



Classification of Density and Transparency Scales of Needle Leaf Types with VGG16

Klasifikasi Skala Kerapatan dan Transparansi Tajuk Jenis Daun Jarum dengan VGG16

Flaurensia Riahta Tarigan¹, Rico Andrian², Rahmat Safe'i^{3*}

^{1,2} Program Studi Ilmu Komputer, Jurusan Ilmu Komputer,
Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, Indonesia
³Program Magister Kehutanan, Jurusan Kehutanan, Fakultas Pertanian, Universitas Lampung, Indonesia

E-Mail: ¹ flaurensiariahta@gmail.com, ² rico.andrian@fmipa.unila.ac.id,
³ rahmat.safei@fp.unila.ac.id

Received Aug 12th 2023; Revised Oct 02nd 2023; Accepted Oct 26th 2023
Corresponding Author: Rahmat Safe'i

Abstract

*This article discusses the use of deep learning, specifically the VGG16 Convolutional Neural Network (CNN) architecture, to classify the canopy density and transparency level in coniferous trees. This study collected images of four types of coniferous trees: *araucaria heterophylla*, *pinus merkusii*, *cupressus retusa*, and *shorea javanica*, each with ten different levels of density and transparency. Each class has 1000 images that have been labeled. The preprocessing process involves resizing, and image augmentation. Data is divided into training data (70%), validation data (10%), and testing data (20%). The deep learning model used is VGG16 with predetermined hyperparameters. The model training results show that VGG16 succeeded in classifying coniferous trees with good accuracy. Accuracy results reached 90.00% for *pinus merkusii*, 92.00% for *araucaria heterophylla*, 96.00% for *cupressus retusa*, and 99.00% for *shorea javanica*. The evaluation results include precision, recall, and F1-score for each density and transparency class. Prediction errors mainly occur in classes with high visual similarity between images. This research proves that deep learning technology can be used to classify the canopy density and transparency level in coniferous trees. The results can be used in forest health monitoring, helping governments and related organizations in sustainable forest management.*

Keyword: CNN, density, needleleaf, transparency, VGG16

Abstrak

Artikel ini membahas penggunaan *deep learning*, khususnya arsitektur *Convolutional Neural Network* (CNN) VGG16, untuk mengklasifikasikan tingkat kerapatan dan transparansi tajuk pada pohon jenis daun jarum. Penelitian ini mengumpulkan gambar dari empat jenis pohon daun jarum: *araucaria heterophylla*, *pinus merkusii*, *cupressus retusa*, dan *shorea javanica*, masing-masing dengan sepuluh tingkat kerapatan dan transparansi yang berbeda. Setiap jenis memiliki 1000 gambar yang telah di-label. Proses *preprocessing* melibatkan perubahan ukuran, dan augmentasi gambar. Data dibagi menjadi data *training* (70%), data *validation* (10%), dan data *testing* (20%). Model *deep learning* yang digunakan adalah VGG16 dengan *hyperparameter* yang telah ditentukan. Hasil pelatihan model menunjukkan bahwa VGG16 berhasil mengklasifikasikan pohon daun jarum dengan tingkat akurasi yang baik. Hasil akurasi mencapai 90.00% untuk *pinus merkusii*, 92.00% untuk *araucaria heterophylla*, 96.00% untuk *cupressus retusa*, dan bahkan 99.00% untuk *shorea javanica*. Hasil evaluasi juga mencakup *precision*, *recall*, dan *F1-score* untuk setiap kelas kerapatan dan transparansi. Kesalahan prediksi terutama terjadi pada kelas dengan tingkat kesamaan visual yang tinggi antar gambar. Penelitian ini membuktikan bahwa teknologi *deep learning* dapat digunakan untuk mengklasifikasikan tingkat kerapatan dan transparansi tajuk pada pohon daun jarum. Hasilnya dapat digunakan dalam pemantauan kesehatan hutan, membantu pemerintah dan organisasi terkait dalam pengelolaan hutan yang berkelanjutan.

Kata Kunci: CNN, Daun Jarum, Kerapatan, Transparansi, VGG16

1. PENDAHULUAN

Hutan adalah wilayah yang terdiri dari berbagai jenis pohon dan dikelola oleh satu entitas atau organisasi dengan tujuan sesuai dengan pemilik lahan [1]. Hutan di Indonesia terbagi menjadi dua kategori, yaitu hutan sehat dan hutan tidak sehat. Keadaan kesehatan hutan tercermin melalui kemampuan ekosistem hutan untuk memenuhi kebutuhan makhluk hidup di dalamnya. Hutan dianggap sehat ketika fungsi-fungsinya tetap terjaga dan berlangsung dengan baik [2]. Kesehatan hutan dapat dipantau dengan menggunakan metode *Forest Health Monitoring* (FHM). Parameter yang dipakai dalam FHM diantaranya adalah kerapatan tajuk (*density*), rasio tajuk hidup (*Live Crown Ratio*), diameter tajuk (*crown diameter*), transparansi tajuk (*transparency*), dan mati pucuk (*die back*) [3]. Kerapatan dan transparansi tajuk adalah parameter penting dalam menilai kesehatan hutan, di mana hutan dianggap sehat jika kerapatan tajuknya mencapai atau melebihi 55% dan tingkat transparansi berkisar antara 0 hingga 45%. Pengukuran kerapatan dan transparansi tajuk menggunakan kartu skala dimanfaatkan untuk mengukur persentase cahaya matahari yang dapat masuk ke dalam dan tertahan oleh tajuk pohon [4]. Biasanya, parameter ini dievaluasi secara manual oleh pengamat yang berada di bawah pohon yang sedang di survei. Penilaian yang dilakukan oleh pengamat untuk mengukur persentase kerapatan dan transparansi tajuk adalah seragam untuk semua jenis pohon, termasuk pohon jenis daun jarum. Pohon jenis daun jarum memiliki bentuk tumbuh yang cenderung kerucut ke atas, sehingga cenderung menahan lebih banyak cahaya matahari yang masuk ke dalam daerah tajuk pohon tersebut [5]. Implementasi dengan menggunakan kartu skala saat ini masih cenderung kurang efektif karena mengandalkan pengamatan visual dan membandingkannya dengan kartu skala secara manual. Masalah ini dapat diatasi dengan mengadopsi teknologi komputasi, salah satunya adalah menggunakan teknologi citra digital.

