

ANALISIS PERBANDINGAN ARSITEKTUR CNN DAN FUNGSI AKTIVASI UNTUK KLASIFIKASI GAMBAR KEPALA CHARGER HITAM-PUTIH

¹El Emir Di Haryanto ²Ninuk Wiliani

¹² Teknik Informatika, Fakultas Teknik, Universitas Pancasila

¹4521210031@univpancasila.ac.id, ²ninuk.wiliani@univpancasila.ac.id

Abstrak

Penelitian ini bertujuan untuk membandingkan kinerja dua arsitektur jaringan saraf konvolusional (CNN), yaitu *VGG16* dan *ResNet50*, dalam tugas klasifikasi gambar kepala charger hitam-putih. Penelitian ini juga mengevaluasi pengaruh empat fungsi aktivasi utama (*ReLU*, *Leaky ReLU*, *Sigmoid*, dan *Tanh*) terhadap performa model. *Dataset* yang digunakan terdiri dari 100 gambar, masing-masing 50 gambar kepala charger hitam dan putih, dengan resolusi 224x224 piksel. Pembagian data dilakukan dengan rasio 80:20 untuk pelatihan dan validasi, sementara model dilatih selama 15 *epoch* menggunakan *optimizer Adam* dengan *loss function categorical crossentropy*. Hasil pengujian menunjukkan bahwa arsitektur *VGG16* dengan fungsi aktivasi *Leaky ReLU* dan *Tanh* mencapai akurasi tertinggi sebesar 100%, sedangkan *ResNet50* hanya menghasilkan akurasi sebesar 50%. Hal ini mengindikasikan bahwa *ResNet50* gagal menangkap pola dari dataset dengan distribusi kecil. Penelitian ini memberikan wawasan mengenai kelebihan dan kekurangan kedua model serta peran penting fungsi aktivasi dalam meningkatkan performa CNN pada dataset tertentu, terutama untuk tugas klasifikasi dengan kompleksitas visual tinggi.

Kata kunci: *Deep Learning, CNN, VGG16, ResNet50, Fungsi Aktivasi, Klasifikasi Gambar.*

PENDAHULUAN

Klasifikasi gambar merupakan tantangan utama dalam bidang visi komputer yang terus berkembang. Salah satu metode paling populer adalah Convolutional Neural Network (CNN) yang memiliki kemampuan unggul dalam mengenali pola pada gambar. Penelitian ini fokus pada klasifikasi gambar kepala charger hitam-putih, yang memiliki tantangan karena keseragaman warna dan bentuknya. Klasifikasi objek seperti kepala charger hitam-putih menjadi tantangan karena kemiripan fitur visualnya.

Berdasarkan studi sebelumnya, arsitektur CNN seperti VGG16 dan ResNet50 telah menunjukkan keunggulan dalam berbagai tugas klasifikasi [1]. Namun, efektivitasnya bergantung pada konfigurasi, termasuk pemilihan fungsi aktivasi. Fungsi aktivasi seperti ReLU, Leaky ReLU, Sigmoid, dan Tanh dapat memengaruhi kemampuan model dalam menangkap pola data.

Penelitian ini bertujuan untuk menganalisis perbandingan kinerja berbagai arsitektur CNN dan fungsi aktivasi untuk menghasilkan model yang optimal dalam klasifikasi gambar kepala charger hitam-putih. Evaluasi kinerja VGG16 dan ResNet50 akan dilakukan dengan menguji pengaruh fungsi aktivasi terhadap akurasi, presisi, recall, dan F1-score.

Dataset yang digunakan terdiri dari 100 gambar, di mana proses preprocessing mencakup augmentasi dan normalisasi. Model dilatih dengan pembagian data 80:20 untuk pelatihan dan validasi, dengan evaluasi berdasarkan hasil confusion matriks. Studi ini diharapkan memberikan kontribusi pada pengembangan metode klasifikasi gambar di domain yang serupa.

Deep learning adalah bidang pembelajaran mesin yang menggunakan jaringan saraf tiruan untuk menganalisis data kompleks. Convolutional Neural Network (CNN) adalah sebuah arsitektur jaringan saraf yang dibuat khusus untuk mengatasi tugas-tugas seperti pengenalan gambar dan

pemrosesan data yang berbentuk grid. CNN menggunakan lapisan konvolusi untuk mengekstraksi fitur spasial penting dari data visual dan fitur penting dari data input.

Arsitektur seperti VGG16 menawarkan pendekatan yang mendalam dan berlapis-lapis untuk meningkatkan akurasi [2]. Oleh karena itu, CNN telah digunakan secara luas dalam berbagai aplikasi, termasuk deteksi objek dan klasifikasi gambar.

Fungsi aktivasi adalah elemen penting dalam jaringan saraf yang memperkenalkan non-linearitas. ReLU (Rectified Linear Unit) adalah fungsi aktivasi paling umum, tetapi fungsi lain seperti Leaky ReLU, Sigmoid, dan Tanh memiliki keunggulan masing-masing tergantung pada konteks[3].

