

Analisa Performa Arsitektur Transfer Learning Untuk Mengidentifikasi Penyakit Daun Pada Tanaman Pangan

Tawang Sahro Winanto^{1*}, Chaerur Rozikin^{2*}, Asep Jamaludin^{3*}

* Teknik Informatika, Universitas Singaperbangsa Karawang

1910631170141@student.unsika.ac.id¹, chaerur.rozikin@staff.unsika.ac.id², asep.jamaludin@staff.unsika.ac.id³

Article Info

Article history:

Received 2023-07-26

Revised 2023-07-30

Accepted 2023-07-31

Keyword:

Transfer Learning,
CNN,
Deep Learning,
Image Classification,
Tanaman Pangan.

ABSTRACT

Salah satu faktor gagal panen ialah serangan penyakit yang menyerang pada bagian daun pada tanaman. Solusi dari permasalahan ini yaitu dengan melakukan identifikasi dini penyakit tanaman dengan memanfaatkan *image classification* dan *deep learning* menggunakan objek citra daun untuk mempercepat proses identifikasi penyakit pada daun tanaman pangan sehingga tidak mempengaruhi hasil produksi tanaman. Banyak penelitian yang sudah membuat penelitian memanfaatkan *Image classification* untuk klasifikasi penyakit tanaman berdasarkan citra daun menggunakan metode *Transfer Learning*. Namun pada penelitian terdahulu hanya menggunakan satu dua atau tiga arsitektur dan hanya menggunakan satu dataset saja untuk proses pengujian yang membuat tidak terlalu memberikan jawaban arsitektur mana yang mempunyai performa terbaik untuk membuat model klasifikasi penyakit berdasarkan citra daun tanaman. Oleh karena itu diperlukan adanya perbandingan performa dari tiap model arsitektur untuk mengetahui arsitektur mana yang terbaik. Maka dari itu penelitian ini, peneliti akan melakukan eksperimen menggunakan lima arsitektur dan tiga dataset yang berbeda dengan enam skenario pelatihan model dan selanjutnya kami melakukan analisis perbandingan kinerja tiap skenario pelatihan model. Hasilnya Penelitian ini dilakukan analisa hasil pelatihan dan pengujian yang sudah dilakukan arsitektur VGG 16 memiliki performa yang paling baik dibandingkan dengan arsitektur lainnya yang diujikan.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Tanaman pangan merupakan makanan pokok sebagian besar penduduk Indonesia. Walaupun Indonesia dikenal sebagai dengan julukan negara agraris namun faktanya Indonesia masih belum bisa memenuhi kebutuhan tanaman pangan dalam negeri dan masih mengandalkan impor hasil tanaman pangan untuk memenuhi kebutuhan dalam negeri.

Menurut data dari Badan Pusat Statistik (BPS) tahun 2020 Indonesia masih mengimpor hasil tanaman pangan sebanyak 20.228.713 ton yang terdiri dari beberapa jenis tanaman pangan, 3 diantaranya tanaman pangan yang memiliki nilai impor paling besar yaitu gandum 10.522.991 ton, kedelai 7.531.884 ton dan jagung 1.242.519 ton [1]. Faktor penyebab tingginya impor gandum, kedelai dan jagung disebabkan oleh gagal panen. Faktor gagal panen tersebut umumnya karena

serangan penyakit yang menyerang pada bagian daun pada tanaman. Serangan patogen yang menyerang pada daun dapat mengakibatkan terganggunya proses fotosintesis tanaman [2]. Berdampak langsung pada hasil produksi pada tanaman. Oleh karena itu penulis mempunyai solusi dari permasalahan tersebut yaitu dengan melakukan identifikasi dini penyakit tanaman pangan dengan memanfaatkan *image classification* dan *deep learning* dengan objek yang di gunakan pada proses ini adalah gambar daun dari tanaman pangan untuk menentukan proses identifikasi penyakit yang menyerang pada tanaman.

Salah satu penelitian yang memanfaatkan *Deep learning* untuk mengidentifikasi penyakit tanaman berfokus pada klasifikasi penyakit pada tanaman kentang dengan menggunakan citra daun tanaman kentang dan menerapkan metode *deep learning* serta arsitektur *transfer learning* [3].

Arsitektur yang di gunakan pada penelitian ini yaitu Inception-V3, ResNet-50 dan VGG-16, hasil yang di dapatkan pada penelitian ini model yang menggunakan arsitektur VGG-16 mendapatkan hasil terbaik dengan nilai akurasi sebesar 95%.

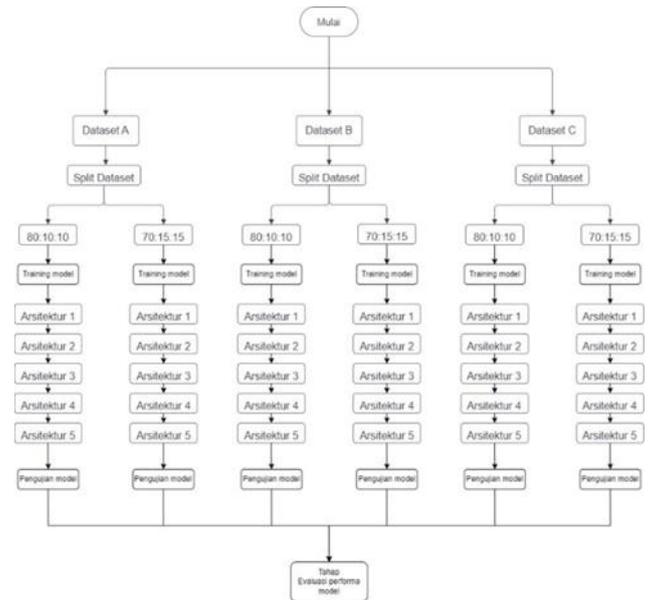
Penelitian lainnya menggunakan metode *Deep learning* dan *transfer learning* yaitu arsitektur EfficientNetB0 untuk mengidentifikasi penyakit pada tanaman jagung dengan memanfaatkan citra daun jagung, hasil yang di dapat pada penelitian ini peneliti mendapatkan model dengan nilai akurasi sebesar 96% [4].

Berdasarkan dari penelitian diatas, pendekatan deep learning dengan menggunakan transfer learning dapat digunakan dalam melakukan deteksi penyakit tanaman menggunakan citra daun. Namun pada penelitian sebelumnya diatas hanya mengujikan satu dua atau tiga arsitektur saja dan hanya menggunakan satu model dataset saja yang diujikan untuk membuat model klasifikasi penyakit pada tanaman yang membuat tidak terlalu memberikan jawaban arsitektur mana yang mempunyai performa terbaik untuk membuat model klasifikasi penyakit jenis tanaman pangan. Hal ini dikarenakan model yang menggunakan metode Transfer Learning memberikan hasil akurasi yang pasti tinggi. Selain itu juga penelitian sebelumnya tidak memberikan analisa dari hasil pelatihan dan pengujian model secara mendalam terkait perbedaan hasil pelatihan dan pengujian tiap sekenario pelatihan yang di ujikan.