Teknologi citra digital yang terus berkembang memainkan peran penting dalam memudahkan penentuan skala kerapatan dan transparansi tajuk pohon. Tujuan utama dari penggunaan klasifikasi citra adalah untuk meningkatkan kemampuan manusia dalam memahami dan menganalisis informasi dari citra digital. [6]. Salah satu pendekatan yang sangat cocok untuk menentukan kerapatan dan transparansi tajuk pohon adalah dengan menggunakan metode *deep learning*, yang menggunakan arsitektur *Convolutional Neural Network* (CNN). CNN merupakan jenis jaringan saraf tiruan yang terinspirasi oleh cara pengolahan visual pada objek [7]. Arsitektur CNN memungkinkan banyak lapisan untuk menyimpan dan memproses ciri-ciri objek dalam gambar dengan efisiensi yang tinggi [8]. CNN telah menjadi salah satu model *deep learning* yang paling umum digunakan dalam klasifikasi gambar, deteksi kesamaan, dan pengenalan objek [9]. Arsitektur CNN yang populer adalah *Visual Geometric Group* (VGG16). VGG16 terdiri dari 13 lapisan konvolusi dan 3 lapisan *fully connected* dengan bobot, serta mampu mengolah gambar dengan tiga saluran warna RGB (*Red, Green, and Blue*) [10]. Penelitian terdahulu terkait penggunaan arsitektur VGG16 dipakai untuk mengklasifikasikan bunga menggunakan metode VGG16. Klasifikasi bunga dengan arsitektur VGG16 memperoleh akurasi sebesar 95% pada proses *training* dan 91% pada proses *testing*. Penelitian ini mengambil *dataset* dari *kaggle* yang terdiri dari 4323 data untuk lima kelas. *Dataset* dibagi dengan 70% data *training*, 20% data *testing* dan 10% data *validation* [11]. Sedangkan penelitian terdahulu terkait penggunaan kartu skala tersebut digunakan untuk menentukan kondisi kesehatan hutan di blok koleksi tumbuhan dan satwa Taman Hutan Raya Wan Abdul Rachman Provinsi Lampung [5].

Penelitian ini melibatkan pelatihan arsitektur VGG16 dikarenakan model ini mampu melakukan klasifikasi hingga 14 juta citra dengan 100 kelas yang berbeda [12]. Dengan *dataset* yang berbeda, penelitian ini bertujuan untuk melakukan klasifikasi terhadap tingkat kerapatan dan transparansi tajuk daun jarum berdasarkan kartu skala sebanyak empat jenis pohon yang berbeda. Setiap jenis pohon memiliki 1000 gambar, dan ada 10 tingkatan skala untuk parameter kerapatan dan transparansi, dengan rentang mulai dari 5% hingga 95%.

2. METODOLOGI

Setiap tahapan pada penelitian ini dijabarkan melalui diagram alir yang menjelaskan secara lengkap langkah-langkah dari penelitian ini yang terdapat pada Gambar 1.

2.1 Pengumpulan Citra Jenis Daun Jarum

Langkah awal dalam penelitian adalah mengumpulkan gambar-gambar pohon jenis daun jarum sebagai sumber data utama. Gambar-gambar ini diperoleh dari blok tradisional Tahura WAR Kemiling serta daerah sekitar Universitas Lampung. Jenis daun jarum yang dikumpulkan berjumlah empat yaitu *araucaria heterophylla*, *pinus merkusii*, *cupressus retusa*, dan *shorea javanica*. Dengan melibatkan 15 responden, penelitian ini memastikan adanya variasi dalam penilaian yang dapat membantu dalam mengklasifikasikan skala kerapatan dan transparansi dengan lebih akurat.

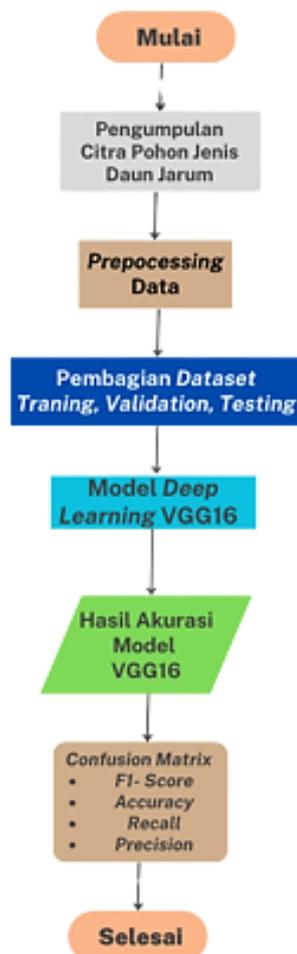
2.2 Preprocessing Data

Preprocessing data dilakukan guna menyiapkan kumpulan data sebelum memasukkannya ke dalam tahap pelatihan model [13]. Langkah-langkah dalam *preprocessing* citra daun jarum terdiri dari mengubah ukuran dan meningkatkan jumlah data. Pada tahap perubahan ukuran, citra daun jarum dari semua varietas

pohon akan dikurangi ukuran pikselnya hingga mencapai dimensi 224x224 piksel [14]. Jumlah data dalam *dataset* yang telah dikumpulkan masih terbilang kurang, sehingga diperlukan augmentasi data untuk menambah jumlah data yang tersedia [15]. Dalam proses augmentasi data, operasi yang digunakan mencakup *flip vertikal*, *flip horizontal*, dan *zoom* dengan faktor 0.1. sehingga jumlah gambar pada setiap kelas mencapai 100. *Dataset* jenis daun jarum ini disimpan dalam *Google Drive* untuk memudahkan pemrosesan data dengan model yang diprogram dalam *Google Colab*. *Dataset* juga disimpan dalam komputer Tesla K80. Setiap gambar jenis pohon disimpan dalam empat folder yang berbeda berdasarkan label kelas kerapatan dan transparansinya. Mesin akan membaca *dataset* ini pada awal prosesnya dan kemudian memprosesnya sesuai dengan kelas yang tertera dalam setiap folder. Hasil dari *preprocessing* citra daun jarum dapat ditemukan dalam Tabel 1.

