

**KLASIFIKASI KUALITAS GETAH KEMENYAN
MENGUNAKAN ARSITEKTUR GOOGLNET
INCEPTION V3 BERBASIS CITRA**

SKRIPSI

OLEH:

VICA SARIANI SITUMORANG

228160087



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS MEDAN AREA
MEDAN
2026**

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Document Accepted 1/7/26

Access From (repository.uma.ac.id)1/7/26

**KLASIFIKASI KUALITAS GETAH KEMENYAN
MENGUNAKAN ARSITEKTUR GOOGLNET
INCEPTION V3 BERBASIS CITRA**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh
Gelar Sarjana di Fakultas Teknik
Universitas Medan Area**



OLEH:

VICA SARIANI SITUMORANG

228160087

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS MEDAN AREA
MEDAN
2026**

HALAMAN PENGESAHAN

**Judul Skripsi : KLASIFIKASI KUALITAS GETAH KEMENYAN
MENGUNAKAN ARSITEKTUR GOOGLNET INCEPTION
V3 BERBASIS CITRA**


Nama : Vica Sariani Situmorang
NPM : 228160087
Fakultas : Teknik

**Disetujui Oleh
Komisi Pembimbing**


Dr. Arnes Sembiring S.T.M.T
Pembimbing I



Dr. Agus Supriatno, S.T. M.T
Rekan Pembimbing
Fakultas Teknik



Dr. Nur Muniono S.Kom, M.Kom
Ka. Prodi

Tanggal Lulus: 12 Maret 2026

HALAMAN PERNYATAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar sarjana merupakan hasil karya tulis saya sendiri. Adapun bagian-bagian tertentu dalam penulisan skripsi ini yang saya kutip dari hasil karya orang lain telah dituliskan sumbernya secara jelas sesuai dengan norma, kaidah, dan etika penulisan ilmiah.

Saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi-sanksi lainnya dengan peraturan yang berlaku, apabila di kemudian hari ditemukan adanya plagiat dalam skripsi ini.

Medan, 12 Maret 2026



Vica Sariani Situmorang
228160087

HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademik Universitas Medan Area, saya yang bertanda tangan di bawah ini:

Nama : Vica Sariani Situmorang
NPM : 228160087
Program Studi : Teknik Informatika
Fakultas : Teknik
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Medan Area **Hak Bebas Royalti Noneksklusif (*Non-exclusive Royalty-Free Right*)** atas karya ilmiah saya yang berjudul : “Klasifikasi Kualitas Getah Kemenyan Menggunakan Arsitektur GoogleNet Inception V3 Berbasis Citra”

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan Skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Medan

Pada tanggal : 12 Maret 2026

Yang menyatakan



(Vica Sariani Situmorang)

228160087

RIWAYAT HIDUP

Penulis dilahirkan di Kandis Pekan Baru Pada tanggal 16 Juni 2004 dari ayah Ronal Robert Situmorang dan ibu Nurlenny Lbn.Tobing. Penulis merupakan anak kedua dari tujuh bersaudara. Penulis pertama kali mengenyam pendidikan di bangku SD YP GKPI Kandis pada tahun 2010 dan lulus pada tahun 2016. Kemudian penulis melanjutkan pendidikan ke jenjang SMP pada tahun 2016 di SMP Negeri 3 Pahae Julu Tapanuli Utara dan lulus pada tahun 2019. Pada tahun yang sama, penulis melanjutkan ke jenjang selanjutnya yaitu di SMK Negeri 1 Pahae Julu dan pada bulan September tahun 2022, penulis melanjutkan pendidikan di bangku kuliah dan terdaftar sebagai mahasiswa Fakultas Teknik dengan Program Studi Teknik Informatika di Universitas Medan Area.



KATA PENGANTAR

Puji dan syukur penulis haturkan kehadiran Allah Yang Maha Esa, karena berkat dan rahmat-Nya saya dapat menyelesaikan skripsi yang berjudul “Klasifikasi Kualitas Getah Kemenyan Menggunakan Arsitektur GoogleNet Inception V3 Berbasis Citra”. Skripsi ini dibuat untuk memnuhi tugas akhir perkuliahan dan sebagai salah satu persyaratan untuk memperoleh gelar Sarjana Strata 1 di Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area. Selain itu, skripsi ini juga dibuat sebagai salah satu wujud implementasi dari ilmu yang didapatkan selama masa perkuliahan di Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area.

Skripsi ini tentunya tidak lepas dari bimbingan, masukan, dan arahan dari berbagai pihak. Oleh karena itu, pada kesempatan ini saya ingin mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Rizki Muliono, S.Kom, M.Kom sebagai Ketua Program Studi Teknik Informatika yang telah memberikan dukungan selama masa perkuliahan di Teknik Informatika Universitas Medan Area.
2. Bapak Dr. Arnes Sembiring, S.T, M.T sebagai dosen pembimbing utama yang telah meluangkan waktu memberikan dukungan, bimbingan, dan motivasi dalam menyelesaikan skripsi ini.
3. Seluruh Dosen dan Staf Program Studi Teknik Informatika Universitas Medan Area
4. Kepada kedua orang tua tercinta, penulis mengucapkan terima kasih yang tidak terhingga. Setiap langkah yang penulis tempuh hingga

sampai pada titik ini tidak pernah lepas dari doa yang Bapak dan Ibu panjatkan dalam diam, dari dukungan yang mungkin tak selalu terucap, serta dari pengorbanan yang sering kali penulis sadari belakangan. Penulis memahami bahwa perjalanan ini dibangun dari kesabaran, ketulusan, dan cinta yang Bapak dan Ibu berikan tanpa syarat. Di saat penulis lelah, ragu, dan hampir menyerah, doa Bapak dan Ibu menjadi kekuatan yang menjaga penulis tetap bertahan. Skripsi ini penulis persembahkan sebagai wujud rasa terima kasih dan bakti yang sederhana. Semoga Bapak dan Ibu senantiasa diberikan kesehatan, ketenangan, dan kebahagiaan. *I love my father dan my mother, you are the reason the author has survived until this point.*

5. Teruntuk Saudara/I tercinta Ferdinan, Melky, Farel, Chelsae, Rosa, Rizki penulis mengucapkan terima kasih yang sebesar-besarnya atas dukungan yang begitu berarti selama proses penyelesaian skripsi ini. Bantuan yang diberikan, baik dalam bentuk dukungan finansial, doa, maupun semangat yang tidak pernah putus, menjadi kekuatan penting bagi penulis untuk terus melangkah. Terima kasih telah menjadi sistem pendukung yang kokoh bagi penulis hingga titik ini. Semoga setiap kebaikan yang Saudara/I berikan dibalas dengan kebaikan yang berlipat ganda.
6. Seluruh teman-teman yang sudah memberikan dukungannya selama penulisan skripsi ini
7. Teruntuk teman-teman seperjuangan saya, Adelina Br.Nainggolan, Siska Octiani. Terima kasih telah menjadi teman dalam suka dan duka selama

menjalani perkuliahan, penelitian, hingga penyusunan skripsi ini. Terima kasih atas semangat, motivasi dan waktu untuk saling membantu selama perkuliahan ini. Semoga semua perjuangan dan kebersamaan kita selama perkuliahan ini membawa manfaat dan keberkahan bagi kita semua, dan semoga pertemanan kita tetap terjaga.

8. Terakhir, kepada diri penulis, Vica Sariani Situmorang. Terima kasih telah menjadi pribadi yang tangguh dan tidak menyerah dalam menghadapi berbagai tantangan selama proses penyusunan skripsi ini. Meskipun banyak hambatan yang dilalui, baik secara fisik, biaya maupun emosional, penulis mampu terus melangkah dan menyelesaikan tugas ini dengan penuh dedikasi. Setiap proses yang dilalui, baik suka maupun duka adalah bagian dari perjalanan yang akan menjadi pijakan menuju masa depan yang lebih baik. Semoga segala usaha dan pengorbanan yang telah dicurahkan dapat menjadi awal dari keberhasilan-keberhasilan berikutnya.

Saya harap semoga Tuhan Yang Maha Esa mengaruniakan rahmat-Nya kepada mereka semua. Semoga skripsi ini dapat bermanfaat bagi kita semua, Amin.