Oleh karena itu, penelitin kami akan melakukan komparasi arsitektur pada deep learning yaitu menggunakan Inception V3, MobileNetV2, VGG16, ResNet50V2 dan NASNetMobile. Dengan melakukan perbandingan arsitektur deep learning ini, diharapkan peneliti dapat mendapatkan model deteksi penyakit tanaman pangan dengan performa terbaik dan dapat memberikan wawasan tentang performa dari masing masing arsitektur untuk deteksi penyakit pada tanaman berdasarkan citra daun.

II. METODE PENELITIAN

Penelitian perbandingan arsitektur Transfer Learning ini diawali dengan melakukan pengumpulan data. Ada tiga dataset yang digunakan. Tiap dataset akan diinput dan melewati tahap preprocessing dan tahap augmentasi. Kemudian data akan dilatih dengan menambahkan berbagai arsitektur Transfer Learning secara terpisah. Arsitektur Transfer Learning yang diuji adalah Inception V3, MobileNetV2, VGG 16, ResNet50V2 dan NasNetMobile. Tiap model dievaluasi dengan melihat training loss, training accuracy, validation loss, validation accuracy, dan confusion matrix. Setelah itu, proses yang sama akan dilakukan pada dataset kedua dan dataset ketiga. Hasil evaluasi seluruh model pada tiga dataset akan dibandingkan dan dianalisis. Hasil dari penelitian ini adalah penemuan arsitektur Transfer Learning terbaik. Gambar 1 menunjukan metode yang diusulkan pada penelitian ini.



Gambar 1. Ilustrasi Pelatihan Model dan Pengujian Model

Tujuan utama dari penelitian ini adalah membandingkan kinerja berbagai arsitektur transfer learning untuk mendapatkan model *Deep learning* dengan performa terbaik untuk mendeteksi penyakit tanaman pangan berdasarkan citra daun. Untuk mencapai hal ini, tiga dataset dari tiga jenis tanaman pangan telah dipilih untuk tiga eksperimen terpisah. Semua dataset yang digunakan tersedia secara publik di Kaggle, yang menjamin aksesibilitas dan reproduktibilitas penelitian ini.

Dataset yang spesifik dipilih berdasarkan tanaman dengan jumlah impor paling tinggi di Indonesia yaitu tanaman gandum, kedelai dan jagung berikut Rincian dari masing-masing dataset adalah sebagai berikut.

Dataset pertama yaitu dataset tanaman gandum dalam dataset ini terdiri dari 289 gambar daun tanaman gandum yang terkena penyakit yang terdiri dari 3 kelas yaitu Brown Rust, Powdery Mildew dan Healthy. Contoh gambar pada dataset ini ditunjukkan pada Gambar 2.



Gambar 2. Contoh Gambar Dataset Gandum

Dataset kedua yaitu dataset tanaman kedelai dalam dataset ini terdiri dari 303 gambar daun tanaman gandum yang terkena penyakit yang terdiri dari 5 kelas yaitu kelas Bacterial Blight, Powdery Mildew, Mosaik, Rust dan Healthy. Contoh gambar pada dataset ini ditunjukkan pada Gambar 3.



Gambar 3. Contoh Gambar Dataset Kedelai

Dataset ketiga yaitu dataset tanaman jagung dalam dataset ini terdiri dari 4188 gambar daun tanaman gandum yang terkena penyakit yang terdiri dari 4 kelas yaitu kelas Common Rust, Blight, Gray Leaf Spot, Healthy. Contoh gambar pada dataset ini ditunjukkan pada Gambar 4.



Gambar 4. Contoh Gambar Dataset Jagung

A. Data Preprocessing

Data preprocessing merupakan langkah untuk mempersiapkan data gambar yang akan digunakan sebelum masuk ke dalam proses klasifikasi citra. Pada penelitian ini, tahap preprocessing yang dilakukan yaitu mengubah ukuran data gambar pada tiap dataset menjadi 224x224, kemudian tiap dataset dilakukan augmentasi data. Teknik augmentasi gambar yang digunakan pada penelitian ini yaitu rescale dengan nilai sebesar 1/255, rotation range dengan nilai sebesar 5, horizontal flip dengan nilai True, zoom range dengan nilai sebesar 0.1, width shift range dengan nilai sebesar 0.1, height shift range dengan nilai sebesar 0.1, brightness range dengan nilai 0.2 dan 1.5 dan fill mode dengan mode nearest.

TABLE 1
ILUSTRASI PEMBAGIAN DATASET

Skenario	Dataset	Perbandingan pembagian dataset
Model A1	Gandum	80:10:10
Model A2		70:15:15
Model B1	Kedelai	80:10:10
Model B2		70:15:15
Model C1	Jagung	80:10:10
Model C2		70:15:15

Setiap dataset dibagi menjadi dua skema pembagian yaitu 80:10:10 dan 70:15:15. Rincian dari pembagian dataset untuk setiap dataset dapat dilihat pada Tabel 1.

B. Convolutional Neural Network

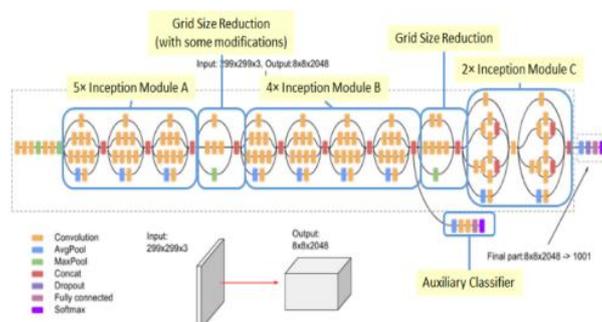
CNN adalah salah satu algoritma Deep Learning yang sangat populer. CNN merupakan pengembangan metode dari Multilayer Perceptron (MLP) dengan jumlah dimensi yang lebih besar daripada MLP. CNN dirancang khusus untuk melakukan klasifikasi langsung pada media 2D seperti gambar, video, teks, dan suara. Cara kerja CNN terinspirasi oleh cara kerja otak manusia. Arsitektur CNN terdiri dari lapisan ekstraksi fitur (convolutional layer dan pooling layer) serta lapisan terhubung penuh (fully connected layer) yang bekerja secara hierarkis, sehingga output dari lapisan pertama dapat digunakan sebagai input pada lapisan berikutnya [5].

C. Transfer Learning

Transfer learning merupakan proses dimana menggunakan Kembali model pre-trained yang sudah pernah di latih, biasanya metode ini digunakan pada saat ingin membuat model klasifikasi namun hanya mempunyai dataset yang terbatas. Transfer learning merupakan metode yang bertujuan untuk mengurangi ukuran data pelatihan, waktu pelatihan, dan biaya komputasi pada saat melakukan implementasi model deep learning. Metode transfer learning dapat digunakan untuk mengurangi sumber daya komputasi pada algoritma CNN [6]. Penerapan metode ini telah banyak digunakan dalam berbagai aplikasi, seperti aplikasi untuk klasifikasi tanaman, memprediksi cacat pada perangkat lunak, pengenalan jenis aktivitas, dan klasifikasi sentiment [7].

D. InceptionV3

Inception, awalnya diperkenalkan oleh Szegedy dkk. pada tahun 2014 dalam sebuah jurnal berjudul "Going Deeper with Convolutions". Inception merupakan arsitektur yang umum digunakan untuk membuat model pengenalan gambar karena terbukti bisa mendapatkan akurasi sebesar 78,1% menggunakan dataset ImageNet [8]. arsitektur ini memecah konvolusi dengan mengganti filter yang ada dengan filter 1-D. Fitur utama dari arsitektur ini adalah menggabungkan beberapa filter konvolusi dengan ukuran yang berbeda menjadi satu filter. Hal ini mengurangi kompleksitas komputasi karena jumlah parameter yang harus dilatih menjadi lebih sedikit [9]. Arsitektur Inception V3 ditunjukkan pada Gambar 5.