Tabel 1. *Dataset* Citra Jenis Daun Jarum

Kelas Kerapatan Dan Transparansi Tajuk	Jenis Pohon			
	<i>Pinus merkusii</i>	<i>Araucaria heterophylla</i>	<i>Cupressus retusa</i>	<i>Shorea javanica</i>
D5_T95	100	100	100	100
D15_T85	100	100	100	100
D25_T75	100	100	100	100
D35_T65	100	100	100	100
D45_T55	100	100	100	100
D55_T45	100	100	100	100
D65_T35	100	100	100	100
D75_T25	100	100	100	100
D85_T15	100	100	100	100
D95_T5	100	100	100	100
Total	1000	1000	1000	1000



Gambar 1. Metodologi Penelitian

2.3 Pembagian Dataset

Pembagian data yang dilakukan adalah membagi data menjadi 3 bagian utama, yaitu data *training*, data *validation* dan data *testing*. Data *training* merupakan komponen kunci dalam proses melatih model. Sebanyak 70% dari jumlah total gambar akan diambil sebagai bagian dari data pelatihan [16]. Data *Validation* digunakan untuk memverifikasi kinerja model dan memastikan bahwa model tersebut dapat bekerja dengan baik pada data yang tidak pernah dilihat sebelumnya. Dalam penelitian ini, sebanyak 10% dari seluruh gambar akan digunakan sebagai data validasi. Proses validasi ini membantu memastikan bahwa model mampu menggeneralisasi dengan baik pada data yang berbeda dari data pelatihan [17]. Data *testing* memiliki peran penting dalam evaluasi kinerja model yang telah dilatih [18]. Dalam penelitian ini, sebanyak 20% dari keseluruhan gambar akan digunakan sebagai data uji. Data uji ini memungkinkan untuk menguji sejauh mana model yang telah dilatih mampu melakukan prediksi dengan baik pada data yang belum pernah dilihat sebelumnya, dan hasil pengujian ini membantu mengukur keakuratan dan kinerja keseluruhan dari model yang dikembangkan.

2.4 Model VGG16 Daun Jarum

Proses pelatihan model dalam penelitian ini memanfaatkan arsitektur VGG16. Pelatihan dilakukan menggunakan alat seperti *Google Colab* dan *Jupyter Notebook* dengan penyesuaian beberapa *hyperparameter* yang krusial, seperti *epoch*, *batch-size*, *optimizer*, dan *learning-rate*. *Hyperparameter* ini memainkan peran kunci dalam memengaruhi keberhasilan pelatihan dan pengujian model [19]. Nilai *hyperparameter* yang digunakan terdapat pada Tabel 2.

Tabel 2. *Hyperparameter* model

<i>Hyperparameter</i>	Jenis/Nilai
<i>Epoch</i>	10
<i>Batch-size</i>	32
<i>Optimizer</i>	Adam
<i>Learning-rate</i>	0,001

2.5 Hasil Akurasi Model VGG16

Hasil akurasi pelatihan model menunjukkan sejauh mana model dapat memahami dan menggeneralisasi pola dalam data [20]. Akurasi pelatihan yang tinggi mungkin menunjukkan bahwa model telah mempelajari data pelatihan dengan baik, tetapi tidak selalu mencerminkan kemampuan model untuk bekerja dengan data yang belum pernah dilihat sebelumnya.

2.6 Confusion Matrix

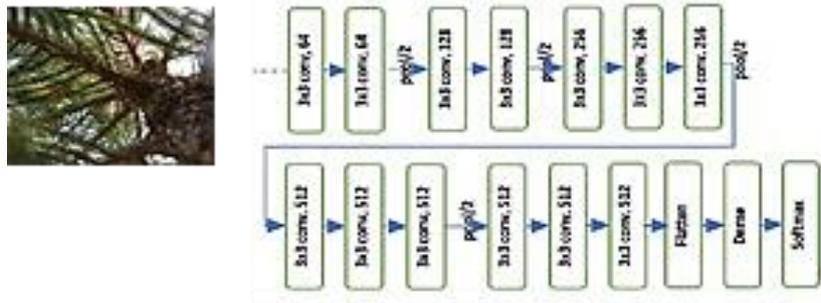
Confusion matrix diperoleh setelah proses pelatihan model pada data pelatihan dan validasi selesai. Saat menguji model, data uji digunakan untuk mengevaluasi performa model yang telah dilatih sebelumnya. Evaluasi kinerja model ini dapat dilakukan dengan menggunakan *confusion matrix* untuk menghitung metrik-metrik seperti akurasi (*accuracy*), *F1-score*, *recall*, dan presisi (*precision*) [21].

3. HASIL DAN ANALISIS

Pada bagian ini, akan dijelaskan hasil dan pembahasan dalam proses klasifikasi kerapatan dan transparansi pada pohon jenis daun jarum dengan arsitektur CNN VGG16. Analisis dan hasil evaluasi dari proses klasifikasi dan implementasi, dijelaskan dalam bagian ini. Adapun hal utama yang akan dibahas dalam bab ini adalah hasil akurasi dan evaluasi model pada setiap jenis pohon daun jarum.

3.1 Model VGG16 Daun Jarum

Model CNN VGG16 terdiri dari total 13 lapisan konvolusi, 5 lapisan *pooling*, 3 lapisan *fully-connected*, dan 1 lapisan *output* [22]. Dalam percobaan ini, model VGG16 memproses input *layer* dengan resolusi 224 x 224 piksel dan tiga saluran warna (RGB). Proses tersebut kemudian melibatkan 13 lapisan konvolusi, dan di setiap lapisan konvolusi, fungsi aktivasi ReLU digunakan setelah operasi konvolusi. Selain itu, beberapa lapisan *max pooling* diterapkan pada beberapa lapisan konvolusi dengan menggunakan *filter* 2x2. Ini berfungsi untuk mereduksi dimensi spasial dari gambar daun jarum dan pada saat yang sama membantu mengurangi jumlah parameter yang diperlukan dalam jaringan. Setelah melalui serangkaian lapisan konvolusi dan *max pooling*, fitur-fitur yang diambil dari gambar kemudian disambungkan ke dalam lapisan *fully-connected* yang terdiri dari 4096 *neuron* di setiap lapisannya. Lapisan *output* terakhir terdiri dari 1000 *neuron*, yang sesuai dengan jumlah kelas dalam *dataset ImageNet*, yang sering digunakan untuk melatih model pengenalan gambar. Lapisan *output* ini biasanya menggunakan fungsi aktivasi *softmax* untuk menghasilkan probabilitas untuk setiap kelas. Arsitektur VGG16 pada daun jarum dapat dilihat pada Gambar 2.