Medan, 12 Maret 2026



Vica Sariani Situmorang
228160087

ABSTRAK

Proses penilaian kualitas getah kemenyan pada umumnya masih dilakukan secara visual sehingga berpotensi menimbulkan ketidakkonsistenan. Penelitian ini bertujuan merancang model klasifikasi kualitas getah kemenyan berbasis citra digital menggunakan arsitektur *Convolutional Neural Network* (CNN) Inception V3. Dataset yang digunakan berjumlah 1.500 citra yang dibagi ke dalam data pelatihan, validasi, dan pengujian dengan tiga kategori kualitas, yaitu tinggi, sedang, dan rendah. Empat konfigurasi pelatihan diterapkan, yakni *training from scratch* dan *transfer learning*, masing-masing dengan dan tanpa penerapan data *augmentation*. Hasil evaluasi menunjukkan bahwa konfigurasi *training from scratch* dengan data *augmentation* menghasilkan performa terbaik dengan akurasi pengujian sebesar 99% serta nilai rata-rata *precision*, *recall*, dan F1-score sebesar 0,99. Analisis *confusion matrix* memperlihatkan tingkat kesalahan klasifikasi yang sangat minimal pada seluruh kategori. Model terbaik kemudian dikonversi ke format *TensorFlow Lite* dan diintegrasikan ke dalam aplikasi *mobile* berbasis Android. Temuan ini menunjukkan bahwa arsitektur Inception V3 mampu memberikan kinerja klasifikasi yang tinggi dan mendukung proses penilaian mutu getah kemenyan secara lebih objektif.

Kata Kunci: Kemenyan, Klasifikasi Citra, CNN, Inception V3.

ABSTRACT

The quality assessment of benzoin resin is generally conducted through visual inspection, which may lead to inconsistencies and subjectivity. This study aims to develop an image-based classification model for benzoin resin quality using the Convolutional Neural Network (CNN) architecture Inception V3. The dataset consists of 1,500 images divided into training, validation, and testing sets across three quality categories: high, medium, and low. Four training configurations were implemented, namely training from scratch and transfer learning, each with and without data augmentation. The evaluation results indicate that the training from scratch configuration with data augmentation achieved the best performance, with a testing accuracy of 99% and average precision, recall, and F1-score of 0.99. The confusion matrix analysis demonstrates a very low misclassification rate across all categories. The best-performing model was subsequently converted into TensorFlow Lite format and integrated into an Android-based mobile application. These findings demonstrate that the Inception V3 architecture provides high classification performance and supports a more objective quality assessment process for benzoin resin.

Keywords: Benzoin Resin, Image Classification, CNN, Inception V3.

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERNYATAAN	iii
RIWAYAT HIDUP	v
KATA PENGANTAR	vi
ABSTRAK	ix
ABSTRACT	x
DAFTAR ISI	xi
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
 BAB I PENDAHULUAN	 1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	6
 BAB II TINJAUAN PUSTAKA	 7
2.1 Citra Digital	7
2.2 Pengolahan Citra Digital	7
2.3 Klasifikasi	8
2.4 <i>Deep Learning</i>	9
2.5 <i>Convolutional Neural Network</i>	9
2.6 Arsitektur GoogLeNet dan Inception V3	13
2.6.1 Sejarah Singkat GoogLeNet	13
2.6.2 GoogLeNet	15
2.6.3 Inception V3	16
2.7 <i>Transfer Learning</i>	17
2.8 <i>Training from scratch</i>	18

2.9	Pengaruh Data Augmentasi Pada CNN	19
2.10	Kemenyan	21
2.10.1	Jenis-jenis Kualitas Kemenyan Berdasarkan Citra	21
2.11	Fungsi <i>Loss</i> dan <i>Optimizer</i>	23
2.12	Evaluasi Kinerja Model	24
2.12.1	<i>Confusion Matrix</i>	24
2.12.2	<i>Precision-Recall Curve</i>	25
2.13	Implementasi Model <i>Deep Learning</i> Ke Aplikasi <i>Mobile</i>	25
2.14	Penelitian Terdahulu	27
BAB III METODOLOGI PENELITIAN		29
3.1	Kerangka Penelitian	29
3.2	Teknik Pengumpulan Data	31
3.4	<i>Split Data</i>	31
3.5	Augmentasi	32
3.6	<i>Hyperparameter</i>	33
3.7	Skenario Eksperimen Pelatihan Model	35
3.8	Evaluasi Model	37
3.9	Implementasi Model Ke Aplikasi Android	38
3.10	Pengujian Dan Evaluasi Aplikasi	39
BAB IV HASIL DAN PEMBAHASAN		42
4.1	Akuisisi Dataset	42
4.2	Preprosesing Dataset	43
4.2.1	<i>Random Horizontal Flip</i>	43
4.2.2	<i>Random Vertikal Flip</i>	43
4.2.3	<i>Random Rotation</i>	44
4.2.4	<i>Color Jitter</i>	44
4.2.5	Konversi ke bentuk Tensor	44
4.2.6	Normalisasi	44
4.3	Pelatihan Model Inception V3	45
4.3.1	Konfigurasi Pelatihan	45

4.3.2	<i>Training from Scratch</i> dengan Data Augmentation	46
4.3.3	Transfer Learning dengan Data Augmentation	47
4.4	Pelatihan Tanpa Data Augmentation	48
4.4.1	<i>Training from Scratch</i> Tanpa Data Augmentation	48
4.4.2	<i>Transfer Learning</i> Tanpa Data Augmentation	49
4.5	Analisis Hasil Pelatihan Model	50
4.5.1	Pengaruh Data Augmentation terhadap Kinerja Model	50
4.5.2	Perbandingan <i>Training from Scratch</i> dan <i>Transfer Learnin</i> dengan data Augmentation	51
4.5.3	Perbandingan Penggunaan dan Tanpa Penggunaan Data Augmentation	52
4.5.4	Peran Data Augmentation dalam Mengurangi <i>Overfitting</i>	53
4.6	Hasil Implementasi Aplikasi <i>Mobile</i>	54
4.6.1	Gambaran Umum Aplikasi	54
4.6.2	Halaman Beranda	55
4.6.3	Halaman Identifikasi Kemenyan	55
4.6.4	Halaman Riwayat Identifikasi	56
4.6.5	Halaman Profil Pengguna	57
4.7	Pengujian Fungsional Aplikasi	58
4.7.1	Tujuan Pengujian Fungsional	58
4.7.2	Hasil Pengujian Fungsional Aplikasi	58
BAB V KESIMPULAN DAN SARAN		60
5.1	Kesimpulan	60
5.2	Saran	60
DAFTAR PUSTAKA		62
DAFTAR LAMPIRAN		66

DAFTAR TABEL

Tabel 2. 1 <i>Confusion Matrix</i>	24
Tabel 2. 2 Penelitian Terdahulu	27
Tabel 3. 1 <i>Split Data</i>	32
Tabel 3. 2 <i>Hyperparameter</i>	33
Tabel 3. 3 Skenario Eksperimen Pelatihan Model	35
Tabel 3. 4 <i>Mockup Mobile KemenyanScan</i>	40
Tabel 3. 5 Akuisisi Dataset	42
Tabel 3. 6 Perbandingan <i>Training from scratch</i> dan <i>Transfer Learning</i> dengan <i>augmentation</i>	51
Tabel 3. 7 Perbandingan <i>Training From Scratch</i> dan <i>Transfer Learning</i> tanpa <i>augmentation</i>	52



DAFTAR GAMBAR

Gambar 2. 1 Proses Konvolusi	11
Gambar 2. 2 Proses <i>Max Pooling</i>	12
Gambar 2. 3 Alur kerja CNN	13
Gambar 2. 4 GoogleNet Model	15
Gambar 2. 5 Arsitektur Inception V3	17
Gambar 2. 6 Kemenyan Kualitas Tinggi	22
Gambar 2. 7 Kemenyan Kualitas Sedang	22
Gambar 2. 8 Kemenyan Kualitas Rendah	23
Gambar 3 1 Kerangka Penelitian	29
Gambar 3 2 Alur aplikasi	38
Gambar 4 1 Grafik <i>Training from Scratch</i> dengan Data <i>Augmentation</i>	46
Gambar 4 2 <i>Confusion Matrix Training From Stracth</i> Dengan <i>Augmentation</i>	47
Gambar 4 3 Grafik <i>Transfer Learning</i> dengan Data <i>Augmentation</i>	47
Gambar 4 4 <i>Confusion Matrix Transfer Learning</i> dengan <i>Augmentation</i>	48
Gambar 4 5 Grafik <i>Training from Scratch</i> Tanpa Data <i>Augmentation</i>	48
Gambar 4 6 <i>Confusion Matrix Training From Stracth</i> Tanpa <i>Augmentation</i>	49
Gambar 4 7 Grafik <i>Transfer Learning</i> Tanpa Data <i>Augmentation</i>	49
Gambar 4 8 <i>Confusion Matrix Transfer Learning</i> Tanpa <i>Augmentation</i>	50
Gambar 4 9 Halaman Beranda	55
Gambar 4 10 Halaman Identifikasi	56
Gambar 4 11 Halaman Riwayat Identifikasi	57
Gambar 4 12 Halaman Profil Pengguna	57
Gambar 4 13 Hasil Klasifikasi kualitas Tinggi	56
Gambar 4 14 Hasil Klasifikasi kualitas Sedang	56
Gambar 4 15 Hasil Klasifikasi kualitas Rendah	56

BAB I

PENDAHULUAN

1.1 Latar Belakang

Getah kemenyan (*Styrax spp.*) merupakan salah satu hasil hutan bukan kayu yang memiliki nilai ekonomi sekaligus nilai budaya yang cukup besar bagi masyarakat di berbagai daerah di Indonesia. Resin ini banyak dimanfaatkan sebagai bahan baku parfum, dupa, kosmetik, hingga aromaterapi, sehingga peluang pasarnya cukup luas baik untuk kebutuhan lokal maupun ekspor. Penelitian terbaru oleh (Susanti dkk. 2025) menunjukkan bahwa kemenyan masih menjadi sumber penghasilan penting bagi masyarakat penghasilnya karena pemanfaatannya yang beragam. Temuan ini diperkuat oleh studi (Sunarti dkk. 2025b) yang mengungkapkan bahwa komponen kimia dalam resin kemenyan asal Sumatera Utara memiliki potensi tinggi untuk dikembangkan sebagai produk bernilai tambah. Sementara itu, penelitian (Ura dkk. 2023) terkait pertumbuhan dan karakteristik bibit kemenyan juga menegaskan bahwa komoditas ini memiliki prospek pengelolaan jangka panjang. Kemenyan masih menjadi bagian dari kehidupan banyak keluarga penadap, khususnya Kabupaten Tapanuli Utara Sumatera Utara, meski proses pengolahan dari penadapan hingga penyimpanan umumnya masih dikerjakan secara tradisional, sehingga mutu resin yang dihasilkan sering kali tidak seragam dan harga yang diterima petani pun ikut bervariasi.