Gambar 5. Struktur Arsitektur Inception V3

batch size yang sama. Kami mengamati kinerja masing-masing arsitektur transfer learning untuk tiga dataset yang berbeda. Selanjutnya, kami membandingkan hasil akurasi, precision, recall, dan f1-score dari semua model pada seluruh dataset untuk menyimpulkan arsitektur transfer learning terbaik pada tiga dataset eksperimen yang dilakukan.

III. HASIL DAN PEMBAHASAN

Setelah melakukan pelatihan model dan pengujian model pada tahap sebelumnya dan memperoleh data pelatihan dan

pengujian dari setiap skenario maka pada tahap ini data yang sudah didapatkan di lakukan visualisasi data dan dilakukan analisa untuk menentukan arsitektur mana yang memiliki performa terbaik untuk klasifikasi data.

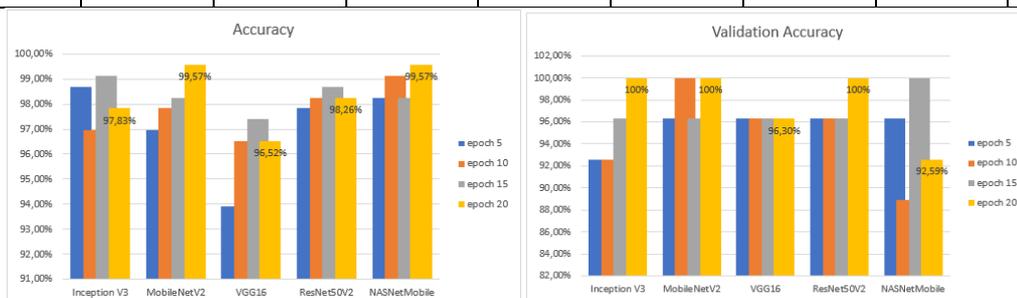
A. Analisa Hasil Pelatihan

Berikut data hasil proses pelatihan dari setiap skenario sebagai berikut :

1. Hasil Pelatihan Skenario A1

TABLE 2
AKURASI DAN VAL AKURASI MODEL A1

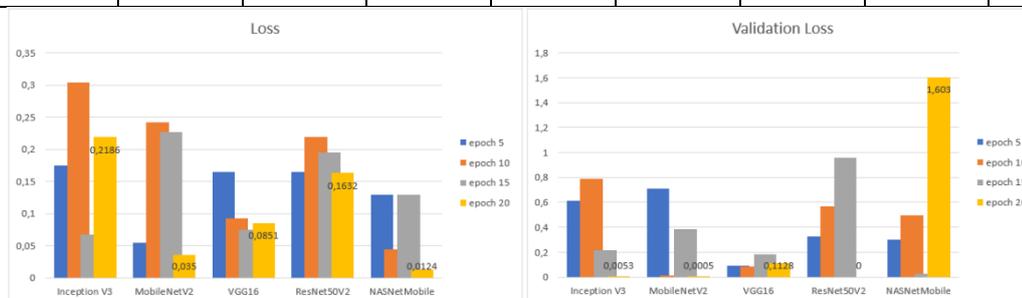
Model	Accuracy				Validation Accuracy			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	98,70%	96,96%	99,13%	97,83%	92,59%	92,59%	96,30%	100%
MobileNetV2	96,96%	97,83%	98,26%	99,57%	96,30%	100%	96,30%	100%
VGG16	93,91%	96,52%	97,39%	96,52%	96,30%	96,30%	96,30%	96,30%
ResNet50V2	97,83%	98,26%	98,70%	98,26%	96,30%	96,30%	96,30%	100%
NASNetMobile	98,26%	99,13%	98,26%	99,57%	96,30%	88,89%	100%	92,59%



Gambar 10. Diagram Akurasi Dan Val Akurasi Model A1

TABLE 3
LOSS DAN VAL LOSS MODEL A1

Model	Loss				Validation loss			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	0,1752	0,3039	0,0666	0,2186	0,6130	0,7879	0,2167	0,0053
MobileNetV2	0,0539	0,2417	0,2269	0,0350	0,7089	0,0149	0,3879	0,0005
VGG16	0,1648	0,0924	0,0751	0,0851	0,0901	0,0855	0,1834	0,1128
ResNet50V2	0,1649	0,2188	0,1952	0,1632	0,3266	0,5692	0,9605	0,0000
NASNetMobile	0,1291	0,0448	0,1287	0,0124	0,2991	0,4938	0,0243	1,6030



Gambar 11. Diagram Loss Dan Val Loss Model A1

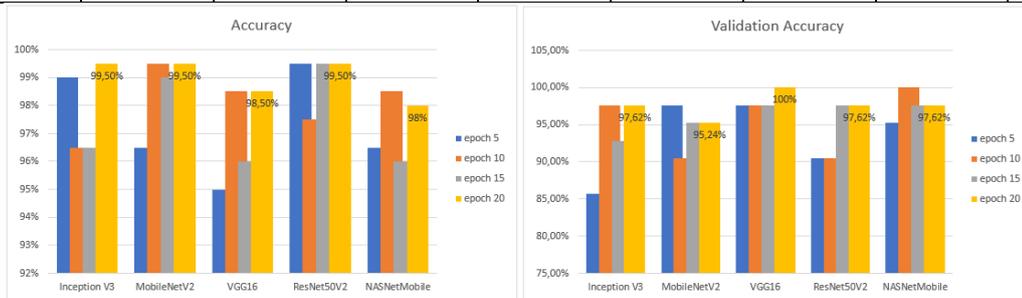
Berdasarkan data pelatihan sekenario model A1 dapat dilihat dari data di atas kelima arsitektur mendapatkan hasil akurasi dan validasi akurasi mendapatkan performa yang sangat baik semua arsitektur mendapatkan nilai diatas 90% dan nilai akurasi dan validasi akurasi yang tidak terlalu jauh beda. Namun untuk nilai pelatihan loss dan validasi loss arsitektur InceptionV3, MobileNetV2, ResNet50V2 dan NasNetMobile mengalami overfitting dapat dilihat dari nilai

loss dan validasi loss memiliki perbedaan yang cukup jauh. Oleh karena itu model yang memiliki performa terbaik pada sekenario pelatihan A1 didapatkan arsitektur VGG 16 walaupun arsitektur VGG 16 tidak mendapatkan hasil terbaik di akurasi dan validasi akurasi namun mendapatkan hasil terbaik di loss dan validasi loss dan tidak mengalami overfitting