VGG16 adalah model CNN yang memiliki arsitektur sederhana dengan lapisan konvolusi bertumpuk, memungkinkan ekstraksi fitur mendalam. ResNet50, di sisi lain, menggunakan residual learning untuk memitigasi masalah vanishing gradient, dengan menambahkan shortcut connections pada setiap blok.

METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen, yaitu pendekatan penelitian yang melibatkan pengujian model untuk mengevaluasi performa dan menganalisis hasil guna memahami efektivitas teknik atau metode tertentu dalam pengolahan data. Metode ini dilakukan dengan langkah-langkah terstruktur yang mencakup pengumpulan data, pengolahan data, pelatihan model, dan evaluasi performa.

Metode eksperimen dalam penelitian ini dirancang untuk menyelesaikan permasalahan klasifikasi gambar kepala charger hitam dan putih dengan memanfaatkan teknologi deep learning.

Kerangka Berpikir

Kerangka berpikir dalam penelitian ini berfokus pada pengembangan model klasifikasi gambar menggunakan arsitektur jaringan saraf convolutional (CNN). Proses penelitian mencakup tahapan berikut:

1. Identifikasi Masalah

Masalah yang didefinisikan adalah bagaimana mengklasifikasikan gambar kepala charger hitam dan putih secara akurat menggunakan model deep learning.

2. Pengumpulan Dataset

Dataset terdiri dari total 100 gambar kepala charger, dengan rincian 50 gambar kepala charger hitam dan 50 gambar kepala charger putih.

3. Preprocessing dan Augmentasi Data

Gambar diproses ulang melalui teknik augmentasi seperti rotasi, translasi, skala, shear, zoom, dan flip horizontal untuk meningkatkan variasi data. Seluruh gambar diubah ukurannya menjadi 224x224 piksel agar cocok dengan input layer model CNN[4].

4. Pembagian Dataset

Dataset dibagi menjadi dua segmen, yaitu 80% untuk data latih dan 20% untuk data validasi. Teknik augmentasi diterapkan hanya pada data latih, sedangkan data validasi hanya melalui proses normalisasi menggunakan rescale 1/255.

5. Perancangan dan Pelatihan Model

o Arsitektur Model

Dua arsitektur CNN, yaitu VGG16 dan ResNet50, digunakan dengan bobot awal yang telah dilatih pada dataset ImageNet. Lapisan tambahan yang diterapkan meliputi Global Average Pooling, Dense Layer dengan 256 unit dan fungsi aktivasi (ReLU, Leaky ReLU, Sigmoid, dan Tanh), serta Dropout Layer dengan rasio 0.5 dan 0.3 untuk mencegah overfitting[5].

o Pelatihan Model

Model dilatih menggunakan optimizer Adam dengan learning rate 1×10^{-5} dan fungsi loss categorical cross entropy[6]. Proses pelatihan dilakukan selama 15 epoch dengan batch size 32. Grafik akurasi dan kerugian digunakan untuk memantau kinerja model.

6. Evaluasi Model

Performa model dievaluasi menggunakan data validasi berdasarkan metrik akurasi, presisi, recall, dan F1-score. Confusion matriks digunakan untuk memberikan gambaran kemampuan model dalam mengenali setiap kelas.

7. Hasil dan Analisis

Hasil kinerja model VGG16 dan ResNet50 dibandingkan berdasarkan metrik evaluasi. Grafik perbandingan akurasi, presisi, recall, dan F1-score disusun untuk menganalisis performa masing-masing model. Analisis dilakukan untuk menentukan kelebihan dan kekurangan setiap model.

8. Kesimpulan

Model terbaik dipilih berdasarkan hasil evaluasi. Analisis kelebihan dan kekurangan setiap model digunakan untuk menentukan efektivitas metode yang diterapkan dalam penelitian ini.

Metode Augmentasi Data

Untuk meningkatkan diversitas data, teknik augmentasi diterapkan melalui rotasi, flipping, translasi, dan zooming menggunakan library Python seperti OpenCV dan TensorFlow [7]. Penerapan teknik augmentasi gambar dalam pelatihan model dapat meningkatkan jumlah variasi data, yang berkontribusi pada peningkatan akurasi deteksi dalam model berbasis CNN [8].

Bahasa Pemrograman

Seluruh proses penelitian dilakukan menggunakan library Python (seperti TensorFlow dan OpenCV) pada platform Google Colab. Platform ini dipilih untuk mendukung efisiensi, kolaborasi, dan kemudahan akses [9].

Dengan menggunakan metode eksperimen yang terstruktur, penelitian ini diharapkan dapat menghasilkan model klasifikasi gambar yang efektif dan akurat, serta memberikan analisis mendalam tentang performa model VGG16 dan ResNet50 dalam tugas klasifikasi gambar kepala charger hitam dan putih.

HASIL DAN PEMBAHASAN

Hasil penelitian menunjukkan bahwa penggunaan fungsi aktivasi mempunyai pengaruh yang signifikan terhadap performa model.