Penilaian mutu getah kemenyan di lapangan selama ini masih dilakukan secara manual berdasarkan tampilan visual seperti warna, kejernihan, kekerasan,

serta ukuran butiran. Cara penilaian seperti ini cukup rentan terhadap subjektivitas, terutama jika dilakukan oleh orang yang berbeda atau pada kondisi pencahayaan yang tidak konsisten. Dampaknya, getah yang sebenarnya berkualitas baik dapat dinilai rendah dan membuat petani menerima harga yang tidak sesuai. Penelitian terbaru oleh (Abduh dkk. 2022b) dan (Sunarti dkk. 2025b) menunjukkan bahwa kualitas getah dapat dikenali melalui ciri fisik dan kimia, seperti kadar resin dan kandungan asam sinamat, yang juga tercermin pada tampilan visualnya. Temuan ini menegaskan bahwa klasifikasi berbasis citra digital sebenarnya sangat memungkinkan dilakukan karena indikator mutunya tampak secara visual. Jika metode subjektif tetap dipertahankan, potensi ketidakadilan harga, lemahnya posisi tawar petani, dan sulitnya standarisasi mutu kemenyan akan terus terjadi.

Seiring berkembangnya teknologi, penggunaan citra digital yang dipadukan dengan metode *deep learning* khususnya *Convolutional Neural Network* (CNN) telah banyak diterapkan dalam berbagai penelitian pertanian. CNN terbukti mampu mengidentifikasi pola visual kompleks seperti warna, tekstur, bentuk, dan permukaan objek tanpa memerlukan perancangan fitur manual. Beberapa studi terkini menunjukkan efektivitas CNN dalam pengklasifikasian hasil pertanian, misalnya penentuan kualitas buah (Descriptor dkk. 2021), deteksi penyakit tanaman (Goła dkk. 2020), serta penilaian mutu biji dan rempah (Wulandari dkk. 2020). Keberhasilan ini menjadi bukti bahwa pendekatan berbasis CNN sangat memungkinkan diterapkan untuk mengklasifikasikan kualitas getah kemenyan yang memiliki variasi bentuk dan tekstur cukup kompleks.

Dari berbagai jenis arsitektur CNN yang ada, GoogLeNet dan versi pengembangannya Inception V3 menjadi salah satu model yang paling banyak

dipakai dalam penelitian berbasis citra. Hal ini karena model tersebut dikenal mampu memberikan akurasi yang tinggi sambil tetap efisien secara komputasi. Beberapa penelitian terbaru juga menunjukkan keberhasilan penggunaan Inception V3, misalnya untuk menentukan tingkat kematangan tomat (Iqbal dkk. 2023) menilai kualitas beras (Xia dkk) ,dan mengidentifikasi mutu daging (Harahap dkk. 2024) . Lewat pendekatan *transfer learning*, model ini tetap dapat bekerja dengan baik meskipun jumlah data tidak terlalu banyak, sehingga sangat sesuai diterapkan pada penelitian citra lapangan seperti penilaian mutu getah kemenyan.

Berdasarkan permasalahan tersebut, pemanfaatan arsitektur Inception V3 dalam pendekatan *deep learning* dinilai relevan untuk diterapkan pada klasifikasi kualitas getah kemenyan. Inception V3 memiliki karakteristik utama berupa kemampuan ekstraksi fitur yang baik dengan kebutuhan komputasi yang relatif efisien. Walaupun penerapan *Convolutional Neural Network* (CNN) telah banyak digunakan pada penelitian klasifikasi kualitas buah maupun bagian tanaman lainnya, kajian yang secara spesifik mengangkat klasifikasi mutu getah kemenyan berbasis citra digital masih sangat terbatas. Oleh sebab itu, penelitian ini dilakukan untuk mengisi kekosongan tersebut dengan merancang sistem klasifikasi kualitas getah kemenyan menggunakan arsitektur Inception V3, yang diuji menggunakan data citra yang diperoleh dari Desa Sibaganding, Kecamatan Pahae Julu, Kabupaten Tapanuli Utara.

Selanjutnya, penelitian ini tidak hanya berfokus pada penerapan *transfer learning*, tetapi juga melakukan perbandingan dengan metode pelatihan model dari awal (*training from scratch*) serta mengevaluasi pengaruh penerapan data

augmentation terhadap kinerja model. Analisis ini bertujuan untuk mengetahui pendekatan pelatihan yang paling optimal dalam menghasilkan model klasifikasi kualitas getah kemenyan yang akurat dan objektif. Hasil dari penelitian ini diharapkan dapat menghasilkan model yang layak untuk diimplementasikan pada perangkat *mobile* sebagai alat bantu penilaian mutu getah kemenyan secara langsung di lapangan. Dengan adanya sistem tersebut, proses penilaian mutu diharapkan menjadi lebih efisien, konsisten, dan mampu meminimalkan subjektivitas yang sering muncul pada metode penilaian manual.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan sebelumnya, dapat dirumuskan beberapa permasalahan yang akan dibahas dalam penelitian ini, yaitu:

1. Bagaimana cara menerapkan arsitektur Inception V3 untuk melakukan klasifikasi kualitas getah kemenyan berdasarkan citra digital?
2. Bagaimana pengaruh metode pelatihan (*training from scratch* dan *transfer learning*) serta penggunaan data *augmentation* terhadap performa model klasifikasi kualitas getah kemenyan?
3. Seberapa baik performa model yang dihasilkan dalam mengklasifikasikan kualitas getah kemenyan berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*?

1.3 Batasan Masalah

Agar penelitian ini lebih terarah dan fokus, maka ruang lingkup penelitian dibatasi pada hal-hal berikut:

1. Penelitian hanya berfokus pada getah kemenyan dengan dataset yang berasal dari Desa Sibaganding, Kecamatan Pahae Julu, Kabupaten Tapanuli Utara .
2. Data penelitian berupa citra digital hasil akuisisi mandiri terhadap getah kemenyan dengan variasi tingkat kualitas.
3. Total dataset yang digunakan berjumlah 1.500 citra, yang kemudian dibagi menjadi 70% data latih (*training*), 15% data uji (*testing*), dan 15% data validasi (*validation*).
4. Model *deep learning* yang digunakan adalah Inception V3 dengan metode *Training From Scratch* dan *transfer learning*.
5. Aspek penilaian mutu yang dianalisis difokuskan pada tampilan visual, seperti warna, tekstur, kejernihan, dan bentuk butiran getah.
6. Penelitian ini tidak membahas aspek kimia, aroma, atau komposisi zat penyusun getah.

1.4 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut :

1. Mengembangkan sistem klasifikasi kualitas getah kemenyan berbasis citra menggunakan algoritma Inception V3.
2. Menghasilkan aplikasi *mobile* untuk klasifikasi kualitas kemenyan secara otomatis
3. Menganalisis dan membandingkan performa model dengan pendekatan *training from scratch* dan *transfer learning* serta penggunaan data *augmentation*.

4. Menentukan model terbaik berdasarkan hasil evaluasi menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*.
5. Memberikan alternatif metode penilaian mutu yang lebih objektif, cepat, dan efisien dibandingkan metode manual yang selama ini digunakan oleh petani atau pengepul.

1.5 Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat dari sisi teoritis maupun praktis, yaitu:

1. Manfaat Teoritis
 - a. Menambah referensi ilmiah dalam penerapan *Convolutional Neural Network* (CNN) khususnya Inception V3 dalam bidang pengolahan citra pertanian.
 - b. Menjadi dasar bagi penelitian lanjutan dalam topik klasifikasi mutu hasil hutan bukan kayu (HHBK) berbasis citra digital
2. Manfaat Praktis
 - a. Memberikan solusi teknologi yang bisa membantu petani dan pelaku usaha kemenyan dalam menentukan kualitas getah secara lebih objektif dan konsisten.
 - b. Membantu pemerintah daerah dan lembaga penelitian dalam menyusun standar mutu kemenyan yang terukur dan berbasis data digital
 - c. Mendorong peningkatan nilai jual dan daya saing produk kemenyan lokal di pasar nasional maupun internasional.