2. Hasil Pelatihan Skenario A2

TABLE 4
 AKURASI DAN VAL AKURASI MODEL A2

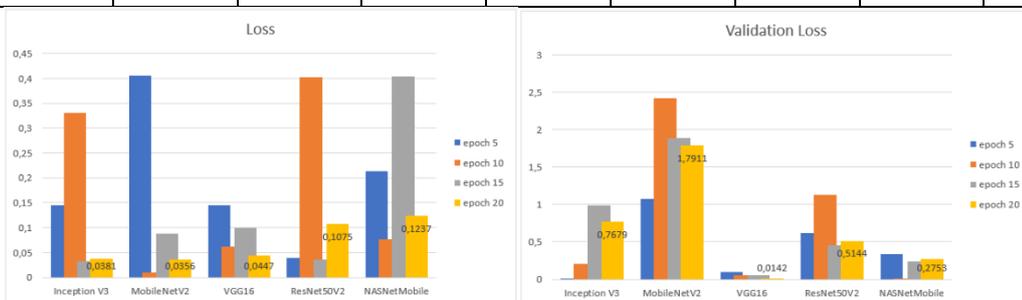
Model	Accuracy				Validation Accuracy			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	99%	96,50%	96,50%	99,50%	85,71%	97,62%	92,86%	97,62%
MobileNetV2	96,50%	99,50%	99%	99,50%	97,62%	90,48%	95,24%	95,24%
VGG16	95%	98,50%	96%	98,50%	97,62%	97,62%	97,62%	100%
ResNet50V2	99,50%	97,50%	99,50%	99,50%	90,48%	90,48%	97,62%	97,62%
NASNetMobile	96,50%	98,50%	96%	98%	95,24%	100%	97,62%	97,62%



Gambar 12. Diagram Akurasi Dan Val Akurasi Model A2

TABLE 5
 LOSS DAN VAL LOSS MODEL A2

Model	loss				Validation loss			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	0,1446	0,3313	0,0329	0,0381	0,0122	0,2105	0,9880	0,7679
MobileNetV2	0,4062	0,0106	0,0882	0,0356	1,0730	2,4156	1,8909	1,7911
VGG16	0,1455	0,0619	0,0992	0,0447	0,1035	0,0577	0,0514	0,0142
ResNet50V2	0,0394	0,4016	0,0361	0,1075	0,6162	1,1294	0,4581	0,5144
NASNetMobile	0,2131	0,0766	0,4042	0,1237	0,3409	0,0001	0,2438	0,2753



Gambar 13. Diagram Loss Dan Val Loss Model A2

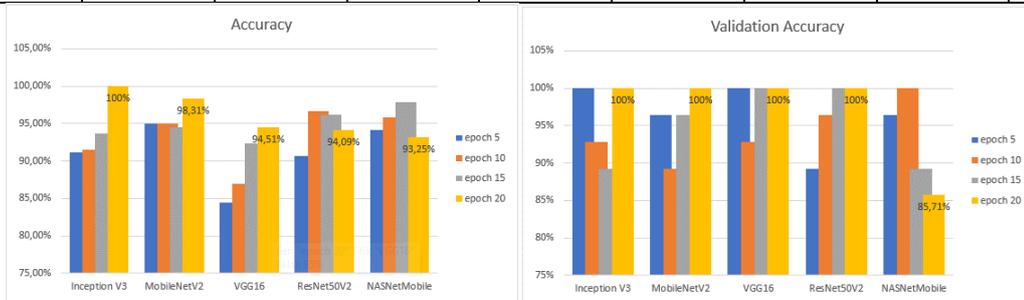
Berdasarkan data pelatihan sekenario model A2 dapat dilihat dari data di atas kelima arsitektur mendapatkan hasil akurasi dan validasi akurasi mendapatkan performa yang sangat baik semua arsitektur mendapatkan nilai diatas 90% dan nilai akurasi dan validasi akurasi yang tidak terlalu jauh beda. Namun untuk nilai pelatihan loss dan validasi loss arsitektur InceptionV3, MobileNetV2, ResNet50V2 dan NasNetMobile mengalami overfitting dapat dilihat dari nilai

loss dan validasi loss memiliki perbedaan yang cukup jauh. Oleh karena itu model yang memiliki performa terbaik pada sekenario pelatihan A2 didapatkan arsitektur VGG 16 dikarenakan pada sekenario A2 nilai akurasi dan validasi akurasi didapatkan arsitektur VGG 16 dan nilai loss dan validasi loss arsitektur mendapatkan nilai yang sangat baik dan tidak mengalami overfitting seperti ke empat arsitektur lainnya.

3. Hasil Pelatihan Skenario B1

TABLE 6
AKURASI DAN VAL AKURASI MODEL B1

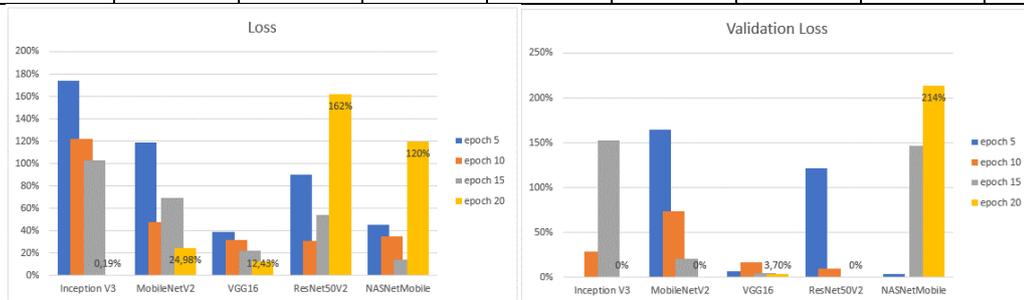
Model	Accuracy				Validation Accuracy			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	91,14%	91,56%	93,67%	100%	100%	92,86%	89,29%	100%
MobileNetV2	94,94%	94,94%	94,51%	98,31%	96,43%	89,29%	96,43%	100%
VGG16	84,39%	86,92%	92,41%	94,51%	100%	92,86%	100%	100%
ResNet50V2	90,72%	96,62%	96,20%	94,09%	89,29%	96,43%	100%	100%
NASNetMobile	94,09%	95,78%	97,89%	93,25%	96,43%	100%	89,29%	85,71%



Gambar 14. Diagram Akurasi Dan Val Akurasi Model B1

TABLE 7
LOSS DAN VAL LOSS MODEL B1

Model	loss				Validation loss			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	1,7407	1,2249	1,0301	0,0019	0,0001	0,2836	1,5336	0,0000
MobileNetV2	1,1989	0,4778	0,6950	0,2498	1,6581	0,7336	0,2083	0,0000
VGG16	0,3867	0,3183	0,2222	0,1243	0,0652	0,1653	0,0441	0,0370
ResNet50V2	0,9046	0,3125	0,5408	1,6275	1,2294	0,0942	0,0003	0,0000
NASNetMobile	0,4540	0,3530	0,1385	1,2043	0,0367	0,0001	1,4739	2,1441



