada Gambar 6.




Gambar 6. Visualisasi *Confusion Matrix*

Pada gambar 6 memperlihatkan hasil confusion matrix dari konfigurasi terbaik pada arsitektur *AlexNet* yang dipadukan dengan *Attention* serta *MobileNetV3-Small* yang juga menggunakan *Attention*. Dari visualisasi tersebut terlihat bahwa nilai prediksi yang benar mendominasi bagian diagonal utama matriks. Hal ini mengindikasikan bahwa sebagian besar sampel pada data uji berhasil diklasifikasikan sesuai dengan kelas sebenarnya.

Pada arsitektur *AlexNet* + *Attention*, jumlah kesalahan prediksi tergolong sangat rendah dan hanya terjadi pada beberapa sampel yang memiliki karakteristik visual yang mirip, misalnya antara kelas *Chickenpox* dan *Measles*. Sementara itu, *MobileNetV3-Small* + *Attention* juga menunjukkan pola klasifikasi yang baik, meskipun masih terdapat sedikit kesalahan yang lebih banyak dibandingkan *AlexNet*.


Secara umum, kedua model memiliki kemampuan pemisahan kelas yang sangat baik terhadap enam kategori penyakit cacar yang diuji. Kesalahan klasifikasi yang muncul relatif kecil dan tidak terkonsentrasi pada satu kelas tertentu, sehingga dapat dikatakan bahwa model tidak menunjukkan kecenderungan bias terhadap kelas tertentu. Selanjutnya, untuk melihat performa pelatihan secara lebih komprehensif, khususnya tren *training accuracy* dan *validation accuracy* hingga *epoch* ke-50 pada konfigurasi terbaik (*AlexNet* Ke-4 dan *MobileNetV3-Small* Ke-5) dengan *optimizer Adam*, visualisasi tersebut dapat dilihat pada Gambar 7.



Gambar 7. Grafik *Training* dan *Validation Accuracy*

Pada Gambar 7 ditampilkan perbandingan grafik *training accuracy* dan *validation accuracy* hingga *epoch* ke-50 pada model *AlexNet* dan *MobileNetV3-Small*. Grafik *AlexNet* pada gambar pertama menunjukkan peningkatan akurasi yang bertahap dan stabil sejak *epoch* awal, dengan selisih yang relatif kecil antara data pelatihan dan validasi pada akhir pelatihan. Hal ini mengindikasikan bahwa model mampu mencapai konvergensi dengan kemampuan generalisasi yang baik serta tanpa indikasi *overfitting* yang signifikan.

Sementara itu, *MobileNetV3-Small* memperlihatkan peningkatan akurasi yang lebih cepat, namun disertai fluktuasi *validation accuracy* yang lebih tajam pada fase awal hingga pertengahan pelatihan. Meskipun demikian, setelah melewati sekitar *epoch* ke-25, kurva *validation accuracy* mulai stabil dan mengikuti tren *training accuracy* dengan selisih yang semakin kecil. Kondisi ini menunjukkan bahwa *MobileNetV3-Small* juga berhasil mencapai konvergensi dan memiliki performa generalisasi yang baik, meskipun dinamika pelatihannya pada tahap awal lebih berfluktuasi dibandingkan *AlexNet*. Visualisasi tren *training loss* dan *validation loss* hingga *epoch* ke-50 untuk kedua model tersebut dapat dilihat pada Gambar 8.



Gambar 8. Grafik *Training* dan *Validation Loss*

Pada gambar 8 menunjukkan perbandingan grafik *training loss* dan *validation loss* hingga *epoch* ke-50 pada model *AlexNet* dan *MobileNetV3-Small*. Analisis dilakukan untuk mengevaluasi pola konvergensi dan kemampuan generalisasi masing-masing arsitektur.

Pada model gambar pertama *AlexNet*, *training loss* mengalami penurunan yang konsisten hingga mendekati nol pada *epoch* ke-50, yang menunjukkan bahwa model mampu mempelajari pola data pelatihan dengan baik. Namun, *validation loss* memperlihatkan fluktuasi yang cukup signifikan pada *epoch* awal hingga pertengahan. Beberapa lonjakan nilai *validation loss* mengindikasikan ketidakstabilan performa pada data validasi dan potensi terjadinya *overfitting* sementara sebelum akhirnya kurva mulai

stabil dan mendekati nilai training loss di akhir pelatihan.

Sebaliknya, pada model gambar kedua *MobileNetV3-Small*, penurunan *training loss* dan *validation loss* berlangsung lebih stabil dan konsisten. Fluktuasi yang terjadi relatif kecil, serta jarak antara kedua kurva cenderung sempit sepanjang proses pelatihan. Pola ini menunjukkan kemampuan generalisasi yang lebih baik dibandingkan *AlexNet*, karena model tidak hanya mampu menurunkan kesalahan pada data pelatihan, tetapi juga mempertahankan performa yang seimbang pada data validasi.