BAB II

TINJAUAN PUSTAKA

2.1 Citra Digital

Menurut (Qi dkk. 2023) citra digital pada dasarnya merupakan representasi visual dari suatu objek yang disimpan dalam bentuk data numerik, di mana setiap titik gambar (*piksel*) memiliki nilai intensitas tertentu yang menunjukkan warna atau kecerahan. Nilai-nilai tersebut disusun dalam bentuk matriks dua dimensi sehingga komputer dapat memproses, menganalisis, dan menampilkan kembali gambar tersebut secara digital. Citra digital bisa diartikan sebagai gambar yang tersusun dari kumpulan titik-titik kecil (*piksel*) yang masing-masing menyimpan informasi warna atau tingkat kecerahan. Karena semua nilai diubah menjadi angka, gambar ini bisa diolah oleh komputer untuk berbagai tujuan, misalnya pengenalan pola, peningkatan kualitas gambar, sampai klasifikasi objek seperti yang dilakukan pada penelitian ini.

2.2 Pengolahan Citra Digital

Berdasarkan (Alappat dkk. 2021) menyebutkan bahwa pengolahan citra digital adalah rangkaian tahapan yang bertujuan menyiapkan dan memperbaiki gambar agar layak dianalisis oleh sistem komputer. Secara umum prosesnya meliputi:

(1) pra-pemrosesan, yaitu langkah-langkah seperti normalisasi nilai piksel, penyamaan ukuran gambar (*resize*), dan augmentasi data untuk memperkaya variasi sampel sehingga model tidak mudah mengalami *overfitting*

(2) ekstraksi fitur, yakni pengambilan ciri-ciri penting dari citra seperti warna, tekstur, dan bentuk yang pada pendekatan modern umumnya dilakukan secara otomatis oleh jaringan saraf konvolusional (CNN) dan

(3) klasifikasi, yaitu tahap akhir di mana fitur yang telah diekstraksi dipetakan ke kelas-kelas target (misal: kualitas tinggi, sedang, rendah).

Tahapan pra-pemrosesan citra diimplementasikan menggunakan pustaka *PyTorch* melalui modul *torchvision.transforms*, yang mencakup proses *resize*, normalisasi, serta data *augmentation*. Seluruh citra distandarkan pada ukuran 299×299 piksel agar sesuai dengan arsitektur Inception V3. Proses ini diterapkan baik pada skenario *training from scratch*, di mana seluruh parameter model dilatih dari awal, maupun pada skenario *transfer learning*, di mana bobot pra-latih digunakan sebagai dasar pembelajaran model.

2.3 Klasifikasi

Menurut (Alzubaidi dkk. 2021) klasifikasi merupakan proses mengelompokkan suatu objek ke dalam kelas tertentu berdasarkan karakteristik atau pola yang dimilikinya. Klasifikasi dilakukan untuk mengenali atau menentukan label dari gambar sesuai dengan ciri visualnya. Pada penelitian ini, klasifikasi digunakan untuk membedakan kualitas getah kemenyan menjadi tiga kelas, yaitu tinggi, sedang, dan rendah, berdasarkan tampilan citra getah tersebut. Metode klasifikasi modern banyak memanfaatkan pendekatan *machine learning* dan *deep learning*. Model akan belajar dari data pelatihan yang sudah diberi label, kemudian digunakan untuk menebak kelas pada data baru. Salah satu pendekatan yang paling banyak dipakai untuk klasifikasi citra adalah *Convolutional Neural*

Network (CNN), karena mampu mendeteksi pola visual yang kompleks secara otomatis tanpa perlu ekstraksi fitur manual.

2.4 *Deep Learning*

Deep Learning adalah cabang dari *machine learning* yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan untuk mempelajari pola dari data. Keunggulan utama pendekatan ini adalah kemampuannya mengenali fitur penting langsung dari data mentah tanpa memerlukan proses ekstraksi fitur secara manual. *Deep learning* sangat efektif karena mampu mengidentifikasi pola visual dari bentuk sederhana seperti tepi dan warna hingga bentuk kompleks seperti objek dan tekstur. Model yang paling banyak digunakan di bidang ini adalah *Convolutional Neural Network* (CNN) yang menjadi dasar bagi arsitektur-arsitektur lanjutan seperti Inception V3 (Mohamed dkk. 2022). Dengan karakteristik tersebut, *deep learning* menjadi metode yang banyak dipakai di berbagai bidang, seperti pengenalan wajah, diagnosis medis berbasis citra, serta penilaian kualitas bahan alam termasuk getah kemenyan.

2.5 *Convolutional Neural Network*

Convolutional Neural Network atau sering disingkat CNN, merupakan salah satu jenis jaringan saraf tiruan yang dirancang khusus untuk mengolah data citra dua dimensi. Menurut (Togawa dkk. 2025) CNN bekerja dengan cara mengenali pola visual yang terdapat pada gambar melalui proses *convolution* dan *pooling* secara bertahap, sehingga mampu mengekstraksi ciri-ciri penting (fitur) dari gambar secara otomatis tanpa perlu rekayasa fitur manual. Struktur CNN

umumnya terdiri dari beberapa jenis lapisan (*layer*) yang saling berhubungan dan memiliki peran berbeda-beda, antara lain:

- a. *Convolutional Layer* adalah lapisan utama dalam CNN yang bertugas mengekstrak fitur-fitur dasar dari gambar masukan. Cara kerjanya memakai filter (*kernel*) yang ditempatkan di berbagai lokasi pada citra, kemudian melakukan operasi perkalian elemen per elemen antara nilai piksel dan bobot kernel, lalu dijumlahkan untuk menghasilkan satu nilai output. Nilai output inilah yang nanti membentuk map fitur (*feature map*) yang menggambarkan pola visual, seperti tepi, tekstur, atau perubahan warna, dan rumus dapat dilihat pada persamaan (2.1):

Persamaan dan contoh operasi dari konvolusi:

$$s(t) = (x * w)(t) \quad (2.1)$$


keterangan :

$s(t)$ = Fungsi hasil operasi konvolusi

x = input

w = bobot (kernel)

Nilai $s(t)$ merupakan hasil tunggal pada setiap pergeseran kernel terhadap input. Jadi, ketika filter digeser ke seluruh bagian gambar, akan terbentuk peta nilai baru yang disebut feature map. Semakin banyak filter yang digunakan, semakin beragam fitur yang bisa dikenali oleh jaringan seperti yang ditampilkan pada gambar 2.1 berikut:



Gambar 2. 1 Proses Konvolusi

b. *Activation Layer (ReLU - Rectified Linear Unit)*

Setelah proses konvolusi, hasilnya akan masuk ke fungsi aktivasi seperti ReLU. Fungsi ini bertujuan menambahkan sifat non-linear pada model, supaya jaringan mampu mengenali pola yang lebih kompleks. Secara sederhana, ReLU akan mengubah semua nilai negatif menjadi nol dengan rumus persamaan (2.2) :

$$f(x) = \max(0, x) \quad (2.2)$$

c. *Pooling layer*

Pooling layer berfungsi untuk mengurangi ukuran data (*dimensionality reduction*) tanpa menghilangkan informasi penting. Jenis yang paling umum dipakai adalah *Max Pooling*, yaitu mengambil nilai maksimum dari area kecil (misalnya 2×2 piksel). Tujuannya adalah memperkecil beban komputasi, mempercepat pelatihan, serta membuat model lebih tahan terhadap perubahan posisi atau rotasi objek di dalam gambar.



Gambar 2. 2 Proses *Max Pooling*

d. *Dropout Layer*

Lapisan ini sering digunakan untuk mencegah *overfitting*. Dropout bekerja dengan cara mematikan beberapa neuron secara acak selama proses pelatihan, sehingga jaringan tidak terlalu bergantung pada satu pola fitur tertentu. Nilai dropout biasanya antara 0.3–0.5 (Zafar dkk. 2024).

e. *Fully Connected Layer (Dense Layer)*

Lapisan ini berada di bagian akhir jaringan dan berfungsi untuk melakukan klasifikasi berdasarkan fitur yang sudah diekstrak dari lapisan-lapisan sebelumnya. Semua neuron pada lapisan ini terhubung dengan neuron di lapisan sebelumnya. Pada tahap ini, hasil akhir biasanya diolah menggunakan fungsi aktivasi *Softmax*, yang mengubah keluaran menjadi nilai probabilitas untuk tiap kelas, misalnya kualitas tinggi, sedang, atau rendah.