Visualisasi Dataset

Untuk memberikan gambaran yang lebih jelas tentang dataset, dilakukan pengujian dan pengambilan 10 contoh sampel, yang terdiri dari 5 gambar kepala charger hitam dan 5 gambar kepala charger putih.



Gambar 1.1 Hasil Sample yang diambil dari 10 Dataset

Hasil Uji Training

Hasil uji pelatihan CNN menunjukkan tingkat kesalahan model sepanjang proses pelatihan. Proses ini bertujuan untuk meminimalkan nilai loss, yang menunjukkan seberapa jauh prediksi model dari nilai sebenarnya pada data pelatihan.

1. Hasil Uji Training Model VGG16

- Hasil Akurasi Terbaik dari Fungsi Aktivasi (Epoch):

- ReLU: 81.25% (Epoch 15)
- Leaky ReLU: 100.00% (Epoch 15)
- Sigmoid: 90.00% (Epoch 15)
- Tanh: 100.00% (Epoch 15)

- Hasil Loss Terendah dari Fungsi Aktivasi (Epoch):

- ReLU: 43.30% (Epoch 15)
- Leaky ReLU: 14.35% (Epoch 15)
- Sigmoid: 44.51% (Epoch 15)
- Tanh: 1.09% (Epoch 14)

- Hasil Akurasi Rata-Rata dari Fungsi Aktivasi:

- ReLU: 67.50%
- Leaky ReLU: 81.25%
- Sigmoid: 67.50%
- Tanh: 88.75%

- Hasil Loss Rata-Rata dari Fungsi Aktivasi:
 - ReLU: 67.50%
 - Leaky ReLU: 48.75%
 - Sigmoid: 67.50%
 - Tanh: 20.33%
- 2. Hasil Uji Training Model ResNet50
 - Hasil Akurasi Terbaik dari Fungsi Aktivasi (Epoch):
 - ReLU: 77.50% (Epoch 15)
 - Leaky ReLU: 87.50% (Epoch 15)
 - Sigmoid: 68.75% (Epoch 15)
 - Tanh: 93.75% (Epoch 15)
 - Hasil Loss Terendah dari Fungsi Aktivasi (Epoch):
 - ReLU: 117.19% (Epoch 1)
 - Leaky ReLU: 34.97% (Epoch 15)
 - Sigmoid: 72.48% (Epoch 15)
 - Tanh: 17.08% (Epoch 15)
 - Hasil Akurasi Rata-Rata dari Fungsi Aktivasi:
 - ReLU: 67.50%
 - Leaky ReLU: 81.25%
 - Sigmoid: 67.50%
 - Tanh: 88.75%
 - Hasil Loss Rata-Rata dari Fungsi Aktivasi:
 - ReLU: 67.50%
 - Leaky ReLU: 48.75%
 - Sigmoid: 67.50%
 - Tanh: 20.33%
- ReLU: 44.50% (Epoch 13)
- Leaky ReLU: 50.63% (Epoch 4)
- Sigmoid: 44.51% (Epoch 15)
- Tanh: 20.87% (Epoch 1)
- Hasil Akurasi Rata-Rata dari Fungsi Aktivasi:
 - ReLU: 95.00%
 - Leaky ReLU: 95.00%
 - Sigmoid: 90.00%
 - Tanh: 100.00%
- Hasil Loss Rata-Rata dari Fungsi Aktivasi:
 - ReLU: 53.92%
 - Leaky ReLU: 24.02%
 - Sigmoid: 69.55%
 - Tanh: 1.45%
- 2. Hasil Uji Validasi Model ResNet50
 - Hasil Akurasi Terbaik dari Fungsi Aktivasi (Epoch):
 - ReLU: 50.00% (Epoch 1)
 - Leaky ReLU: 50.00% (Epoch 1)
 - Sigmoid: 50.00% (Epoch 1)
 - Tanh: 50.00% (Epoch 1)
 - Hasil Loss Terendah dari Fungsi Aktivasi (Epoch):
 - ReLU: 154.33% (Epoch 1)
 - Leaky ReLU: 97.60% (Epoch 1)
 - Sigmoid: 77.46% (Epoch 1)
 - Tanh: 84.49% (Epoch 1)
 - Hasil Akurasi Rata-Rata dari Fungsi Aktivasi:
 - ReLU: 50.00%
 - Leaky ReLU: 50.00%
 - Sigmoid: 50.00%
 - Tanh: 50.00%
 - Hasil Loss Rata-Rata dari Fungsi Aktivasi:
 - ReLU: 128.90%
 - Leaky ReLU: 99.41%
 - Sigmoid: 76.34%
 - Tanh: 73.10%

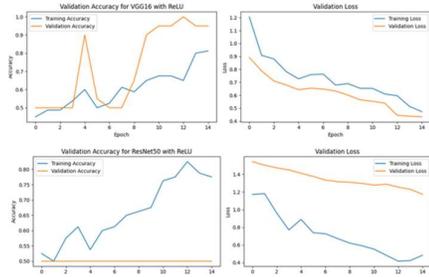
Hasil Uji Validasi

Hasil pengujian validasi kerugian menunjukkan bagaimana model bekerja pada data yang tidak digunakan selama pelatihan. Validasi loss digunakan untuk menilai kemampuan generalisasi model dan mengidentifikasi potensi overfitting atau underfitting.