Gambar 15. Diagram Loss Dan Val Loss Model B1

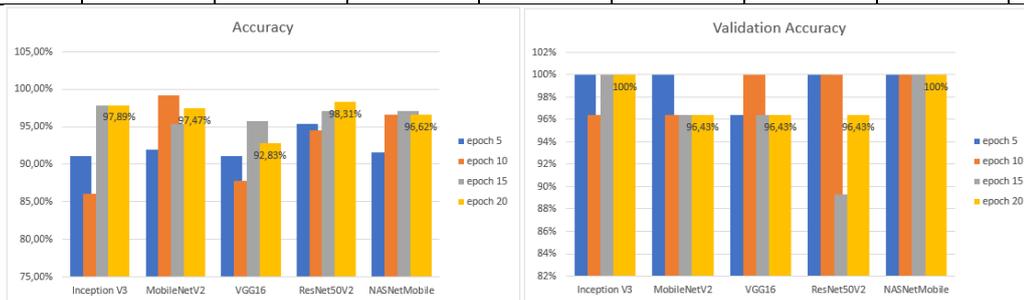
Berdasarkan data pelatihan sekenario model B1 dapat dilihat dari data di atas kelima arsitektur mendapatkan hasil akurasi dan validasi akurasi mendapatkan performa yang sangat baik semua arsitektur mendapatkan nilai diatas 90% untuk nilai akurasi dan validasi akurasi dan nilai akurasi dan validasi akurasi tidak terlalu jauh beda. Namun untuk nilai pelatihan loss dan validasi loss arsitektur InceptionV3, MobileNetV2, ResNet50V2 dan NasNetMobile mengalami overfitting dapat dilihat dari nilai loss dan validasi loss

memiliki perbedaan yang cukup jauh. Oleh karena itu model yang memiliki performa terbaik pada sekenario pelatihan B1 didapatkan arsitektur VGG 16 dikarenakan pada sekenario B1 arsitektur VGG 16 memiliki performa akurasi dan validasi akurasi yang sangat baik dan pada nilai loss dan validasi loss arsitektur VGG 16 tidak mengalami perbedaan nilai terlalu tinggi antara nilai loss dan validasi loss dan memiliki nilai loss yang cukup rendah pada setiap epoch nya.

4. Hasil Pelatihan Skenario B2

TABLE 8
 AKURASI DAN VAL AKURASI MODEL B2

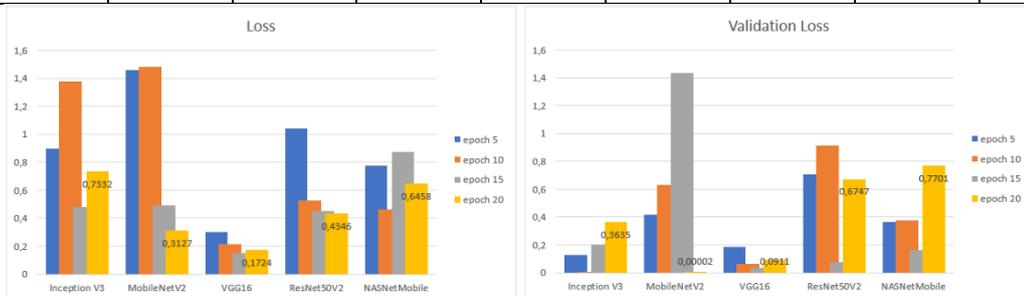
Model	Accuracy				Validation Accuracy			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	91,75%	93,20%	94,17%	96,60%	97,67%	86,05%	93,02%	93,02%
MobileNetV2	92,23%	94,17%	96,60%	98,06%	95,35%	95,53%	95,35%	100%
VGG16	86,89%	92,72%	93,69%	92,72%	93,02%	97,67%	100%	95,35%
ResNet50V2	92,72%	96,12%	97,09%	97,57%	93,02%	97,67%	97,67%	97,67%
NASNetMobile	91,75%	95,63%	94,17%	94,17%	95,35%	95,35%	95,35%	95,35%



Gambar 16. Diagram Akurasi Dan Val Akurasi Model B2

TABLE 9
 LOSS DAN VAL LOSS MODEL B2

Model	loss				Validation loss			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	0,8983	1,3765	0,4815	0,7332	0,1293	0,0003	0,2003	0,3635
MobileNetV2	1,4576	1,4799	0,4903	0,3127	0,4178	0,6298	1,4351	0,00002
VGG16	0,3015	0,2116	0,1503	0,1724	0,1844	0,0659	0,0343	0,0911
ResNet50V2	1,040	0,5248	0,4538	0,4346	0,7065	0,9168	0,0744	0,6747
NASNetMobile	0,7737	0,4655	0,8769	0,6458	0,3651	0,3756	0,1631	0,7701



Gambar 17. Diagram Loss Dan Val Loss Model B2

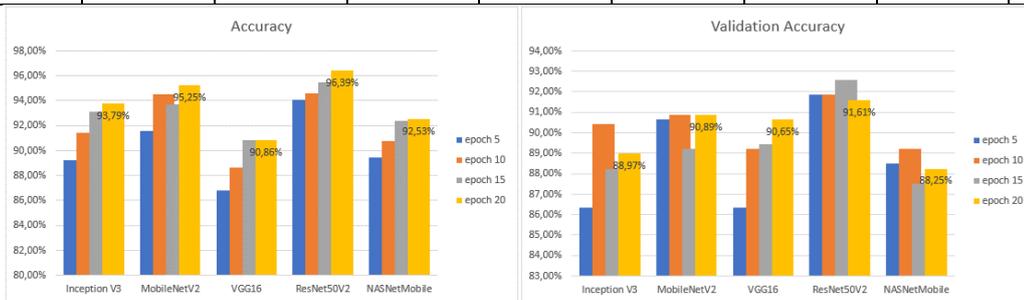
Berdasarkan data pelatihan sekenario model B2 dapat dilihat dari data di atas kelima arsitektur mendapatkan hasil akurasi dan validasi akurasi mendapatkan performa yang sangat baik semua arsitektur mendapatkan nilai diatas 90% dan nilai akurasi dan validasi akurasi yang tidak terlalu jauh beda. Namun untuk nilai pelatihan loss dan validasi loss arsitektur InceptionV3, MobileNetV2, ResNet50V2 dan NasNetMobile mengalami overfitting dapat dilihat dari nilai

loss dan validasi loss memiliki perbedaan yang cukup jauh. Oleh karena itu model yang memiliki performa terbaik pada sekenario pelatihan B2 didapatkan arsitektur VGG 16 dikarenakan pada sekenario B2 arsitektur VGG 16 mendapatkan performa akurasi dan validasi akurasi yang cukup baik walaupun tidak terbaik namun pada pada nilai loss dan validasi loss akurasi VGG 16 mendapatkan nilai yang paling rendah dibandingkan arsitektur lainnya.

5. Hasil Pelatihan Skenario C1

TABLE 10
AKURASI DAN VAL AKURASI MODEL C1

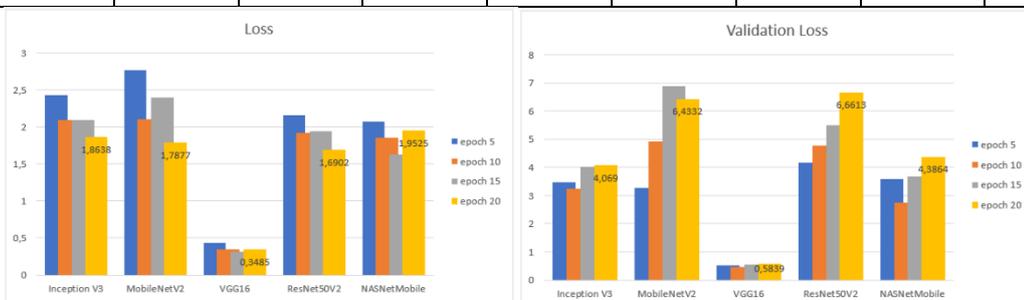
Model	Accuracy				Validation Accuracy			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	89,25%	91,43%	93,10%	93,79%	86,33%	90,41%	88,25%	88,97%
MobileNetV2	91,58%	94,50%	93,73%	95,25%	90,65%	90,89%	89,21%	90,89%
VGG16	86,77%	88,62%	90,86%	90,86%	86,33%	89,21%	89,45%	90,65%
ResNet50V2	94,03%	94,56%	95,49%	96,39%	91,85%	91,85%	92,57%	91,61%
NASNetMobile	89,46%	90,74%	92,35%	92,53%	88,49%	89,21%	87,53%	88,25%