Secara sederhana, urutan kerja CNN bisa digambarkan seperti ini:



Gambar 2. 3 Alur kerja CNN

Setiap lapisan dalam CNN memiliki peran yang saling melengkapi yaitu lapisan awal berfokus pada pola sederhana seperti tepi dan warna, sementara lapisan yang lebih dalam mampu mengenali bentuk yang lebih kompleks, seperti tekstur khas pada getah kemenyan. Dengan struktur berlapis seperti ini, CNN terbukti sangat efektif dalam tugas-tugas pengenalan dan klasifikasi citra.

2.6 Arsitektur GoogLeNet dan Inception V3

2.6.1 Sejarah Singkat GoogLeNet

GoogLeNet yang kadang disebut Inception v1, dikembangkan oleh tim Google Research yang dipimpin Christian Szegedy (Salehin, 2023). Ide inti dari arsitektur ini adalah *Inception module* blok yang menjalankan beberapa ukuran konvolusi secara paralel (misalnya 1×1 , 3×3 , dan 5×5) lalu menggabungkan


hasilnya. Pendekatan ini memungkinkan jaringan menangkap fitur pada banyak skala tanpa membengkakkan jumlah parameter sehingga tetap efisien dari sisi komputasi. Versi pertama (/Inception v1) langsung menunjukkan performa bagus di kompetisi *ImageNet* 2014 dan menjadi tonggak penting dalam desain CNN modern (Zhao dkk. 2024).

Setelah itu, arsitektur Inception terus disempurnakan. Di Inception-v2 dan v3, peneliti memperkenalkan beberapa pembaruan teknis penting seperti *factorized convolutions* (memecah kernel besar jadi beberapa kernel kecil untuk mengurangi biaya komputasi), penerapan *batch normalization* untuk menstabilkan dan mempercepat pelatihan, serta teknik regularisasi seperti *label smoothing* agar model tidak menjadi terlalu yakin pada label satu-hot. Semua perubahan ini membuat Inception-v3 lebih akurat dan lebih stabil saat dilatih pada dataset besar (Tanbin dkk. 2025).

Selanjutnya ada pengembangan yang menggabungkan ide Inception dengan *residual connections* (konsep dari ResNet), yang melahirkan varian seperti Inception-ResNet dan Inception-v4. Perpaduan ini mempercepat pelatihan jaringan yang sangat dalam dan sedikit meningkatkan performa lagi dibanding versi non-residual. Intinya, rangkaian pengembangan Inception menunjukkan evolusi desain CNN yang fokus pada efisiensi komputasi sambil mempertahankan atau meningkatkan akurasi (Fakhrabadi dkk. 2025).

2.6.2 GoogLeNet

Menurut (Yu dkk. 2024) GoogLeNet adalah salah satu desain jaringan saraf konvolusional (CNN) yang dikembangkan oleh tim Google Research. Ide utamanya bukan sekadar menambah jumlah lapisan, melainkan merancang blok khusus yang disebut Inception module yang menjalankan beberapa ukuran konvolusi secara paralel (mis. 1×1 , 3×3 , 5×5) dan kemudian menggabungkan hasilnya. Dengan cara itu jaringan bisa melihat fitur pada berbagai skala sekaligus tanpa membuat model jadi terlalu besar. Selain itu, GoogLeNet memakai trik seperti konvolusi 1×1 sebagai lapisan pengurang dimensi dan *global average pooling* di akhir jaringan supaya parameter berkurang dan *overfitting* bisa diminimalkan. Pendekatan ini membuat GoogLeNet jauh lebih efisien daripada arsitektur sebelumnya (mis. AlexNet), sekaligus meningkatkan akurasi pada tugas klasifikasi gambar skala besar seperti *ImageNet*.



Gambar 2. 4 GoogLeNet Model


Gambar 2.4 menjelaskan alur kerja model CNN berbasis Inception dalam mengklasifikasikan kualitas getah kemenyan menjadi tiga kategori, yaitu kualitas tinggi, sedang, dan rendah. Proses dimulai dari citra input yang sudah melalui

tahap prapemrosesan, lalu masuk ke *layer* konvolusi awal (Conv1 dan Conv2) untuk mengekstraksi fitur dasar seperti tepi, tekstur, dan pola sederhana. Setelah itu dilakukan *max pooling* untuk mengurangi ukuran fitur agar proses komputasi lebih efisien. Selanjutnya, citra diproses melalui beberapa modul Inception (3a sampai 5b) yang bekerja dengan melakukan konvolusi secara paralel menggunakan berbagai ukuran kernel sehingga model dapat menangkap fitur dalam berbagai skala, baik detail kecil maupun pola yang lebih kompleks. Di beberapa bagian juga diterapkan *max pooling* untuk membantu mengurangi dimensi dan meminimalkan risiko *overfitting*. Pada tahap akhir, fitur yang dihasilkan diringkas menggunakan *global average pooling* menjadi bentuk vektor, kemudian diterapkan *dropout* sebesar 40% untuk meningkatkan kemampuan generalisasi model. Output akhirnya diproses dengan fungsi aktivasi *softmax* yang menghasilkan nilai probabilitas untuk masing-masing kelas, dan kelas dengan probabilitas tertinggi akan menjadi hasil prediksi kualitas kemenyan.

2.6.3 Inception V3

Inception V3 adalah pengembangan dari arsitektur GoogLeNet yang dibuat oleh tim Google Research. Inti peningkatannya adalah membagi operasi konvolusi besar menjadi rangkaian konvolusi kecil yang disebut *factorized convolution* dan menambahkan *batch normalization* agar proses pelatihan lebih stabil dan cepat konvergen (Fariza, 2024). Pendekatan ini membuat model tetap akurat tetapi lebih hemat komputasi. Secara struktur, Inception V3 diawali oleh stem yang menyiapkan citra input, lalu berlanjut ke beberapa blok *Inception* mulai dari *Inception-A* (beberapa blok untuk menangkap fitur dasar dengan kombinasi konvolusi 1×1 ,

3×3 , 5×5), dilanjutkan *grid size reduction* untuk mengecilkan ukuran fitur. Bagian tengah berisi Inception-B yang memakai konvolusi ter-faktorisasi (mis. 1×7 dan 7×1) untuk efisiensi, lalu ada reduksi *grid* lagi, dan diakhiri Inception-C yang merangkum fitur kompleks sebelum tahap akhir. Ada juga *auxiliary classifier* di tengah jaringan untuk membantu distribusi gradien saat pelatihan. Pada tahap akhir arsitektur, fitur diringkas lewat *global average pooling*, lalu keluaran diproses oleh *softmax* untuk menentukan kelas, misalnya kualitas getah terdiri dari tinggi, sedang, atau rendah. Berdasarkan struktur arsitektur yang digunakan, Inception V3 mampu mencapai akurasi tinggi pada tugas klasifikasi berskala besar sambil menjaga jumlah parameter relatif efisien (Naveen & Cholli, 2024).



Gambar 2. 5 Arsitektur Inception V3

2.7 Transfer Learning

Transfer Learning adalah teknik pelatihan model *deep learning* dengan memanfaatkan pengetahuan dari model lain yang sudah dilatih sebelumnya (*pre-trained model*). Konsep ini memungkinkan model baru belajar lebih cepat karena sebagian besar bobotnya sudah terlatih dari dataset besar seperti *ImageNet*.

Selanjutnya, hanya lapisan akhir yang disesuaikan (*fine-tuning*) agar sesuai dengan dataset penelitian. Keuntungan utama *transfer learning* adalah mempercepat waktu pelatihan, meningkatkan akurasi, dan mengurangi risiko *overfitting* (Yamaguchi dkk. 2025). Dalam penelitian ini, digunakan model Inception V3 yang telah dilatih di ImageNet dan kemudian disesuaikan untuk mengklasifikasi kualitas getah kemenyan menjadi tiga kelas.

2.8 *Training from scratch*

Training from scratch adalah pendekatan pelatihan jaringan saraf dalam di mana seluruh parameter model dilatih dari kondisi awal tanpa menggunakan bobot hasil pelatihan sebelumnya. Pendekatan ini menempatkan dataset penelitian sebagai satu-satunya sumber pembelajaran fitur, sehingga model membangun representasi visual sepenuhnya berdasarkan karakteristik data yang digunakan (Marchenko dkk. 2021).

(Marchenko dkk. 2021) secara khusus mengevaluasi efektivitas pelatihan dari awal dibandingkan penggunaan model pra-latih dan menunjukkan bahwa pada kondisi tertentu, terutama ketika dataset cukup *representatif* atau memiliki perbedaan domain yang signifikan, *training from scratch* mampu menghasilkan performa yang sebanding dengan *transfer learning*.

Pada *training from scratch*, proses pembelajaran fitur berlangsung secara hierarkis, dimulai dari ekstraksi fitur tingkat rendah seperti tepi dan tekstur, hingga fitur tingkat tinggi yang merepresentasikan bentuk dan struktur objek. Proses ini memungkinkan model menyesuaikan fitur yang dipelajari dengan

domain data yang spesifik, namun juga menuntut jumlah data yang memadai agar proses generalisasi berjalan optimal (Steiner dkk. 2022).