1. Hasil Uji Validasi Model VGG16
 - Hasil Akurasi Terbaik dari Fungsi Aktivasi (Epoch):
 - ReLU: 100.00% (Epoch 13)
 - Leaky ReLU: 100.00% (Epoch 4)
 - Sigmoid: 90.00% (Epoch 15)
 - Tanh: 100.00% (Epoch 1)
 - Hasil Loss Terendah dari Fungsi Aktivasi (Epoch):

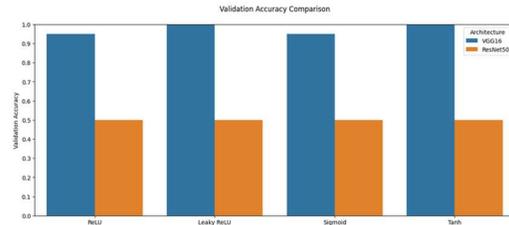
Grafik Perbandingan Validasi Akurasi

1. Fungsi Aktivasi Relu



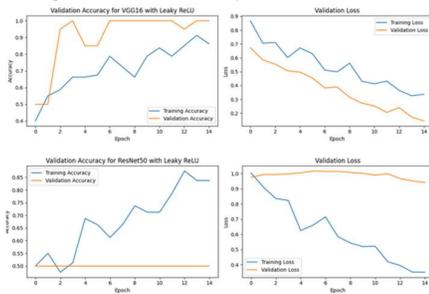
Gambar 2.1 Perbandingan Hasil Grafik Validasi Akurasi Fungsi Aktivasi Relu

Diagram Batang Perbandingan Validasi Akurasi



Gambar 3.1 Diagram Batang Perbandingan Hasil Validasi Akurasi

2. Fungsi Aktivasi Leaky Relu



Gambar 2.2 Perbandingan Hasil Grafik Validasi Akurasi Fungsi Aktivasi Leaky Relu

Tabel Data Perbandingan Uji Training Validasi

Model	Fungsi Aktivasi	Akurasi Training Terbaik (Epoch)	Loss Training Terendah (Epoch)	Akurasi Training Rata-Rata	Loss Training Rata-Rata	Akurasi Validasi Terbaik (Epoch)	Loss Validasi Terendah (Epoch)	Akurasi Validasi Rata-Rata	Loss Validasi Rata-Rata
VGG16	ReLU	81.25% (15)	47.32% (15)	47.50%	47.50%	100.00% (15)	44.50% (15)	93.00%	33.52%
VGG16	Leaky ReLU	91.25% (14)	14.35% (15)	77.50%	48.75%	100.00% (14)	50.65% (14)	92.00%	34.25%
VGG16	Sigmoid	72.50% (15)	52.18% (15)	57.50%	75.40%	90.00% (15)	44.55% (15)	90.00%	49.55%
VGG16	Tanh	91.25% (15)	20.33% (15)	77.50%	47.50%	100.00% (1)	30.87% (1)	100.00%	1.45%
ResNet50	ReLU	77.50% (15)	48.34% (15)	65.00%	75.40%	50.00% (1)	54.33% (1)	50.00%	128.90%
ResNet50	Leaky ReLU	87.50% (15)	34.97% (15)	67.50%	47.50%	50.00% (1)	97.60% (1)	50.00%	98.41%
ResNet50	Sigmoid	48.75% (15)	60.37% (15)	57.50%	75.40%	50.00% (1)	77.46% (1)	50.00%	76.54%
ResNet50	Tanh	93.75% (15)	17.08% (15)	77.50%	47.50%	50.00% (1)	84.40% (1)	50.00%	73.10%

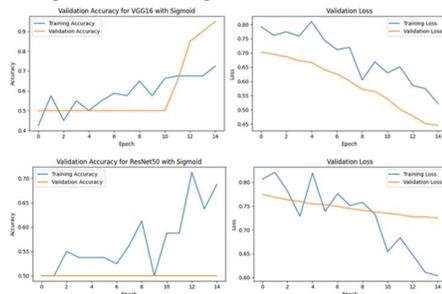
Gambar 4.1 Tabel Perbandingan Hasil Uji Training dan Hasil Uji Validasi

Hasil training dengan data latih 80% dan data validasi 20% menunjukkan perkembangan akurasi dan loss pada model VGG16 dan ResNet50 dengan berbagai fungsi aktivasi. VGG16 secara konsisten menunjukkan performa terbaik, terutama pada fungsi aktivasi Leaky ReLU dengan akurasi training tertinggi sebesar 91.25% (Epoch 14) dan loss training terendah 14.35% (Epoch 15) [10]. Fungsi Tanh juga unggul dengan akurasi validasi rata-rata mencapai 100.00% dan loss validasi rata-rata terendah sebesar 1.45%.