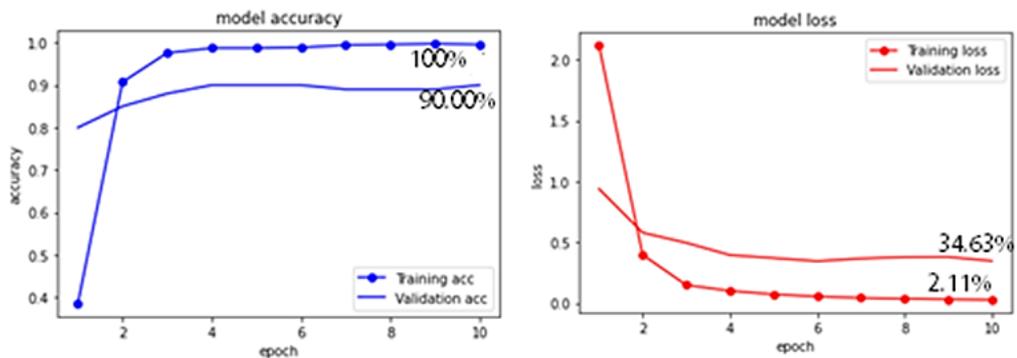
Gambar 2. Arsitektur VGG16 pada jenis daun jarum

3.2 Hasil Akurasi Model VGG16 Daun Jarum

Dalam bagian ini akan dibahas tingkat akurasi dan *loss* pada empat jenis pohon daun jarum, diantaranya *pinus merkusii*, *araucaria heterophylla*, *cupressus retusa*, dan *shorea javanica*.

1. Pinus Merkusii

Model VGG16 mencapai tingkat akurasi sebesar 90.00% dalam mengklasifikasikan kelas kerapatan dan transparansi pohon *pinus merkusii* ketika diperlakukan dengan mesin GPU Tesla K80, dan ini dicapai dalam waktu 110.00 detik.

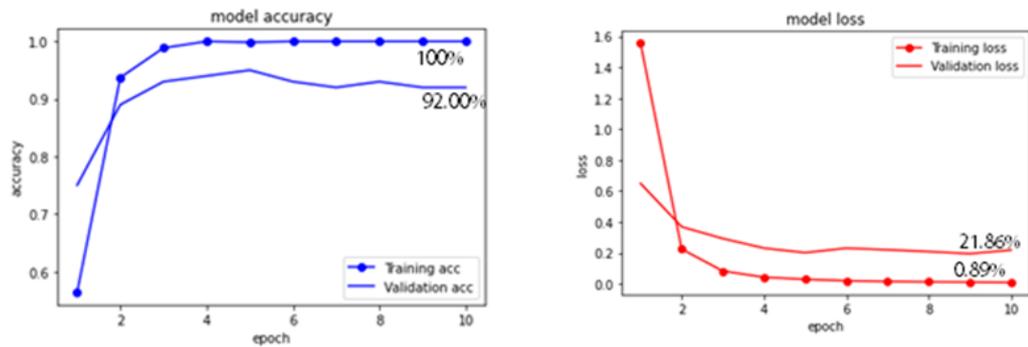


Gambar 3. Grafik *accuracy* dan *loss* model VGG16 *pinus merkusii* dengan GPU Tesla K80

Ilustrasi di atas menunjukkan grafik akurasi dan *loss* yang dihasilkan selama pelatihan model VGG16 *pinus merkusii* dengan penggunaan GPU Tesla K80. Pada Gambar 3a, terlihat bahwa tingkat akurasi model bersifat fluktuatif, walaupun secara keseluruhan terdapat peningkatan yang sedikit dari satu *epoch* ke *epoch* berikutnya. Terdapat penurunan yang terlihat pada *epoch* ke-7, tetapi kemudian mengalami peningkatan kembali pada *epoch* berikutnya. Fluktuasi dalam tingkat akurasi selama pengujian dianggap wajar karena merupakan bagian dari proses penyesuaian model terhadap data yang belum pernah dilihat sebelumnya. Hasil pelatihan menunjukkan bahwa akurasi pada data latihan mencapai 100%, sementara data validasi mencapai akurasi sebesar 90.00%. Di sisi lain, Gambar 3b menggambarkan perubahan dalam nilai kerugian (*loss*) pada model VGG16 untuk klasifikasi pohon *pinus merkusii*. Meskipun terjadi penurunan dalam nilai *loss*, grafiknya tidak stabil. Terdapat peningkatan dalam nilai *loss* pada *epoch* ke-7, ke-8, dan ke-9, namun nilai *loss* kembali menurun pada *epoch* selanjutnya. Nilai akhir *loss* pada data pelatihan adalah sekitar 2.11%, sedangkan pada data validasi mencapai sekitar 34.63%. Secara keseluruhan, grafik dari model VGG16 yang menggunakan GPU Tesla K80 menunjukkan variasi yang tidak terlalu signifikan dari satu *epoch* ke *epoch* berikutnya.

2. Araucaria Heterophylla

Model VGG16 untuk klasifikasi pohon *araucaria heterophylla* dalam menentukan kelas kerapatan dan transparansi, saat dijalankan menggunakan mesin GPU Tesla K80, mencapai tingkat akurasi sebesar 92.00% dalam waktu 85.00 detik.

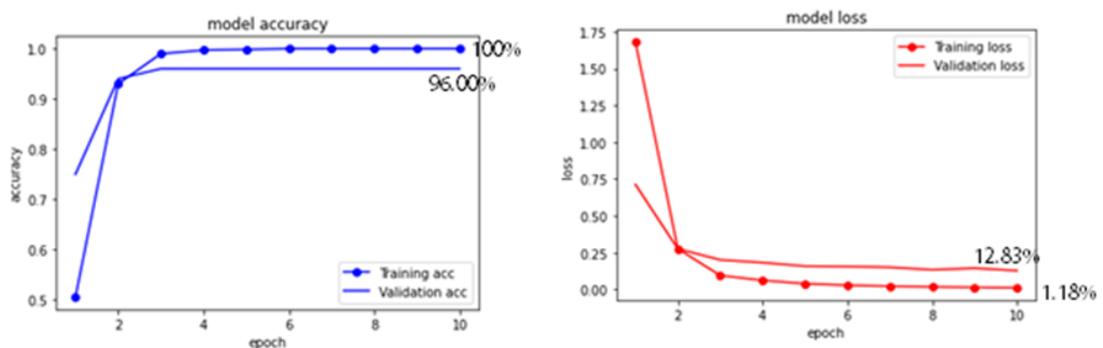


Gambar 4. Grafik *accuracy* dan *loss* model VGG16 *araucaria heterophylla* dengan GPU Tesla K80