Training from scratch memiliki keunggulan utama dalam membentuk fitur yang benar-benar sesuai dengan karakteristik data penelitian. Apabila data yang digunakan memiliki ciri visual yang berbeda jauh dari dataset umum, penggunaan model pra-latih berpotensi menghasilkan fitur yang kurang relevan karena adanya perbedaan domain. Dalam kondisi seperti ini, pelatihan model dari awal memungkinkan jaringan saraf mempelajari pola visual yang lebih spesifik dan sesuai dengan objek yang diklasifikasikan, sehingga berpeluang memberikan hasil klasifikasi yang lebih akurat pada domain tertentu.

Hasil analisis menunjukkan bahwa *training from scratch* bukanlah pendekatan yang lebih rendah dibandingkan *transfer learning*, melainkan metode alternatif yang relevansinya ditentukan oleh kondisi dan sifat data yang digunakan dalam penelitian. Metode ini menjadi lebih relevan ketika dataset yang digunakan bersifat spesifik, memiliki jumlah yang cukup, serta disusun dengan kualitas data yang baik. Oleh karena itu dalam penelitian ini, *training from scratch* digunakan sebagai salah satu metode pembandingan untuk mengkaji pengaruh perbedaan pendekatan pelatihan terhadap kinerja klasifikasi citra.

2.9 Pengaruh Data Augmentasi Pada CNN

Data augmentasi merupakan teknik yang digunakan untuk menambah variasi data latih dengan melakukan perubahan tertentu pada citra, seperti rotasi, pencerminan, dan perubahan skala, tanpa mengubah label aslinya. Teknik ini bertujuan untuk membantu model *Convolutional Neural Network* (CNN) agar

mampu mengenali objek dalam kondisi visual yang lebih beragam sehingga kemampuan generalisasi model dapat meningkat (Shorten dkk. 2021).

Pada proses pelatihan CNN, salah satu permasalahan yang sering muncul, terutama pada dataset berukuran kecil, adalah *overfitting*. Kondisi ini terjadi ketika model terlalu menyesuaikan diri dengan data latih sehingga performanya menurun saat dihadapkan pada data baru. Data *augmentation* dapat berperan sebagai solusi untuk mengurangi *overfitting* karena model dilatih menggunakan data dengan variasi yang lebih luas, meskipun berasal dari dataset yang sama (Baur dkk).

Penggunaan data augmentasi menjadi semakin penting ketika jumlah data yang tersedia terbatas. Dengan menambahkan variasi citra secara buatan, model tidak hanya menghafal pola tertentu, tetapi belajar mengenali karakteristik objek secara lebih umum. Hal ini berdampak pada peningkatan stabilitas performa model CNN terhadap perubahan sudut pandang, pencahayaan, maupun orientasi objek (Hernandez-garcia dkk. 2020).

Sejalan dengan hal tersebut, data *augmentasi* diuji dan dibandingkan sebagai salah satu variabel untuk mengetahui pengaruhnya terhadap kinerja model CNN. Pengujian dilakukan untuk melihat apakah penerapan data *augmentation* mampu meningkatkan performa klasifikasi, baik pada skenario pelatihan *training from scratch* maupun *transfer learning*, sehingga dapat diperoleh strategi pelatihan yang paling sesuai dengan karakteristik dataset yang digunakan (Shorten dkk. 2021).

2.10 Kemenyan

Kemenyan merupakan getah alami yang dihasilkan oleh pohon *Styrax sumatrana*, tanaman yang banyak ditemukan di wilayah Tapanuli, Sumatera Utara. Getah ini telah lama dimanfaatkan untuk berbagai keperluan, seperti bahan baku parfum, obat, hingga bahan ritual (Utara dkk. 2020). Mutu getah kemenyan dipengaruhi oleh kondisi lingkungan, teknik penyadapan, dan cara pengeringan. Secara umum mutu itu dibagi menjadi tiga kategori yaitu tinggi, sedang, dan rendah. Selama ini penilaian masih dilakukan secara visual melihat warna, tekstur, dan sejauh mana getah tampak bersih namun cara tradisional ini seringkali bersifat subjektif karena sangat tergantung pada pengalaman penilai. Seiring perkembangan teknologi, sekarang mulai banyak yang memakai pengolahan citra digital dan *deep learning* untuk mengotomatisasi klasifikasi mutu kemenyan. Dengan pendekatan ini sistem bisa membaca perbedaan visual misalnya tingkat kecerahan, kekasaran permukaan, dan pola warna secara konsisten, sehingga proses penilaian jadi lebih cepat, objektif, dan dapat dipercaya. Pada penelitian kali ini, penulis akan menggunakan objek kemenyan dengan 3 kategori kualitas (tinggi, sedang, rendah) untuk pengklasifikasian yakni :

2.10.1 Jenis-jenis Kualitas Kemenyan Berdasarkan Citra

1. Kemenyan kualitas tinggi

Menurut (Kholibrina et al., 2025) , jenis kemenyan kualitas tinggi memiliki ciri fisik yaitu warna putih kekuningan hingga transparan, tampak bersih, keras dan memiliki permukaan halus. Umumnya berasal dari getah murni tanpa banyak kotoran dan mengandung banyak atsiri tinggi, citra getah kualitas tinggi

tampak cerah dengan kontras tinggi dan tekstur padat seperti pada gambar dibawah ini :



Gambar 2. 6 Kemenyan Kualitas Tinggi

2. Kemenyan kualitas sedang

Menurut (Abduh dkk. 2022a) jenis kemenyan kualitas sedang memiliki ciri fisik yaitu warna kekuningan hingga kecokelatan, agak keruh, dan terdapat sedikit kotoran pada permukaan. Teksturnya sedikit kasar namun masih cukup padat. Berdasarkan citra, getah sedang memiliki gradasi warna yang tidak seragam dengan kombinasi kuning dan coklat muda.



Gambar 2. 7 Kemenyan Kualitas Sedang

3. Kemenyan kualitas rendah

Menurut (Abduh dkk. 2022a) jenis kemenyan kualitas rendah memiliki ciri fisik yaitu warna gelap hingga coklat tua, tekstur lembek atau mudah hancur, dan

banyak mengandung serpihan atau kotoran. Umumnya berasal dari hasil sadapan lama atau tercampur bahan lain. Pada citra digital, kemenyan kualitas rendah tampak kurang mengkilap, warnanya gelap, dan teksturnya tidak merata, sebagaimana ditunjukkan pada gambar 2.7.



Gambar 2. 8 Kemenyan Kualitas Rendah

2.11 Fungsi *Loss* dan *Optimizer*

Dalam pelatihan model CNN, kita perlu mengukur seberapa jauh prediksi model terhadap label sebenarnya itulah fungsi *loss*. Untuk kasus klasifikasi dengan tiga kelas (tinggi, sedang, rendah), fungsi *loss* yang umum dipakai adalah *Categorical Cross-Entropy*, yang secara matematis ditulis dalam persamaan 2.3 :

$$L = - \sum_{i=1}^N y_1 \log (\hat{y}_1) \quad (2.3)$$

Disini, y_1 adalah label asli (*one-hot*) dan $\hat{y}_1$ adalah probabilitas yang diprediksi model untuk kelas ke-i. Intinya, semakin besar perbedaan antara prediksi dan label, nilai *loss* akan semakin besar, sehingga selama *training model* berusaha meminimalkan nilai ini (Gordon-rodriguez dkk. 2020). Untuk mengoptimalkan selama *training*, penelitian ini memakai *Adam Optimizer* karena

sifatnya adaptif terhadap *learning rate* sehingga proses konvergensi biasanya lebih cepat dan stabil. Parameter yang dipakai pada eksperimen ini antara lain: *learning rate* $\alpha = 0,0001$, $\beta_1 = 0,9$ dan $\beta_2 = 0,999$.

2.12 Evaluasi Kinerja Model

Untuk menilai seberapa baik model bekerja, kita tidak hanya melihat akurasi saja, tetapi juga *metric* lain yang lebih informatif. Dua alat evaluasi utama yang digunakan disini adalah *confusion matrix* dan *precision-recall curve*.

2.12.1 Confusion Matrix

Confusion matrix menunjukkan perbandingan antara label sebenarnya dan prediksi model. Untuk tiga kelas (tinggi, sedang, rendah) bentuknya dapat ditampilkan seperti table 2.1 dibawah :

Tabel 2. 1 *Confusion Matrix*

Prediksi	Tinggi	Sedang	Rendah
Tinggi	TP	FP	FI
Sedang	FN	TP	FI
rendah	FN	FN	TI

Dari matrix ini kita bisa menghitung metrix dasar seperti:

- Akurasi (*accuracy*) : seberapa banyak prediksi benar dari seluruh sampel.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.4)$$

- b. Presisi (*precision*) : seberapa banyak prediksi positif yang benar.

$$precision = \frac{TP}{TP + FP} \quad (2.5)$$

- c. *Recall* (*sensitivity*) : seberapa banyak data positif yang berhasil ditangkap model

$$recall = \frac{TP}{TP + FN} \quad (2.6)$$

- d. *F-1 Score* : rata-rata harmonis antara *precision* dan *recall*

$$F1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (2.7)$$

Metrik-metrik ini penting untuk mengetahui kelemahan model, misalnya apakah model ini sering salah mengklasifikasi kelas sedang menjadi rendah, atau sebaliknya.