Pada fungsi ReLU, VGG16 mencapai akurasi training terbaik sebesar 81.25% (Epoch 15) dengan loss training terendah 47.32% (Epoch 15), serta akurasi validasi rata-rata yang tinggi, yaitu 95.00% [11]. Fungsi Sigmoid memberikan performa yang baik pada akurasi validasi sebesar 90.00% (Epoch 15), meskipun rata-rata loss training dan validasinya lebih tinggi dibandingkan fungsi aktivasi lainnya.

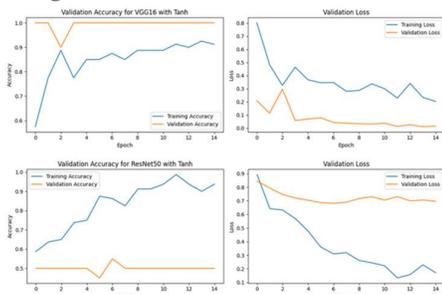
Sebaliknya, ResNet50 menunjukkan performa lebih rendah untuk semua fungsi aktivasi. Fungsi Tanh menghasilkan akurasi training terbaik sebesar 93.75% (Epoch 15), namun akurasi validasi rata-rata hanya mencapai 50.00%. Fungsi ReLU dan Leaky ReLU pada ResNet50 menghasilkan akurasi training terbaik masing-masing sebesar 77.50% dan 87.50% (keduanya pada Epoch 15), tetapi akurasi validasi rata-rata tetap stagnan di

3. Fungsi Aktivasi Sigmoid



Gambar 2.3 Perbandingan Hasil Grafik Validasi Akurasi Fungsi Aktivasi Sigmoid

4. Fungsi Aktivasi Tanh



Gambar 2.4 Perbandingan Hasil Grafik Validasi Akurasi Fungsi Aktivasi Tanh

50.00%, dengan loss validasi rata-rata yang relatif tinggi, seperti 128.90% untuk ReLU.

Fungsi Sigmoid juga menunjukkan hasil serupa, dengan akurasi training terbaik sebesar 68.75% (Epoch 15) dan loss validasi rata-rata sebesar 76.34%. Hasil uji training loss menunjukkan tingkat kesalahan model selama proses pelatihan, sementara validasi loss mencerminkan performa model pada data yang tidak terlihat selama pelatihan. Validasi loss yang konsisten atau lebih rendah dibanding training loss menandakan generalisasi yang baik.

Melalui hasil ini, VGG16 menunjukkan keunggulan signifikan dibandingkan ResNet50 untuk keempat fungsi aktivasi. Fungsi Leaky ReLU dan Tanh pada VGG16 memberikan hasil terbaik secara keseluruhan, diikuti oleh ReLU dan Sigmoid, yang tetap lebih unggul dibandingkan performa ResNet50 dengan data latih 80% dan data validasi 20% [12].

Confusion Matrix

Confusion matrix merupakan alat evaluasi kinerja model klasifikasi. Dengan confusion matrix, dapat dihitung metrik evaluasi seperti akurasi, presisi, recall dan F1-score [13]. Confusion matrix memberikan gambaran jelas tentang kinerja model, terutama dalam konteks ketidakseimbangan kelas.

Tabel Data Perbandingan Confusion Matriks

Model/Arskitektur	Fungsi Aktivasi	Jenis Charger	Hasil Akurasi (%)	Hasil Presisi (%)	Hasil Recall (%)	Hasil F1-Score (%)	Support (%)	Data Confusion Matriks
VGG16	ReLU	Hitam/Charger_Hitam	100.00	100.00	100.00	100.00	100.00	100 00 0 0
VGG16	ReLU	Putih/Charger_Putih	90.00	90.00	90.00	90.00	100.00	90 10 0 0
VGG16	Leaky ReLU	Hitam/Charger_Hitam	100.00	100.00	100.00	100.00	100.00	100 00 0 0
VGG16	Leaky ReLU	Putih/Charger_Putih	100.00	100.00	100.00	100.00	100.00	100 00 0 0
VGG16	Sigmoid	Hitam/Charger_Hitam	100.00	63.00	100.00	81.00	100.00	100 00 0 0
VGG16	Sigmoid	Putih/Charger_Putih	68.75	100.00	68.75	80.00	100.00	100 00 0 0
VGG16	Tanh	Hitam/Charger_Hitam	100.00	100.00	100.00	100.00	100.00	100 00 0 0
VGG16	Tanh	Putih/Charger_Putih	100.00	100.00	100.00	100.00	100.00	100 00 0 0
ResNet50	ReLU	Hitam/Charger_Hitam	0.00	0.00	0.00	0.00	100.00	0 100 0 0
ResNet50	ReLU	Putih/Charger_Putih	100.00	100.00	100.00	100.00	100.00	0 100 0 0
ResNet50	Leaky ReLU	Hitam/Charger_Hitam	0.00	0.00	0.00	0.00	100.00	0 100 0 0
ResNet50	Leaky ReLU	Putih/Charger_Putih	100.00	100.00	100.00	100.00	100.00	0 100 0 0
ResNet50	Sigmoid	Hitam/Charger_Hitam	0.00	0.00	0.00	0.00	100.00	0 100 0 0
ResNet50	Sigmoid	Putih/Charger_Putih	100.00	100.00	100.00	100.00	100.00	0 100 0 0
ResNet50	Tanh	Hitam/Charger_Hitam	0.00	0.00	0.00	0.00	100.00	0 100 0 0
ResNet50	Tanh	Putih/Charger_Putih	100.00	100.00	100.00	100.00	100.00	0 100 0 0