Gambar 18. Diagram Akurasi Dan Val Akurasi Model C1

TABLE 11
LOSS DAN VAL LOSS MODEL C1

Model	loss				Validation loss			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	2,4297	2,0934	2,0934	1,8638	3,4670	3,2296	4,0291	4,0690
MobileNetV2	2,7706	2,1066	2,4026	1,7877	3,2716	4,9120	6,8803	6,4332
VGG16	0,4383	0,3451	0,3192	0,3485	0,5372	0,4610	0,5480	0,5839
ResNet50V2	2,1615	1,9181	1,9438	1,6902	4,1778	4,7881	5,4990	6,6613
NASNetMobile	2,0786	1,8541	1,6275	1,9525	3,5798	2,7413	3,6733	4,3864



Gambar 19. Diagram Loss Dan Val Loss Model C1

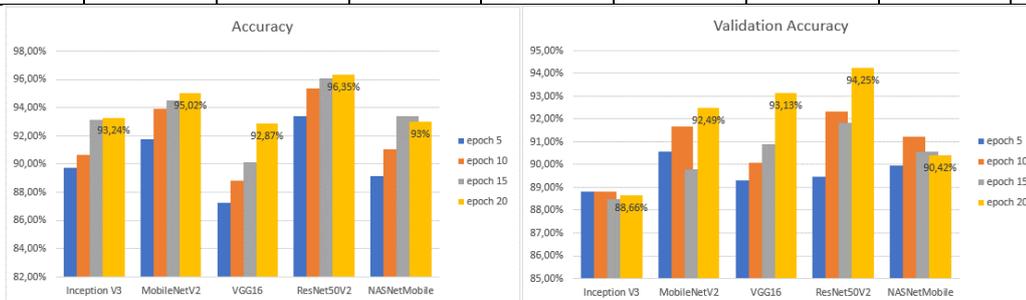
Berdasarkan data pelatihan sekenario model C1 dapat dilihat dari data di atas kelima arsitektur mendapatkan hasil akurasi dan validasi akurasi mendapatkan performa yang sangat baik semua arsitektur mendapatkan nilai diatas 90% dan nilai akurasi dan validasi akurasi yang tidak terlalu jauh beda. Namun untuk nilai pelatihan loss dan validasi loss arsitektur InceptionV3, MobileNetV2, ResNet50V2 dan NasNetMobile mengalami overfitting dapat dilihat dari nilai

loss dan validasi loss memiliki perbedaan yang cukup jauh. Oleh karena itu model yang memiliki performa terbaik pada sekenario pelatihan C1 didapatkan arsitektur VGG 16 dikarenakan pada sekenario C1 arsitektur VGG 16 mendapatkan performa akurasi dan validasi akurasi yang cukup baik walaupun tidak terbaik namun pada pada nilai loss dan validasi loss akurasi VGG 16 mendapatkan nilai yang paling rendah dibandingkan arsitektur lainnya.

6. Hasil Pelatihan Skenario C2

TABLE 12
AKURASI DAN VAL AKURASI MODEL C2

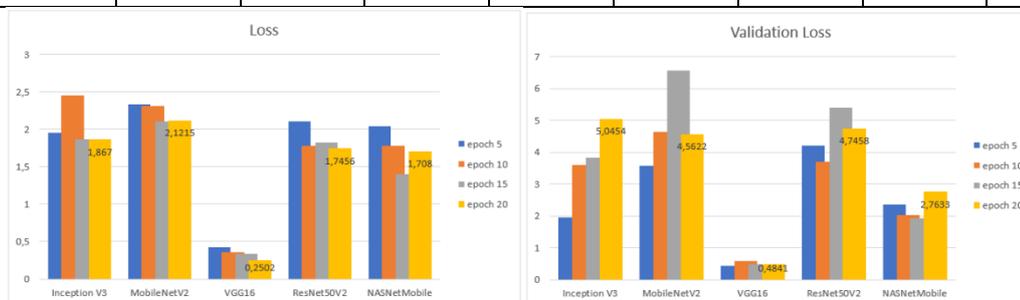
Model	Accuracy				Validation Accuracy			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	89,73%	90,68%	93,11%	93,24%	88,82%	88,82%	88,50%	88,66%
MobileNetV2	91,74%	93,89%	94,47%	95,02%	90,58%	91,69%	89,78%	92,49%
VGG16	87,27%	88,84%	90,10%	92,87%	89,30%	90,10%	90,89%	93,13%
ResNet50V2	93,38%	95,36%	96,08%	96,35%	89,46%	92,33%	91,85%	94,25%
NASNetMobile	89,15%	91,06%	93,41%	93%	89,94%	91,21%	90,58%	90,42%



Gambar 20. Diagram Akurasi Dan Val Akurasi Model C2

TABLE 13
LOSS DAN VAL LOSS MODEL C2

Model	loss				Validation loss			
	Epoch				Epoch			
	5	10	15	20	5	10	15	20
Inception V3	1,9582	2,4507	1,8700	1,8670	1,9526	3,6049	3,8340	5,0454
MobileNetV2	2,335	2,3091	2,1057	2,1215	3,5791	4,6319	6,5621	4,5622
VGG16	0,4189	0,3542	0,3371	0,2502	0,4246	0,5753	0,4933	0,4841
ResNet50V2	2,1052	1,7805	1,8245	1,7456	4,2080	3,7057	5,4001	4,7458
NASNetMobile	2,0384	1,7835	1,4046	1,7080	2,3507	2,0350	1,9216	2,7633



Gambar 21. Diagram Loss Dan Val Loss Model C2

Berdasarkan data pelatihan sekenario model C2 dapat dilihat dari data di atas kelima arsitektur mendapatkan hasil akurasi dan validasi akurasi mendapatkan performa yang sangat baik semua arsitektur mendapatkan nilai diatas 90% dan nilai akurasi dan validasi akurasi yang tidak terlalu jauh beda. Namun untuk nilai pelatihan loss dan validasi loss arsitektur InceptionV3, MobileNetV2, ResNet50V2 dan NasNetMobile mengalami overfitting dapat dilihat dari nilai loss dan validasi loss memiliki perbedaan yang cukup jauh. Oleh karena itu model yang memiliki performa terbaik pada sekenario pelatihan C2 didapatkan arsitektur VGG 16 dikarenakan pada sekenario C2 arsitektur VGG 16

mendapatkan performa akurasi dan validasi akurasi yang cukup baik walaupun tidak terbaik namun pada pada nilai loss dan validasi loss akurasi VGG 16 mendapatkan nilai yang paling rendah dibandingkan arsitektur lainnya.