2.12.2 Precision-Recall Curve

Precision-Recall Curve menampilkan hubungan antara *precision* dan *recall* pada setiap *threshold*. Kurva ini lebih efektif untuk data yang tidak seimbang karena memberikan perhatian lebih pada evaluasi kelas positif. Nilai AUC-PR yang lebih tinggi menandakan bahwa model mampu mengenali kelas target dengan lebih baik.

2.13 Implementasi Model Deep Learning Ke Aplikasi Mobile

Seiring berkembangnya teknologi kecerdasan buatan, khususnya di bidang *deep learning*, banyak penelitian yang tidak hanya berfokus pada pelatihan model, tetapi juga diarahkan agar dapat digunakan langsung oleh pengguna melalui

aplikasi *mobile*. Implementasi ini mempermudah pengguna dalam mengakses hasil klasifikasi tanpa perlu perangkat komputer dengan spesifikasi tinggi (Alzubaidi dkk. 2021).

Agar model *deep learning* dapat dijalankan di perangkat Android, model hasil pelatihan dikonversi ke format *TensorFlow Lite (.tflite)*. Format ini membuat ukuran model menjadi lebih kecil dan efisien, sehingga tetap bisa dijalankan di *smartphone* dengan sumber daya terbatas. Proses ini umum dilakukan setelah model seperti Inception V3 mencapai performa optimal di tahap evaluasi (Muneeb dkk. 2022).

Berdasarkan (Widad, 2024) setelah dikonversi, model diintegrasikan ke dalam aplikasi Android menggunakan Android Studio dan *library TensorFlow Lite Interpreter*. Library ini berfungsi menjalankan proses inferensi (prediksi) langsung di perangkat tanpa koneksi internet. Dengan begitu, pengguna dapat memperoleh hasil klasifikasi secara cepat dan efisien. Aplikasi ini biasanya dilengkapi dengan fitur untuk mengambil gambar secara langsung atau mengunggah dari galeri, lalu menjalankan proses klasifikasi otomatis. Hasil yang ditampilkan berupa kategori dan nilai kepercayaan (*confidence score*). Proses inferensi yang berjalan lokal memungkinkan penggunaan aplikasi tanpa koneksi internet, sehingga lebih fleksibel untuk pengguna di lapangan.

Melalui penerapan metode tersebut, hasil penelitian *deep learning* tidak hanya berhenti pada tahap akademik, tetapi juga dapat diimplementasikan secara praktis. Aplikasi *mobile* berbasis model CNN mampu membantu masyarakat dalam proses identifikasi, termasuk dalam penelitian ini untuk menilai kualitas getah kemenyan secara cepat melalui kamera ponsel (Martinez-Alpiste dkk. 2022).

2.14 Penelitian Terdahulu

Tabel 2. 2 Penelitian Terdahulu

Author	Topic	Metode	Hasil penelitian
Putra dkk, 2021	Klasifikasi Kematangan Tomat	<i>Transfer Learning</i> dengan Inception V3	Model mencapai akurasi 97,2%, stabil pada dataset kecil, dan efektif mengekstraksi fitur warna serta tekstur.
Tantri dkk, 2022	Klasifikasi Kualitas Beras	Convolutional Neural Network (CNN)	Sistem memperoleh akurasi 95,6% dalam membedakan kelas mutu beras berdasarkan ciri visual.
Gill dkk, 2022	Klasifikasi Komoditas Pertanian	Berbagai model <i>Deep Learning</i> (CNN, Inception, dll.)	Studi tinjauan menyimpulkan rata-rata akurasi model mencapai 93–98% pada berbagai komoditas pertanian dengan karakteristik visual beragam.
Abduh dkk, 2022	Identifikasi Kualitas Resin	Analisis Ciri Visual (warna, kejernihan, tekstur)	Penelitian membuktikan karakter visual resin dapat digunakan untuk klasifikasi kualitas dengan tingkat akurasi identifikasi mencapai 92%.
Purbasari dkk, 2024	Penilaian Mutu Kemenyan	Analisis Proses Penilaian Manual	Menemukan adanya subjektivitas tinggi; akurasi konsistensi antar penilai hanya 68%, sehingga diperlukan sistem otomatis berbasis citra.

Berdasarkan kajian terhadap penelitian terdahulu, sebagian besar studi yang ada cenderung berfokus pada penerapan *transfer learning* atau penggunaan CNN secara umum tanpa membandingkannya secara langsung dengan pendekatan *training from scratch*. Selain itu, penggunaan data *augmentation* sering kali tidak


dianalisis secara terpisah, melainkan hanya digunakan sebagai bagian dari proses pelatihan tanpa evaluasi khusus terhadap pengaruhnya (Steiner dkk. 2022).

Beberapa penelitian terbaru juga menunjukkan bahwa ketergantungan terhadap model pra-latih tidak selalu memberikan peningkatan performa yang signifikan, terutama ketika dataset memiliki karakteristik yang berbeda dari dataset umum seperti *ImageNet*. Hal ini mengindikasikan adanya celah penelitian terkait perbandingan metode pelatihan dan penggunaan data *augmentation* secara terpisah (Marchenko dkk. 2021).

Penelitian ini membandingkan empat skenario pelatihan, yakni *training from scratch* dan *transfer learning* baik dengan maupun tanpa penerapan data *augmentation*, guna menentukan metode yang memberikan performa paling optimal dalam klasifikasi kualitas getah kemenyan berbasis citra.

BAB III METODOLOGI PENELITIAN

3.1 Kerangka Penelitian



Gambar 3 1 Kerangka Penelitian

Gambar 3.1 menunjukkan alur penelitian yang diawali dengan tahap pengumpulan data berupa citra getah kemenyan yang diambil langsung dari lapangan menggunakan kamera digital. Setiap gambar mewakili tiga kategori mutu, yaitu mutu tinggi, sedang, dan rendah. Tahap ini menjadi dasar penting karena kualitas data sangat mempengaruhi hasil klasifikasi yang akan diperoleh di tahap akhir.

Setelah data terkumpul, dilakukan proses pembagian data (*split data*) menjadi tiga bagian utama, yaitu data *training*, *validation*, dan *testing*. Data *training* digunakan untuk melatih model agar dapat mengenali pola dan karakteristik citra getah, data *validation* dipakai untuk memantau serta menyesuaikan parameter selama proses pelatihan, sedangkan data *testing* digunakan untuk mengukur kemampuan model terhadap data baru yang belum pernah dilihat.

Tahap berikutnya adalah augmentasi data, yaitu proses memperbanyak variasi citra secara buatan dengan teknik seperti rotasi, pembalikan, *zoom*, serta penyesuaian pencahayaan. Langkah ini bertujuan agar model menjadi lebih *robust* dan mampu mengenali objek meskipun berada dalam kondisi pencahayaan atau posisi yang berbeda. Kemudian dilakukan proses *training* dan *validation* menggunakan arsitektur Inception V3. Pada tahap ini, model akan belajar mengenali fitur-fitur visual dari setiap kategori mutu getah. Proses pelatihan berlangsung hingga model mencapai kondisi konvergen, yaitu ketika performa model sudah stabil dan tidak menunjukkan peningkatan signifikan.

Apabila model belum mencapai konvergensi, dilakukan *tuning hyperparameter* untuk menyesuaikan parameter seperti *learning rate*, *batch size*, dan jumlah *epoch* agar hasil pelatihan menjadi lebih optimal. Setelah model dinilai stabil, dilanjutkan dengan tahap klasifikasi menggunakan model GoogLeNet. Tahap selanjutnya adalah evaluasi model menggunakan beberapa metrik performa seperti akurasi, *precision*, *recall*, dan *F1-score*. Evaluasi ini dilakukan untuk mengetahui sejauh mana model dapat mengklasifikasikan mutu getah dengan benar serta mengukur keandalan sistem secara keseluruhan.

Model dengan hasil terbaik kemudian diimplementasikan ke dalam aplikasi *mobile* berbasis Android. Aplikasi ini dirancang agar pengguna dapat memotret atau mengunggah citra getah kemenyan, lalu sistem secara otomatis memberikan hasil klasifikasi mutu getah berdasarkan model yang telah dilatih. Tahap terakhir adalah hasil dan analisis, yaitu proses pengujian akhir untuk memastikan bahwa sistem berjalan dengan akurasi tinggi, respon cepat, serta mudah digunakan di lapangan. Harapannya, aplikasi ini dapat membantu petani kemenyan dalam menilai mutu getah secara lebih praktis dan efisien tanpa memerlukan keahlian teknis yang rumit.