Gambar 5.1 Hasil Tabel Perbandingan Confusion Matriks Berdasarkan Jenis Charger

Dari hasil tabel diatas model VGG16 dengan fungsi aktivasi Leaky ReLU dan Tanh menunjukkan performa terbaik untuk kedua jenis charger (hitam dan putih), dengan nilai akurasi, presisi, recall, dan F1-score sempurna (100%). Fungsi aktivasi ReLU juga memberikan hasil baik pada charger hitam dengan akurasi 90% dan F1-score 95%, meskipun presisi sedikit lebih rendah dibandingkan Leaky ReLU.

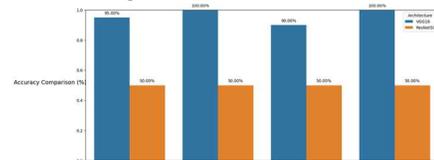
Fungsi Sigmoid pada VGG16 menunjukkan hasil yang baik pada charger hitam dengan akurasi

100% dan F1-score 91%, tetapi pada charger putih, akurasinya sedikit menurun menjadi 80%, dengan F1-score 89%. Sebaliknya, ResNet50 menunjukkan akurasi 100% untuk charger putih pada semua fungsi aktivasi, namun dengan presisi rendah (50%) dan F1-score rendah (67%), serta tidak efektif dalam mengenali charger hitam, dengan akurasi dan skor lainnya berada di 0%.

Secara keseluruhan, VGG16 dengan fungsi aktivasi Leaky ReLU dan Tanh unggul dalam mengenali kedua jenis charger, sementara ResNet50 memiliki keterbatasan dalam performa dan lebih baik di charger putih meskipun kurang optimal [14].

Diagram Batang Perbandingan Hasil Confusion Matriks

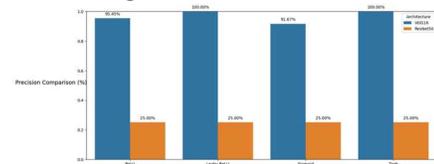
1. Perbandingan Hasil Akurasi



Gambar 6.1 Hasil Diagram Batang Perbandingan Hasil Akurasi

Dari perbandingan diagram batang hasil akurasi pada confusion matriks, VGG16 dengan fungsi aktivasi Leaky ReLU dan Tanh adalah yang terbaik karena memiliki nilai akurasi tertinggi sebesar 100%. Sebaliknya, ResNet50 menunjukkan nilai akurasi terendah sebesar 50% pada semua fungsi aktivasi (ReLU, Leaky ReLU, Sigmoid, dan Tanh), sehingga model ini kurang efektif dalam mengenali data.

2. Perbandingan Hasil Presisi

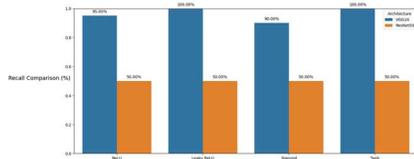


Gambar 6.2 Hasil Diagram Batang Perbandingan Hasil Presisi

Dari perbandingan diagram batang hasil presisi pada confusion matriks, VGG16 dengan fungsi aktivasi Leaky

ReLU dan Tanh kembali unggul dengan nilai presisi tertinggi sebesar 100%. Sebaliknya, ResNet50 memiliki nilai presisi terendah sebesar 25% pada semua fungsi aktivasi, menunjukkan model ini memiliki kemampuan prediksi yang sangat buruk dibandingkan VGG16.

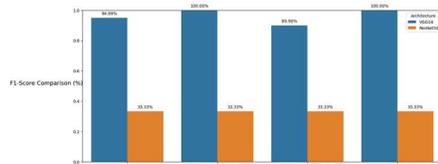
3. Perbandingan Hasil Recall



Gambar 6.3 Hasil Diagram Batang Perbandingan Hasil Recall

Dari perbandingan diagram batang hasil recall pada confusion matriks, VGG16 dengan fungsi aktivasi Leaky ReLU dan Tanh memiliki nilai recall tertinggi sebesar 100%, menunjukkan kemampuannya untuk mengenali seluruh data dengan benar. Sebaliknya, ResNet50 memiliki nilai recall terendah sebesar 50% pada semua fungsi aktivasi, yang menunjukkan kelemahan dalam mendeteksi data secara keseluruhan.