B. Analisa Hasil Pengujian

Pengujian model pada penelitian menggunakan confusion matrix. Berikut data hasil proses pengujian model dari setiap sekenario sebagai berikut :

TABLE 14
PRECISION

Precision	Skenario A1	Skenario A2	Skenario B1	Skenario B2	Skenario C1	Skenario C2
Inception V3	96,97%	91,74%	100%	98%	86,93%	87,98%
MobileNetV2	94,87%	93,33%	97,50%	96%	90,43%	90,90%
VGG16	94,19%	92,36%	95%	98,57%	92,82%	89,08%
ResNet50V2	100%	100%	95%	98%	93,06%	92,32%
NASNetMobile	90,74%	100%	98%	94,70%	88,35%	89,74%

Penjelasan Tabel Precision sebagai berikut :

- Pada skenario A1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur NasNetMobile dengan nilai 90,74%.
- Pada skenario A2 nilai tertinggi didapatkan arsitektur ResNet50 dan NasNetMobile dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 91,74%.
- Pada skenario B1 nilai tertinggi didapatkan arsitektur InceptionV3 dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur VGG16 dan ResNet50V2 dengan nilai 95%.
- Pada skenario B2 nilai tertinggi didapatkan arsitektur VGG 16 dengan nilai 98.57% dan untuk nilai terendah didapatkan arsitektur NasNetMobile dengan nilai 94,70%.
- Pada skenario C1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 93,06% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 86,93%.
- Pada skenario C2 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 92,32% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 87,98%.

TABLE 15
TABLE RECALL

Recall	Skenario A1	Skenario A2	Skenario B1	Skenario B2	Skenario C1	Skenario C2
Inception V3	96,97%	91,53%	100%	95%	86,08%	84,20%
MobileNetV2	99,33%	91,39%	96,67%	98,46%	89,98%	90,89%
VGG16	93,64%	91,53%	95,56%	97,78%	87,98%	87,78%
ResNet50V2	100%	100%	96,67%	98,46%	91,89%	89,40%
NASNetMobile	90,32%	100%	96,67%	95,10%	88,07%	88,69%

Penjelasan Tabel Recall sebagai berikut :

- Pada skenario A1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 100% dan untuk nilai

terendah didapatkan arsitektur NasNetMobile dengan nilai 90,32%.

- Pada skenario A2 nilai tertinggi didapatkan arsitektur ResNet50 dan NasNetMobile dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur MobileNetV2 dengan nilai 91,39%.
- Pada skenario B1 nilai tertinggi didapatkan arsitektur InceptionV3 dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur VGG16 dengan nilai 95,56%.
- Pada skenario B2 nilai tertinggi didapatkan arsitektur MobileNetV2 dan ResNet50V2 dengan nilai 98,46%

dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 95%.

- Pada skenario C1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 93,06% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 86,08%.
- Pada skenario C2 nilai tertinggi didapatkan arsitektur MobileNetV2 dengan nilai 90,89% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 84,20%.

TABLE 16
F1-SCORE

F1-Score	Skenario A1	Skenario A2	Skenario B1	Skenario B2	Skenario C1	Skenario C2
Inception V3	96,83%	91,39%	100%	96,09%	86,35%	85,34%
MobileNetV2	93,52%	91,69%	96,85%	96,98%	90,19%	90,89%
VGG16	93,77%	91,55%	94,64%	98,08%	89,29%	88,33%
ResNet50V2	100%	100%	95,32%	98,15%	92,41%	90,35%
NASNetMobile	90,39%	100%	97,13%	94,65%	87,87%	89,12%

Penjelasan Tabel F1-score sebagai berikut :

- Pada skenario A1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur NasNetMobile dengan nilai 90,39%.
- Pada skenario A2 nilai tertinggi didapatkan arsitektur ResNet50 dan NasNetMobile dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 91,39%.
- Pada skenario B1 nilai tertinggi didapatkan arsitektur InceptionV3 dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur VGG16 dengan nilai 94,64%.
- Pada skenario B2 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 98,15% dan untuk nilai terendah didapatkan arsitektur NasNetMobile dengan nilai 94,65%
- Pada skenario C1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 92,41% dan untuk nilai terendah didapatkan arsitektur NasNetMobile dengan nilai 86,35%.
- Pada skenario C2 nilai tertinggi didapatkan arsitektur MobileNetV2 dengan nilai 90,89% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 85,34%.

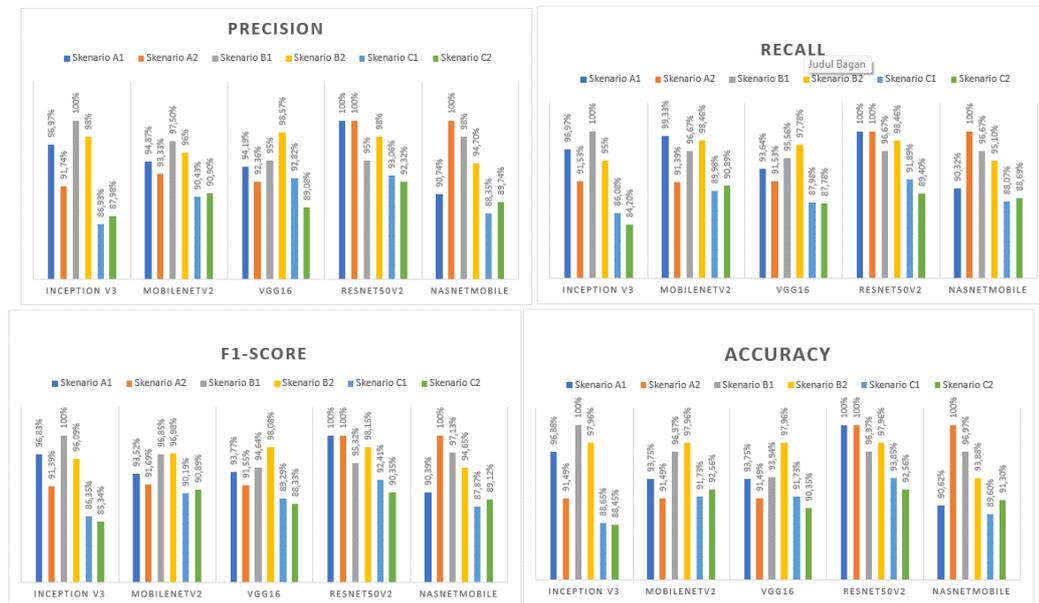
TABLE 17
ACCURACY

Accuracy	Skenario A1	Skenario A2	Skenario B1	Skenario B2	Skenario C1	Skenario C2
Inception V3	96,88%	91,49%	100%	97,96%	88,65%	88,45%
MobileNetV2	93,75%	91,49%	96,97%	97,96%	91,73%	92,56%
VGG16	93,75%	91,49%	93,94%	97,96%	91,73%	90,35%
ResNet50V2	100%	100%	96,97%	97,96%	93,85%	92,56%
NASNetMobile	90,62%	100%	96,97%	93,88%	89,60%	91,30%

Penjelasan Tabel Accuracy sebagai berikut :

- Pada skenario A1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur NasNetMobile dengan nilai 90,62%.
- Pada skenario A2 nilai tertinggi didapatkan arsitektur ResNet50 dan NasNetMobile dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur InceptionV3, MobileNetV2 dan VGG 16 dengan nilai 91,49%.
- Pada skenario B1 nilai tertinggi didapatkan arsitektur InceptionV3 dengan nilai 100% dan untuk nilai terendah didapatkan arsitektur VGG16 dan dengan nilai 93,94%.
- Pada skenario B2 nilai tertinggi didapatkan arsitektur InceptionV3, MobileNetV2, VGG16 dan ResNet50V2 dengan nilai 97,96% dan untuk nilai terendah didapatkan arsitektur NasNetMobile dengan nilai 93,88%.