Ilustrasi dalam Gambar 4 menggambarkan grafik akurasi dan *loss* selama proses pelatihan model VGG16 untuk klasifikasi kelas kerapatan dan transparansi pohon *araucaria heterophylla* menggunakan GPU Tesla K80. Dalam Gambar 4a, terlihat bahwa tingkat akurasi model hampir konstan, walaupun secara keseluruhan terjadi peningkatan yang sedikit dari satu *epoch* ke *epoch* berikutnya. Terjadi penurunan pada grafik pada *epoch* 6, 7, dan 9, tetapi kemudian mengalami peningkatan kembali pada *epoch* berikutnya, hingga mencapai *epoch* 10. Variasi tingkat akurasi yang naik dan turun selama pelatihan dianggap sebagai bagian yang normal karena model sedang beradaptasi dengan data yang belum pernah dilihat sebelumnya. Akurasi pada data pelatihan mencapai 100%, sementara data validasi mencapai akurasi sebesar 92.00%. Sementara itu, Gambar 4b menunjukkan perubahan dalam nilai kerugian (*loss*) pada model VGG16 untuk klasifikasi pohon *araucaria heterophylla*. Meskipun terjadi penurunan dalam grafik, namun kerugian tidak stabil. Terdapat peningkatan pada nilai *loss* pada *epoch* 6, yang kemudian mengalami penurunan pada *epoch* selanjutnya, namun kembali meningkat pada *epoch* 10. Nilai akhir dari *loss* pada data pelatihan adalah sekitar 0.89%, sedangkan pada data validasi mencapai sekitar 21.86%.

3. Cupressus Retusa

Model arsitektur VGG16 yang diterapkan pada klasifikasi kerapatan dan transparansi pohon *cupressus retusa*, saat dijalankan menggunakan mesin GPU Tesla K80, berhasil mencapai tingkat akurasi sebesar 96.00% dalam waktu 95.00 detik.

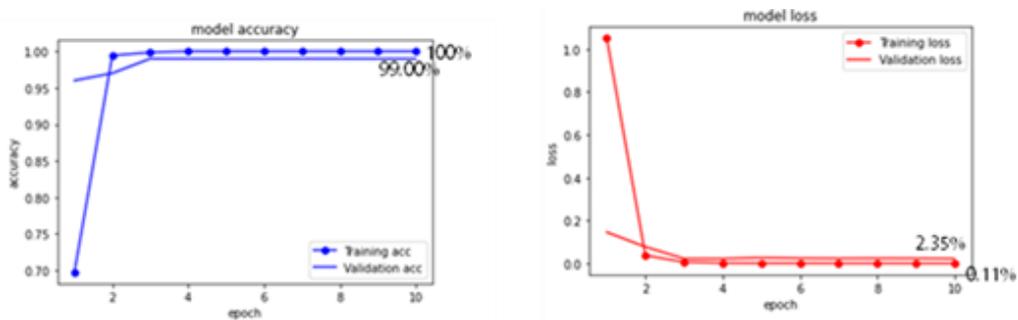


Gambar 5. Grafik *accuracy* dan *loss* model VGG16 *cupressus retusa*, dengan GPU Tesla K80

Ilustrasi pada Gambar 5 menggambarkan grafik akurasi dan *loss* selama proses pelatihan model VGG16 untuk mengenali persentase kerapatan dan transparansi pohon *cupressus retusa* dengan menggunakan GPU Tesla K80. Dalam Gambar 5a, terlihat bahwa tingkat akurasi model tidak konsisten, meskipun secara keseluruhan terjadi peningkatan yang sedikit dari satu *epoch* ke *epoch* berikutnya. Grafik tetap stabil dalam rentang *epoch* 3 hingga *epoch* 10. Variabilitas dalam tingkat akurasi selama pengujian dianggap wajar karena merupakan bagian dari proses penyesuaian model terhadap data yang belum pernah dilihat sebelumnya. Akurasi pada data pelatihan mencapai 100%, sementara data validasi mencapai akurasi sekitar 96.00%. Di sisi lain, Gambar 5b menggambarkan perubahan dalam nilai kerugian (*loss*) pada model VGG16 untuk pohon *cupressus retusa*. Meskipun terjadi penurunan dalam grafik, nilai kerugian tidak stabil. Terdapat peningkatan *loss* pada *epoch* 9, yang kemudian turun kembali pada *epoch* berikutnya. Nilai akhir *loss* pada data pelatihan adalah sekitar 1.18%, sedangkan pada data validasi mencapai sekitar 12.83%.

4. Shorea Javanica

Model VGG16 yang diterapkan pada klasifikasi kerapatan dan transparansi pada pohon *shorea javanica*, saat dijalankan dengan menggunakan mesin GPU Tesla K80, berhasil mencapai tingkat akurasi sebesar 99.00% dalam waktu 100.00 detik.



Gambar 6. Grafik accuracy dan loss model VGG16 *shorea javanica*, dengan GPU Tesla K80

Gambar 6 menggambarkan grafik akurasi dan kerugian selama proses pelatihan model VGG16 untuk mengenali kerapatan dan transparansi pada pohon *shorea javanica* menggunakan GPU Tesla K80. Dalam Gambar 6a, terlihat bahwa tingkat akurasi model tidak konsisten, meskipun secara keseluruhan terjadi peningkatan yang sedikit dari satu *epoch* ke *epoch* berikutnya. Stabilitas dalam grafik terlihat mulai dari *epoch* 3 hingga *epoch* 10. Akurasi pada data pelatihan mencapai 100%, sementara data validasi mencapai akurasi sekitar 99.00%. Sementara itu, Gambar 6b menggambarkan perubahan dalam nilai kerugian (*loss*) pada model VGG16 untuk pohon *shorea javanica*. Meskipun terjadi penurunan dalam grafik, nilai kerugian tidak konsisten. Terdapat peningkatan *loss* pada *epoch* 5 dan 8, yang kemudian turun kembali pada *epoch* berikutnya. Nilai akhir dari *loss* pada data pelatihan adalah sekitar 0.11%, sedangkan pada data validasi mencapai sekitar 2.35%.