4. Perbandingan Hasil F1-Score



Gambar 6.4 Hasil Diagram Batang Perbandingan Hasil F1-Score

Dari perbandingan diagram batang hasil hasil F1-score pada confusion matriks, VGG16 dengan fungsi aktivasi Leaky ReLU dan Tanh memiliki nilai F1-score tertinggi sebesar 100%, menandakan keseimbangan sempurna antara presisi dan recall. Sebaliknya, ResNet50 memiliki nilai F1-score terendah sebesar 33.33% pada semua fungsi aktivasi, yang mempertegas kelemahan model ini dalam mengenali pola data.

Tabel Hasil Akhir Confusion Matriks

Index	Architecture	Activation	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
0	VGG16	ReLU	95.0	95.45	95.0	94.99
1	VGG16	Leaky ReLU	100.0	100.0	100.0	100.0
2	VGG16	Sigmoid	90.0	91.67	90.0	89.99
3	VGG16	Tanh	100.0	100.0	100.0	100.0
4	ResNet50	ReLU	50.0	25.0	50.0	33.33
5	ResNet50	Leaky ReLU	50.0	25.0	50.0	33.33
6	ResNet50	Sigmoid	50.0	25.0	50.0	33.33
7	ResNet50	Tanh	50.0	25.0	50.0	33.33

Gambar 7.1 Hasil Akhir Perbandingan Confusion Matriks

Hasil confusion matriks dengan data latih 80% dan data validasi 20% menunjukkan bahwa VGG16 dengan fungsi aktivasi Leaky ReLU dan Tanh memberikan performa terbaik, mencapai akurasi 100%, presisi 100%, recall 100%, dan F1-score 100% untuk kedua jenis charger (hitam dan putih), menandakan model ini sangat efektif dalam mengenali kedua jenis charger dengan hasil yang sempurna [15].

Fungsi aktivasi ReLU juga menunjukkan hasil yang sangat baik dengan akurasi 95%, presisi 95.45%, recall 95%, dan F1-score 94.99%. Namun, fungsi Sigmoid menunjukkan sedikit penurunan dengan akurasi 90%, presisi 91.67%, recall 90%, dan F1-score 89.90%.

Sebaliknya, ResNet50 menunjukkan performa yang sangat rendah pada semua fungsi aktivasi, dengan akurasi hanya 50%, presisi 25%, recall 50%, dan F1-score 33.33%, yang menunjukkan model ini kurang efektif dalam mengenali charger baik hitam maupun putih.

Secara keseluruhan, VGG16 dengan fungsi aktivasi Leaky ReLU dan Tanh unggul jauh dibandingkan dengan ResNet50, baik dalam akurasi, presisi, recall, maupun F1-score, meskipun menggunakan pembagian data latih 80% dan data validasi 20%.

Hasil Pengujian Model

Pengujian model VGG16 dan ResNet50 dengan data latih 80% dan validasi 20% menunjukkan perbedaan signifikan dalam akurasi, loss, dan metrik confusion matriks. VGG16 unggul dalam berbagai konfigurasi fungsi aktivasi, termasuk ReLU, Leaky ReLU, Sigmoid, dan Tanh.

VGG16 mencapai akurasi validasi tertinggi 100% dengan fungsi Leaky ReLU dan Tanh, sedangkan ResNet50 stagnan pada 50%. VGG16 juga menunjukkan nilai akurasi, presisi, recall, dan F1-score sempurna (100%) pada fungsi aktivasi Leaky ReLU dan Tanh.

VGG16 memiliki keunggulan stabilitas konvergensi dan keunggulan pada dataset kecil, tetapi dengan beban komputasi yang lebih berat. ResNet50 memiliki kemampuan training baik,

tetapi performa validasi rendah dan stagnan, serta rentan terhadap underfitting pada dataset kecil (He et al., 2016).

KESIMPULAN

Penelitian ini menggunakan dataset kepala charger dengan pengolahan gambar ukuran 224x224 piksel, batch size 32, dan 15 epoch. Dua puluh persen data digunakan untuk validasi dan delapan puluh persen untuk pelatihan. Hasilnya menunjukkan bahwa model VGG16 secara konsisten dan signifikan mengungguli ResNet50

VGG16 mencapai akurasi validasi 100% dengan fungsi aktivasi Leaky ReLU dan Tanh, serta menunjukkan kemampuan generalisasi yang sangat baik. Confusion matrix menunjukkan akurasi, presisi, recall, dan F1-score yang sempurna (100%) untuk mengenali kedua jenis charger (hitam dan putih).

Sebaliknya, ResNet50 mengalami kesulitan mengenali pola data, terutama charger hitam (0% akurasi). Meskipun lebih efisien komputasional, ResNet50 menunjukkan akurasi validasi stagnan (50%) dan presisi rendah, membuatnya kurang cocok untuk klasifikasi dalam penelitian ini.