Berdasarkan keseluruhan hasil pengujian, terlihat bahwa variasi *learning rate* dan *batch size* memberikan pengaruh yang berbeda pada masing-masing arsitektur. Penggunaan *learning rate* 0.0001 cenderung menghasilkan performa yang lebih stabil dibandingkan 0.001, baik pada *AlexNet + Channel Attention* maupun *MobileNetV3-Small + Channel Attention*. Pada konfigurasi tertentu, *AlexNet* menunjukkan capaian akurasi yang sedikit lebih tinggi, sedangkan *MobileNetV3-Small* memperlihatkan konsistensi performa yang relatif seimbang pada beberapa skenario pengujian.

Apabila ditinjau dari kurva accuracy dan loss hingga *epoch* ke-50, kedua arsitektur sama-sama menunjukkan proses konvergensi yang baik. *AlexNet* memperlihatkan pola pelatihan yang lebih bertahap dengan fluktuasi yang relatif terkendali pada fase akhir, sementara *MobileNetV3-Small* menunjukkan dinamika yang lebih fluktuatif pada tahap awal sebelum akhirnya stabil. Perbedaan karakteristik ini menggambarkan respons masing-masing arsitektur terhadap konfigurasi hyperparameter yang digunakan.

Secara umum, integrasi *Channel Attention Mechanism* memberikan dampak positif terhadap proses pembelajaran fitur pada kedua model. Perbandingan yang dilakukan menunjukkan bahwa meskipun terdapat perbedaan pada stabilitas pelatihan dan dinamika konvergensi, kedua arsitektur mampu mencapai performa yang kompetitif pada dataset yang digunakan. Dengan demikian, hasil penelitian ini menegaskan adanya perbedaan karakteristik kinerja antara *AlexNet* dan *MobileNetV3-Small* ketika dikombinasikan dengan *Channel Attention* dalam skenario pelatihan yang sama.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian yang telah dilakukan, penelitian ini menunjukkan adanya perbedaan karakteristik performa antara arsitektur *AlexNet* dan *MobileNetV3-Small* yang diintegrasikan dengan *Channel Attention Mechanism* pada dataset penyakit cacar. *AlexNet* cenderung memperlihatkan capaian akurasi yang sedikit lebih tinggi pada konfigurasi tertentu dengan pola konvergensi yang stabil, sedangkan *MobileNetV3-Small* menunjukkan efisiensi komputasi yang lebih ringan dengan performa

yang tetap kompetitif. Variasi *learning rate* dan *batch size* terbukti memengaruhi stabilitas pelatihan pada kedua arsitektur, di mana *learning rate* yang lebih rendah memberikan hasil yang lebih konsisten. Hasil ini menegaskan bahwa pemilihan arsitektur dan konfigurasi hyperparameter perlu disesuaikan dengan kebutuhan implementasi, khususnya dalam mempertimbangkan keseimbangan antara akurasi dan efisiensi komputasi. Untuk penelitian selanjutnya, disarankan dilakukan pengujian pada dataset dengan jumlah data yang lebih besar, penambahan variasi *attention mechanism* lainnya, serta evaluasi pada perangkat dengan keterbatasan sumber daya untuk memperoleh gambaran performa yang lebih komprehensif dalam skenario implementasi nyata.

DAFTAR PUSTAKA

- [1] "Wabah cacar WHO red book".
- [2] Y. Nawaz, M. K. Ullah, and K. Iqbal, "A Review on Smallpox", doi: 10.36648/2254-609X.11.6.65.
- [3] Musarifa, Hikmah, and Fardinah, "Analisis Model Matematika SEITR pada Penyakit Cacar Air," *JOMTA Journal of Mathematics: Theory and Applications*, vol. 3, no. 2, 2021.
- [4] P. A. Siregar, N. A. Azwa, A. D. Mrp, and S. Maghfirah, "EPIDEMIOLOGI PENYAKIT MENULAR CACAR AIR," *JK: Jurnal Kesehatan*, vol. 1, no. 1, pp. 10–24, 2023.
- [5] A. Riset *et al.*, "FAKUMI MEDICAL JOURNAL," 2017.
- [6] M. Melgar *et al.*, "Clinical and economic burden of varicella in pediatric patients hospitalized in four institutions in Guatemala," *PLOS Global Public Health*, vol. 5, no. 1, Jan. 2025, doi: 10.1371/journal.pgph.0004165.
- [7] H. A. Shah, A. Meiwald, C. Perera, G. Casabona, P. Richmond, and N. Jamet, "Global Prevalence of Varicella-Associated Complications: A Systematic Review and Meta-Analysis," *Infect. Dis. Ther.*, vol. 13, no. 1, pp. 79–103, Jan. 2024, doi: 10.1007/s40121-023-00899-7.
- [8] A. González-Briones, S. L. Florez, P. Chamoso, L. F. Castillo-Ossa, and E. S. Corchado, "Enhancing Plant Disease Detection: Incorporating Advanced CNN Architectures for Better Accuracy and Interpretability," *International Journal of Computational Intelligence Systems*, vol. 18, no. 1, Dec. 2025, doi: 10.1007/s44196-025-00835-2.
- [9] A. Howard *et al.*, "Searching for MobileNetV3," Nov. 2019, [Online]. Available: <http://arxiv.org/abs/1905.02244>
- [10] W. Tang, J. Sun, S. Wang, and Y. Zhang, "EAI Endorsed Transactions on e-Learning Review of AlexNet for Medical Image Classification", doi: 10.4108/_____.