3.3 Evaluasi Model VGG16 Daun Jarum

Evaluasi model mencakup *confusion matrix* pada citra empat jenis pohon jenis daun jarum berdasarkan kelas kerapatan dan transparansi daun jarum.

1. Confusion Matrix Pinus Merkusii

Tingkat akurasi pengujian model VGG16 dalam menentukan kerapatan dan transparansi pada pohon *pinus merkusii* di mesin Tesla K80 adalah sekitar 91%. Informasi tentang nilai dari *confusion matrix* untuk klasifikasi kerapatan dan transparansi pohon *pinus merkusii* dapat ditemukan dalam Tabel 3.

Tabel 3. Precision, Recall, F1-score Arsitektur VGG16 Pohon Pinus merkusii

Kelas Kerapatan dan Transparansi Daun Jarum	Hasil		
	Precision	Recall	F1-score
D5,T95	100%	84.00%	91.00%
D15,T85	72.00%	87.00%	79.00%
D25,T75	90.00%	96.00%	83.00%
D35,T65	79.00%	92.00%	85.00%
D45,T55	100%	100%	100%
D55,T45	100%	95.00%	98.00%
D65,T35	90.00%	90.00%	90.00%
D75,T25	85.00%	100%	92.00%
D85,T15	100%	90.00%	95.00%
D95,T5	94.00%	76.00%	84.00%
Accuracy		91.00%	
Error		9.00%	

Tabel di atas memaparkan nilai *precision*, *recall*, dan *f1-score* dari arsitektur VGG16 yang digunakan untuk mengklasifikasikan nilai kerapatan dan transparansi pada pohon *pinus merkusii*. *Precision* terbaik terjadi pada kelas dengan tingkat kerapatan 5, 45, 55, dan 85, yang mencapai 100%. Sementara itu, *precision* terendah terjadi pada kelas dengan tingkat kerapatan 15, yaitu sebesar 72.00%. Hasil ini muncul karena ada 5 kasus *false positive* (FP) pada kelas kerapatan 15 yang seharusnya termasuk dalam kelas kerapatan 5, 2 FP pada kelas kerapatan 35, dan 1 FP pada kelas kerapatan 65. *Recall* tertinggi ditemukan pada kelas dengan tingkat kerapatan 45 dan 75, mencapai 100%. Sementara itu, *recall* terendah terjadi pada kelas dengan tingkat kerapatan 95, yaitu sebesar 76.00%. Ini disebabkan oleh 5

false negative (FN) pada kelas kerapatan 95 yang seharusnya termasuk dalam kelas kerapatan 25 dan 2 FN pada kelas kerapatan 75. *F1-score* tertinggi ditemukan pada kelas kerapatan 45, sementara nilai *F1-score* terendah terdapat pada kelas kerapatan 15.

2. Confusion Matrix Araucaria Heterophylla

Tingkat akurasi pengujian model VGG16 dalam menentukan kerapatan dan transparansi pada pohon *araucaria heterophylla* di mesin Tesla K80 adalah sekitar 93.00%. Informasi tentang nilai dari *confusion matrix* untuk klasifikasi kerapatan dan transparansi pohon *araucaria heterophylla* dapat ditemukan dalam Tabel 4.

Tabel 4. Precision, Recall, F1-score Arsitektur VGG16 Pohon Araucaria Heterophylla

Kelas Kerapatan dan Transparansi Daun Jarum	Hasil		
	Precision	Recall	F1-score
D5,T95	93.00%	100%	96.00%
D15,T85	65.00%	73.00%	69.00%
D25,T75	100%	96.00%	98.00%
D35,T65	96.00%	100%	98.00%
D45,T55	100%	100%	100%
D55,T45	88.00%	67.00%	76.00%
D65,T35	100%	90.00%	95.00%
D75,T25	100%	100%	100%
D85,T15	83.00%	95.00%	89.00%
D95,T5	100%	100%	100%
Accuracy	93.00%		
Error	7.00%		

Tabel di atas memperlihatkan nilai *precision*, *recall*, dan *f1-score* dari arsitektur VGG16 pada klasifikasi kerapatan dan transparansi pohon *araucaria heterophylla*. *Precision* terbaik diperoleh oleh kelas dengan kerapatan 25, 45, 65, 75, dan 95, mencapai 100%. Sementara itu, *precision* terendah terdapat pada kelas dengan kerapatan 15, yaitu sekitar 65.00%. Hal ini disebabkan oleh adanya 6 kasus *false positive* (FP) pada kelas kerapatan 15 yang seharusnya termasuk dalam kelas kerapatan 55 (4 FP) dan kelas kerapatan 65 (2 FP). *Recall* tertinggi ditemukan pada kelas dengan kerapatan 5, 35, 45, 75, dan 95, mencapai 100%. Sementara itu, *recall* terendah terjadi pada kelas dengan kerapatan 55, yaitu sekitar 67.00%. Hal ini disebabkan oleh adanya 7 kasus *false negative* (FN) pada kelas kerapatan 55 yang seharusnya termasuk dalam kelas kerapatan 15 (4 FN) dan kelas kerapatan 85 (3 FN). *F1-score* tertinggi terdapat pada kelas kerapatan 45, 75, dan 95, sementara nilai *F1-score* terendah terjadi pada kelas kerapatan 15.

3. Confusion Matrix Cupressus Retusa

Tingkat akurasi pengujian model VGG16 dalam menentukan kerapatan dan transparansi pada pohon *cupressus retusa* di mesin Tesla K80 adalah sekitar 95.00%. Informasi tentang nilai dari *confusion matrix* untuk klasifikasi kerapatan dan transparansi pohon *cupressus retusa* dapat ditemukan dalam Tabel 5.