DAFTAR PUSTAKA

- [1] T. Berliani, E. Rahardja, and L. Septiana, "Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16," *Journal of Medicine and Health*, vol. 5, no. 2, pp. 123–135, Aug. 2023, doi: 10.28932/jmh.v5i2.6116.
- [2] M. K. Insani and D. B. Santoso, "Perbandingan Kinerja Model Pre-Trained CNN (VGG16, RESNET, dan INCEPTIONV3) untuk Aplikasi Pengenalan Wajah pada Sistem Absensi Karyawan," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, vol. 5, no. 3, pp. 2612–2622, Sep. 2024, doi: 10.35870/jimik.v5i3.925.
- [3] J. Ayad, "Survey on Neural Networks in Networking: Applications and Advancements," *Babylonian Journal of Networking*, vol. 2024, pp. 135–147, Aug. 2024, doi: 10.58496/BJN/2024/014.
- [4] A. Agung Mujiono, K. Kartini, and E. Yulia Puspaningrum, "IMPLEMENTASI MODEL HYBRID CNN-SVM PADA KLASIFIKASI KONDISI KESEGERAN DAGING AYAM," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 756–763, Mar. 2024, doi: 10.36040/jati.v8i1.8855.
- [5] Fauzan Muhammad, Aniati Murni Arimurthy, and Dina Chahyati, "Transfer learning pada Network VGG16 dan ResNet50," *The Indonesian Journal of Computer Science*, vol. 12, no. 1, Feb. 2023, doi: 10.33022/ijcs.v12i1.3130.
- [6] S. Yuliany, Aradea, and Andi Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Buana Informatika*, vol. 13, no. 1, pp. 54–65, Apr. 2022, doi: 10.24002/jbi.v13i1.5022.
- [7] Qorry Aina Fitroh and Shofwatul 'Uyun, "Deep Transfer Learning untuk Meningkatkan Akurasi Klasifikasi pada Citra Dermoskopi Kanker Kulit," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 12, no. 2, pp. 78–84, May 2023, doi: 10.22146/jnteti.v12i2.6502.
- [8] N. Wiliani, A. P. V. D. Lusi, and N. Hikmah, "Identifying Skin Cancer Disease Types With You Only Look Once (YOLO) Algorithm," *Jurnal Riset Informatika*, vol. 5, no. 3, pp. 455–464, Jun. 2023, doi: 10.34288/jri.v5i3.241.
- [9] Mawadatul Maulidah, "KLASIFIKASI KEPERIBADIAN MENGGUNAKAN ALGORITMA MACHINE LEARNING," *Jurnal Informatika Dan Tekonologi Komputer (JITEK)*, vol. 3, no. 1, pp. 66–73, Apr. 2023, doi: 10.55606/jitek.v3i1.1292.
- [10] K. W. Goh et al., "Comparison of Activation Functions in Convolutional Neural Network for Poisson Noisy Image Classification," *Emerging Science Journal*, vol. 8, no. 2, pp. 592–602, Apr. 2024, doi: 10.28991/ESJ-2024-08-02-014.
- [11] A. A. Handoko, M. A. Rosid, and U. Indahyanti, "Implementasi Convolutional Neural Network (CNN) Untuk Pengenalan Tulisan Tangan Aksara Bima," *SMATIKA JURNAL*, vol. 14, no. 01, pp. 96–110, Jul. 2024, doi: 10.32664/smatika.v14i01.1196.
- [12] I. Firmansyah and B. H. Hayadi, "Komparasi Fungsi Aktivasi Relu Dan Tanh Pada Multilayer Perceptron," *JIKO (Jurnal Informatika dan Komputer)*, vol. 6,

- no. 2, p. 200, Sep. 2022, doi:
10.26798/jiko.v6i2.600.
- [13] S. NOR, M. A. MUSLIM, and M. ASWIN,
“Pengenalan Pola Dasar Angka
berdasarkan Gerakan Tangan
menggunakan Machine Learning,”
*ELKOMIKA: Jurnal Teknik Energi
Elektrik, Teknik Telekomunikasi, & Teknik
Elektronika*, vol. 10, no. 3, p. 595, Jul.
2022, doi: 10.26760/elkomika.v10i3.595.
- [14] B. Budiman, N. Alamsyah, and R. Y. R.
Alamsyah, “ACTIVATION FUNCTION
IN LSTM FOR IMPROVED
FORECASTING OF CLOSING
NATURAL GAS STOCK PRICES,” *JITK
(Jurnal Ilmu Pengetahuan dan Teknologi
Komputer)*, vol. 10, no. 1, pp. 100–107,
Aug. 2024, doi: 10.33480/jitk.v10i1.5258.
- [15] R. Rikendry and A. Maharil,
“PERBANDINGAN ARSITEKTUR
VGG16 DAN RESNET50 UNTUK
REKOGNISI TULISAN TANGAN
AKSARA LAMPUNG,” *Jurnal
Informatika dan Rekayasa Perangkat
Lunak*, vol. 3, no. 2, pp. 236–243, Oct.
2022, doi: 10.33365/jatika.v3i2.2030.