- Pada skenario C1 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 93,85% dan untuk nilai terendah didapatkan arsitektur 88,65%.
- Pada skenario C2 nilai tertinggi didapatkan arsitektur ResNet50V2 dengan nilai 92,56% dan untuk nilai terendah didapatkan arsitektur InceptionV3 dengan nilai 88,45%.



Gambar 22. Diagram Nilai Precision, Recall, F1-score dan Accuracy

Berdasarkan analisa hasil pengujian model 6 sekenario diatas terdapat 2 model yang memiliki performa cukup baik yaitu MobileNetV2 berdasarkan data di atas arsitektur tersebut memiliki performa precision, recall, f1-score dan accuracy terbaik dan di ikuti arsitektur VGG16 yang juga memiliki performa precision, recall, f1-score dan accuracy cukup baik tidak terlalu besar perbedaan kedua performa arsitektur tersebut sedangkan pada arsitektur ResNet50V2 walaupun mendapatkan nilai terbaik di beberapa sekenario namun arsitektur ResNet50V2 teridentifikasi mengalami overfitting pada sekenario A1 dan A2 dimana pada sekenario tersebut arsitektur ResNet50V2 mendapatkan nilai 100% disemua pengujian precision, recall, f1-score dan akurasi.

IV. KESIMPULAN

Penelitian ini bertujuan untuk memberikan perbandingan kinerja performa dari masing masing arsitektur yang diujikan untuk mengklasifikasi penyakit tanaman berdasarkan citra daun. Penelitian sebelumnya yang membuat model klasifikasi penyakit tanaman berdasarkan citra daun hanya menggunakan satu dua atau tiga arsitektur dan satu jenis dataset tanaman saja untuk perbandingan performa arsitektur untuk klasifikasi penyakit tanaman. kemudian pada penelitian ini kami melakukan eksperimen menggunakan lima arsitektur dan tiga dataset tanaman yang berbeda. Lalu kami membandingkan hasil kinerja dari masing masing arsitektur pada setiap sekenario pengujian secara

menyeluruh. Hasilnya berdasarkan hasil analisa data pelatihan dan pengujian model dari keseluruhan model yang sudah dilakukan dapat dilihat arsitektur VGG 16 memiliki performa terbaik dikarenakan dari 6 kali sekenario pelatihan dan pengujian model arsitektur VGG 16 memiliki performa yang cukup stabil dan tidak pernah mengalami overfitting dan underfitting dari 6 kali sekenario yang dijalankan dan pada hasil analisa hasil pengujian model VGG 16 mendapatkan performa yang cukup stabil walaupun tidak mendapatkan hasil yang terbaik tetapi model VGG 16 tidak mengalami overfitting dari 6 sekenario pengujian.

DAFTAR PUSTAKA

- [1] R. Darmawan, M. Eng., M. S. Dr. Ir. A. A. Susanti, and S. M. M. A. Supriyatna, "STATISTIK PERTANIAN," Jakarta, Nov. 2021. Accessed: Mar. 14, 2023. [Online]. Available: <http://repository.pertanian.go.id/handle/123456789/16127>
- [2] A. Walascha, A. Febriana, D. Saputri, D. Sri Nur Haryanti, R. Tsania, and Y. Sanjaya, "Prosiding SEMNAS BIO 2021 Review Artikel: Inventarisasi Jenis Penyakit yang Menyerang Daun Tanaman Padi (*Oryza sativa* L.)," *Prosiding Seminar Nasional Biologi*, 2021.
- [3] Abdul Jalil Rozaqi, M. R. Arief, and A. Sunyoto, "Implementation of Transfer Learning in the Convolutional Neural Network Algorithm for Identification of Potato Leaf Disease," *Procedia of Engineering and Life Science*, vol. 1, no. 1, Apr. 2021, doi: 10.21070/pels.v1i1.820.
- [4] F. Sarasati, F. Septia Nugraha, U. Radiyah, and U. N. Mandiri, "Pemanfaatan Metode Deep Learning untuk Klasifikasi Penyakit pada Tanaman Jagung," *Jurnal Infortech*, vol. 4, no. 2, p. 6, 2022, [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/infortech>

- [5] Y. Altuntaş, Z. Cömert, and A. F. Kocamaz, "Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach," *Comput Electron Agric*, vol. 163, p. 104874, Aug. 2019, doi: 10.1016/j.compag.2019.104874.
- [6] L. D. Nguyen, D. Lin, Z. Lin, and J. Cao, "Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation," in *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*, IEEE, 2018, pp. 1–5. doi: 10.1109/ISCAS.2018.8351550.
- [7] G. G. and A. P. J., "Identification of plant leaf diseases using a nine-layer deep convolutional neural network," *Computers & Electrical Engineering*, vol. 76, pp. 323–338, Jun. 2019, doi: 10.1016/j.compeleceng.2019.04.011.
- [8] A. Demir, F. Yilmaz, and O. Kose, "Early detection of skin cancer using deep learning architectures: resnet-101 and inception-v3," in *2019 Medical Technologies Congress (TIPTEKNO)*, IEEE, Oct. 2019, pp. 1–4. doi: 10.1109/TIPTEKNO47231.2019.8972045.
- [9] P. Dandwate, C. Shahane, V. Jagtap, and S. C. Karande, "Comparative study of Transformer and LSTM Network with attention mechanism on Image Captioning," Mar. 2023, [Online]. Available: <http://arxiv.org/abs/2303.02648>
- [10] S. Saha, T. Chakraborty, R. Bin Sulaiman, and T. Paul, "A Comparative Analysis of CNN-Based Pretrained Models for the Detection and Prediction of Monkeypox," 2023.
- [11] M. Manoj krishna, M. Neelima, M. Harshali, and M. Venu Gopala Rao, "Image classification using Deep learning," *International Journal of Engineering & Technology*, vol. 7, no. 2.7, p. 614, Mar. 2018, doi: 10.14419/ijet.v7i2.7.10892.
- [12] S. Tammina, "Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images," *International Journal of Scientific and Research Publications (IJSRP)*, vol. 9, no. 10, p. p9420, Oct. 2019, doi: 10.29322/IJSRP.9.10.2019.p9420.
- [13] M. Harahap, Em Manuel Laia, Lilis Suryani Sitanggang, Melda Sinaga, Daniel Franci Sihombing, and Amir Mahmud Husein, "Deteksi Penyakit Covid-19 Pada Citra X-Ray Dengan Pendekatan Convolutional Neural Network (CNN)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 70–77, Feb. 2022, doi: 10.29207/resti.v6i1.3373.
- [14] S. K. Addagarla, "Real Time Multi-Scale Facial Mask Detection and Classification Using Deep Transfer Learning Techniques," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 4, pp. 4402–4408, Aug. 2020, doi: 10.30534/ijatcse/2020/33942020.