Tabel 5. Precision, Recall, F1-score Arsitektur VGG16 Pohon Cupressus Retusa

Kelas Kerapatan dan Transparansi Daun Jarum	Hasil		
	Precision	Recall	F1-score
D5,T95	91.00%	80.00%	85.00%
D15,T85	100%	93.00%	97.00%
D25,T75	93.00%	100%	96.00%
D35,T65	96.00%	100%	98.00%
D45,T55	100%	100%	100%
D55,T45	100%	100%	100%
D65,T35	100%	95.00%	98.00%
D75,T25	92.00%	100%	96.00%
D85,T15	83.00%	90.00%	86.00%
D95,T5	100%	95.00%	98.00%
Accuracy	95.00%		
Error	5.00%		

Tabel di atas menggambarkan nilai *precision*, *recall*, dan *f1-score* dari arsitektur VGG16 pada klasifikasi kerapatan dan transparansi pohon *cupressus retusa*. *Precision* memiliki tingkat tertinggi hampir pada seluruh kelas, yakni sekitar 100%, kecuali pada kelas dengan tingkat kerapatan 5, 25, 35,

75, dan 85. *Precision* terendah terdapat pada kelas kerapatan 85, yaitu sekitar 83.00%. Hal ini disebabkan oleh adanya 4 kasus *false positive* (FP) pada kelas kerapatan 85, yang seharusnya termasuk dalam kelas kerapatan 5 (3 FP) dan kelas kerapatan 65 (1 FP). *Recall* tertinggi ditemukan pada sebagian besar kelas, mencapai sekitar 100%, kecuali pada kelas dengan tingkat kerapatan 5, 15, 65, 85, dan 95. *Recall* terendah terjadi pada kelas dengan tingkat kerapatan 5, yaitu sekitar 80.00%. Ini disebabkan oleh adanya 5 kasus *false negative* (FN) pada kelas kerapatan 5 yang seharusnya termasuk dalam kelas kerapatan 25 (2 FN) dan kelas kerapatan 85 (3 FN). Nilai *F1-score* tertinggi terdapat pada kelas kerapatan 45 dan 55, mencapai sekitar 100%. Sementara itu, nilai *F1-score* terendah terjadi pada kelas kerapatan 5, yakni sekitar 85.00%.

4. Confusion Matrix Shorea Javanica

Tingkat akurasi pengujian model VGG16 dalam menentukan kerapatan dan transparansi pada pohon *shorea javanica* di mesin Tesla K80 adalah sekitar 99.00%. Informasi mengenai nilai dari *confusion matrix* untuk klasifikasi kerapatan dan transparansi pohon *shorea javanica* dapat ditemukan dalam Tabel 6.

Tabel 6. *Precision, Recall, F1-score* Arsitektur VGG16 Pohon Shorea Javanica

Kelas Kerapatan dan Transparansi	Hasil		
	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Daun Jarum			
D5,T95	100%	100%	100%
D15,T85	100%	100%	100%
D25,T75	96.00%	100%	98.00%
D35,T65	100%	100%	100%
D45,T55	100%	100%	100%
D55,T45	100%	100%	100%
D65,T35	100%	100%	100%
D75,T25	100%	100%	100%
D85,T15	100%	100%	100%
D95,T5	100%	95.00%	98.00%
<i>Accuracy</i>		99.00%	
<i>Error</i>		1.00%	

Tabel di atas menampilkan nilai *precision*, *recall*, dan *f1-score* dari arsitektur VGG16 dalam klasifikasi kerapatan dan transparansi pohon *shorea javanica*. *Precision* memiliki tingkat tertinggi pada sebagian besar kelas, yaitu sekitar 100%, kecuali pada kelas dengan tingkat kerapatan 25. *Precision* terendah terjadi pada kelas kerapatan 25, yaitu sekitar 96.00%. Ini disebabkan oleh adanya 1 kasus *false positive* (FP) pada kelas kerapatan 5, yang seharusnya termasuk dalam kelas kerapatan 95. *Recall* tertinggi ditemukan pada hampir semua kelas, mencapai sekitar 100%, kecuali pada kelas dengan tingkat kerapatan 95. *Recall* terendah terjadi pada kelas dengan kerapatan 95, yaitu sekitar 95.00%. Hal ini disebabkan oleh adanya 1 kasus *false negative* (FN) pada kelas kerapatan 95 yang seharusnya termasuk dalam kelas kerapatan 25. Nilai *F1-score* tertinggi ditemukan pada hampir semua kelas kerapatan, yaitu sekitar 100%, kecuali pada kelas kerapatan 25 dan 95. Nilai *F1-score* terendah terjadi pada kelas kerapatan 25 dan 95, yaitu sekitar 98.00%.

4. KESIMPULAN

Pada penelitian ini identifikasi skala kerapatan dan transparansi tajuk dengan empat jenis daun jarum berhasil dilakukan dengan baik menggunakan arsitektur VGG16 dengan perwakilan *hyperparameter* tertentu. Hasil akurasi yang didapatkan oleh arsitektur VGG16 dengan menggunakan mesin tesla K80 terhadap gambar pohon daun jarum *pinus merkusii* sebesar 90.00%, pada pohon *araucaria heterophylla* sebesar 92.00%, pada pohon *cupressus retusa* sebesar 96.00%, dan pada pohon *shorea javanica* sebesar 99.00%. Hasil analisis misklasifikasi pada arsitektur VGG16 dengan citra pohon *pinus merkusii* sebanyak 19 citra, dengan citra pohon *araucaria heterophylla* sebanyak 15 citra, dengan citra pohon *cupressus retusa* sebanyak 10 citra, dan dengan citra pohon *shorea javanica* sebanyak 1 citra. Terjadinya misklasifikasi dikarenakan adanya citra yang memiliki pola dan posisi yang serupa. Nilai ketepatan model dalam memprediksi kelas kerapatan dan transparansi pada empat jenis daun jarum (*precision*) dan nilai efektivitas pencarian data uji dalam menemukan kelas kerapatan dan transparansi pada empat jenis daun jarum (*recall*), menggunakan augmentasi *flip vertical*, *flip horizontal*, dan *zoom* menghasilkan rata-rata *precision* dan *recall* masing masing sebesar 91.00% pada citra *pinus merkusii*, untuk citra *araucaria heterophylla* menghasilkan rata-rata *precision* dan *recall* masing masing sebesar 92.50% dan 92.10%, untuk citra *cupressus retusa* menghasilkan rata-rata *precision* dan *recall*

masing masing sebesar 95.50% dan 95.30%, dan untuk citra *shorea javanica* menghasilkan rata-rata *precision* dan *recall* masing masing sebesar 99.60% dan 99.50%.

REFERENSI

- [1] D. Pertiwi, R. Safe, and H. Kaskoyo, "Identifikasi Kondisi Kerusakan Pohon Menggunakan Metode Forest Health Monitoring di Tahura WAR Provinsi Lampung Identification of Tree Damage Condition Using the Forest Health Monitoring Method at Tahura WAR Lampung Province," *J. Perenn.*, vol. 15, no. 1, pp. 1–7, 2019, [Online]. Available: <http://journal.unhas.ac.id/index.php/perennial>
- [2] R. Safe'i, A. Darmawan, H. Kaskoyo, and C. F. G. Rezinda, "Analysis of Changes in Forest Health Status Values in Conservation Forest (Case Study: Plant and Animal Collection Blocks in Wan Abdul Rachman Forest Park (Tahura WAR))," *J. Phys. Conf. Ser.*, vol. 1842, no. 1, 2021, doi: 10.1088/1742-6596/1842/1/012049.
- [3] R. Safe'i, C. Wulandari, and H. Kaskoyo, "Forest Health Assessment of Various Forest Types in Lampung Province (in Bahasa : Penilaian Kesehatan Hutan pada Berbagai Tipe Hutan di Provinsi Lampung)," *J. Sylva Lestari*, vol. 7, no. 1, pp. 95–109, 2019.
- [4] Supriyanto and T. Iskandar, "Penilaian Kesehatan Kebun Benih Semai Pinus Merkusii Dengan Metode FHM (Forest Health Monitoring) di KPH Sumedang Health Assessment for Seedling Seed Orchard of Pinus merkusii Using FHM (Forest Health Monitoring) Method in KPH Sumedang," *J. Trop. Silv.*, vol. 9, no. 2, pp. 99–108, 2019, doi: 10.29244/j-siltrop.9.2.99-108.
- [5] D. Pertiwi, R. Safe'i, and H. Kaskoyo, "Kesehatan Hutan Di Blok Koleksi Tumbuhan Dan/Atau Satwa Tahura Wan Abdul Rachman Provinsi Lampung," *J. Hutan Trop.*, vol. 8, no. 3, p. 251, 2020, doi: 10.20527/jht.v8i3.9623.
- [6] I. Wulandari, H. Yasin, and T. Widiari, "Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma Convolutional Neural Network (Cnn)," *J. Gaussian*, vol. 9, no. 3, pp. 273–282, 2020, doi: 10.14710/j.gauss.v9i3.27416.
- [7] A. S. Almryad and H. Kutucu, "Automatic identification for field butterflies by convolutional neural networks," *Eng. Sci. Technol. an Int. J.*, vol. 23, no. 1, pp. 189–195, 2020, doi: 10.1016/j.jestch.2020.01.006.
- [8] M. Tripathi, "Analysis of Convolutional Neural Network based Image Classification Techniques," *J. Innov. Image Process.*, vol. 3, no. 2, pp. 100–117, 2021, doi: 10.36548/jiip.2021.2.003.
- [9] M. Fasounaki, E. B. Yüce, S. Öncül, and G. Ince, "CNN-based Text-independent Automatic Speaker Identification Using Short Utterances," *Proc. - 6th Int. Conf. Comput. Sci. Eng. UBMK 2021*, vol. 01, pp. 413–418, 2021, doi: 10.1109/UBMK52708.2021.9559031.
- [10] M. A. Hasan, Y. Riyanto, and D. Riana, "Grape leaf image disease classification using CNN-VGG16 model," *J. Teknol. dan Sist. Komput.*, vol. 9, no. 4, pp. 218–223, 2021, doi: 10.14710/jtsiskom.2021.14013.
- [11] C. Narvekar and M. Rao, "Flower classification using CNN and transfer learning in CNN-Agriculture Perspective," *Proc. 3rd Int. Conf. Intell. Sustain. Syst. ICISS 2020*, pp. 660–664, 2020, doi: 10.1109/ICISS49785.2020.9316030.
- [12] H. Wang, "Garbage recognition and classification system based on convolutional neural network vgg16," *Proc. - 2020 3rd Int. Conf. Adv. Electron. Mater. Comput. Softw. Eng. AEMCSE 2020*, pp. 252–255, 2020, doi: 10.1109/AEMCSE50948.2020.00061.
- [13] S. Tang, S. Yuan, and Y. Zhu, "Data Preprocessing Techniques in Convolutional Neural Network Based on Fault Diagnosis towards Rotating Machinery," *IEEE Access*, vol. 8, pp. 149487–149496, 2020, doi: 10.1109/ACCESS.2020.3012182.
- [14] J. Sanjaya and M. Ayub, "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 2, pp. 311–323, 2020, doi: 10.28932/jutisi.v6i2.2688.
- [15] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [16] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [17] A. E. Maxwell, T. A. Warner, and L. A. Guillén, "Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—part 2: Recommendations and best practices," *Remote Sens.*, vol. 13, no. 13, 2021, doi: 10.3390/rs13132591.
- [18] R. Ramadhan, I. Fibriani, and W. Cahyadi, "Application of Microexpressions to Recognize Kinship Using Extreme Learning Machine Penerapan Microexpressions untuk Mengenal Hubungan Kekeabatan Menggunakan Extreme Learning Machine," vol. 1, no. October, pp. 162–169, 2021, [Online]. Available: <https://journal.irpi.or.id/index.php/malcom/article/view/101>
- [19] R. Andonie and A. C. Florea, "Weighted random search for CNN hyperparameter optimization," *Int. J.*

- Comput. Commun. Control*, vol. 15, no. 2, pp. 1–11, 2020, doi: 10.15837/IJCCC.2020.2.3868.
- [20] R. J. Gunawan, B. Irawan, and C. Setianingsih, “Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network Dengan Model Arsitektur VGG16,” *Engineering*, vol. 8, no. 5, pp. 6442–6454, 2021.
- [21] H. Iwata, Y. Hayashi, A. Hasegawa, K. Terayama, and Y. Okuno, “Classification of scanning electron microscope images of pharmaceutical excipients using deep convolutional neural networks with transfer learning,” *Int. J. Pharm. X*, vol. 4, no. August, p. 100135, 2022, doi: 10.1016/j.ijpx.2022.100135.
- [22] R. Windiawan, A. Suharso, and S. Artikel, “Identifikasi Penyakit pada Daun Kopi Menggunakan Metode Deep Learning VGG16,” *J. Keilmuan dan Apl. Tek. Inform.*, vol. 13, no. 2, pp. 9–16, 2021, [Online]. Available: <https://doi.org/10.35891/explorit>