3.2 Teknik Pengumpulan Data

Data penelitian ini dikumpulkan di Desa Sibaganding, Kecamatan Pahae Julu. Pengambilan foto getah kemenyan dilakukan langsung menggunakan kamera ponsel Android dengan resolusi cukup tinggi supaya warna dan tekstur terekam jelas. Setiap potongan getah difoto dari jarak sekitar 15 cm dengan pencahayaan alami siang hari agar minim bayangan dan warna konsisten antar sampel. Semua gambar disimpan dalam format JPG dan ditata agar ukuran serta orientasinya seragam sebelum masuk tahap pelabelan dan pra-proses.

3.4 Split Data

Total dataset yang dipakai berjumlah 1.500 gambar, terbagi rata ke dalam tiga kelas mutu yaitu tinggi, sedang, dan rendah. Untuk keperluan pelatihan dan evaluasi, data dibagi secara proporsional menjadi 70% untuk *training*, 15% untuk *testing*, dan 15% untuk *validation*. Pembagian ini dilakukan supaya model

mendapat cukup data untuk belajar, sekaligus dievaluasi dan divalidasi dengan sampel yang terpisah.

Tabel 3. 1 *Split Data*

No	Kelas	<i>Training</i> (70%)	<i>Test</i> (20%)	<i>Validasi</i> (10%)	Total per kelas
1	Kemenyan kualitas Tinggi	350	75	75	500
2	Kemenyan kualitas Sedang	350	75	75	500
3	Kemenyan kualitas Rendah	350	75	75	500
Total		1050	225	225	1500

3.5 Augmentasi

Proses augmentasi data dilakukan untuk menambah keragaman citra getah kemenyan tanpa harus melakukan pengambilan data baru secara langsung. Langkah ini diperlukan agar model *deep learning* memperoleh data latih yang lebih bervariasi, sehingga mampu mempelajari karakteristik visual secara lebih baik dan tidak mudah mengalami *overfitting*.

Penelitian ini menerapkan augmentasi pada data latih dengan memanfaatkan modul *torchvision.transforms* pada *PyTorch*. Teknik yang digunakan meliputi pembalikan citra secara horizontal dengan peluang tertentu, pembalikan vertikal, rotasi citra hingga batas ± 15 derajat, serta penyesuaian tingkat kecerahan, kontras, dan saturasi dengan kisaran $\pm 20\%$. Seluruh citra kemudian disesuaikan ukurannya menjadi 299×299 piksel agar kompatibel dengan arsitektur Inception V3.

Berbeda dengan metode yang menyimpan hasil augmentasi sebagai data baru, augmentasi pada penelitian ini dilakukan secara langsung selama proses

pelatihan berlangsung. Dengan pendekatan ini, variasi citra yang diterima model akan berbeda pada setiap *epoch*, sehingga model memperoleh paparan pola visual yang lebih beragam.

Sementara itu, data validasi tidak diberikan perlakuan augmentasi dan hanya melalui tahap praproses berupa perubahan ukuran dan normalisasi. Pendekatan ini bertujuan agar proses evaluasi kinerja model mencerminkan kemampuan klasifikasi terhadap citra asli tanpa pengaruh modifikasi tambahan. Dengan demikian, penerapan augmentasi diharapkan dapat meningkatkan stabilitas pelatihan serta kemampuan generalisasi model terhadap data baru.

3.6 Hyperparameter

Pada bagian ini menetapkan parameter yang digunakan oleh peneliti dalam membentuk sebuah model GoogleNet berikut parameteranya:

Tabel 3. 2 *Hyperparameter*

No	Parameter	Value (GoogLeNet Inception V3)
1	<i>Epoch</i>	15
2	<i>Batch size</i>	32
3	<i>Optimizer</i>	SGD
4	<i>Learning Rate</i>	0.005
5	<i>Scheduler</i>	<i>StepLR (step size = 7, gamma = 0.1)</i>
6	Augmentasi	<i>Flip, rotasi $\pm 15^\circ$, brightness, contrast, saturation $\pm 20\%$</i>
7	<i>Loss Function</i>	<i>Cross-Entropy</i>
8	<i>Input Size</i>	<i>299 x 299</i>

9	<i>Transfer Learning</i>	<i>Backbone</i> dibekukan (<i>FREEZE_BACKBONE = True</i>)
10	<i>Training From Scratch</i>	Seluruh layer dilatih (<i>FREEZE_BACKBONE = False</i>)

Tabel 3.3 menampilkan konfigurasi *hyperparameter* yang digunakan dalam pelatihan model GoogLeNet Inception V3 untuk klasifikasi kualitas getah kemenyan. Setiap parameter diatur agar model dapat belajar secara efektif dan menghasilkan akurasi yang baik. Ukuran citra masukan yang digunakan adalah 299×299 piksel, menyesuaikan dengan ketentuan standar pada arsitektur Inception V3. Penyesuaian ukuran ini dilakukan agar seluruh citra dapat diproses secara optimal oleh jaringan tanpa mengubah struktur dasar model.

Proses pelatihan dilakukan selama 15 *epoch*, yang berarti seluruh data latih diproses berulang sebanyak 15 kali. Jumlah *epoch* ini dipilih agar model memiliki waktu yang cukup untuk mempelajari pola visual tanpa menyebabkan proses pelatihan berlangsung terlalu lama atau berujung pada *overfitting*.

Nilai *batch size* sebesar 32 digunakan untuk menentukan jumlah citra yang diproses dalam satu siklus pembelajaran. Penggunaan *batch size* ini dipertimbangkan untuk menjaga keseimbangan antara kecepatan pelatihan dan keterbatasan sumber daya komputasi.

Optimasi bobot model dilakukan menggunakan *Stochastic Gradient Descent* (SGD). *Optimizer* ini dipilih karena memiliki mekanisme pembaruan bobot yang sederhana dan stabil, sehingga proses pembelajaran dapat berlangsung secara terkontrol.

Nilai *learning rate* sebesar 0.005 digunakan untuk mengatur besar langkah pembaruan bobot pada setiap iterasi. Nilai ini dipilih agar perubahan bobot tidak

terjadi secara terlalu drastis dan proses pembelajaran dapat berjalan secara bertahap.

Untuk mengatur perubahan *learning rate* selama proses pelatihan, diterapkan *learning rate scheduler* StepLR, di mana nilai *learning rate* diturunkan setiap 7 *epoch* dengan faktor pengali 0.1. Pengaturan ini bertujuan untuk meningkatkan kestabilan pelatihan pada tahap akhir.

Penelitian ini menerapkan dua skenario pelatihan, yaitu *transfer learning* dan *training from scratch*. Pada skenario *transfer learning*, parameter pada *backbone* model dibekukan sehingga hanya *layer* klasifikasi akhir yang diperbarui. Sebaliknya, pada skenario *training from scratch* seluruh parameter model dilatih secara penuh sejak awal.

Selain pengaturan pelatihan, diterapkan pula data *augmentation* berupa teknik *flip*, rotasi citra hingga ± 15 derajat, serta penyesuaian tingkat kecerahan hingga $\pm 20\%$. Teknik ini digunakan untuk meningkatkan variasi data latih sehingga model diharapkan mampu melakukan generalisasi yang lebih baik terhadap data baru.

3.7 Skenario Eksperimen Pelatihan Model

Tabel 3. 3 Skenario Eksperimen Pelatihan Model

No	Metode Pelatihan	Data Augmentasi	Keterangan
1	<i>Training From Scratch</i>	Tidak digunakan	Seluruh parameter model dilatih dari awal tanpa bobot pra-latih dan tanpa penambahan variasi data.

2	<i>Training From Scratch</i>	Digunakan	Seluruh parameter model dilatih dari awal dengan penerapan data <i>augmentation</i> pada data latih.
3	<i>Transfer Learning</i>	Tidak Digunakan	<i>Backbone</i> Inception V3 dibekukan dan hanya layer klasifikasi akhir yang dilatih tanpa augmentasi data.
4	<i>Transfer learning</i>	Digunakan	<i>Backbone</i> Inception V3 dibekukan, layer akhir dilatih, dan data latih diberikan augmentasi.

Penelitian ini dirancang dengan empat skenario eksperimen yang ditunjukkan pada table 3.3 dimana bertujuan untuk mengkaji pengaruh perbedaan metode pelatihan serta penerapan data *augmentation* terhadap performa model dalam klasifikasi citra getah kemenyan. Keempat skenario tersebut disusun secara sistematis agar setiap kombinasi strategi pelatihan dapat dibandingkan dengan jelas.

Pada skenario pertama, model dilatih menggunakan pendekatan *training from scratch* tanpa menerapkan data *augmentation*. Skenario ini digunakan sebagai dasar pembandingan untuk mengetahui kemampuan model dalam mempelajari pola visual dari data asli ketika seluruh parameter dilatih dari kondisi awal.

Skenario kedua masih menerapkan *training from scratch*, namun disertai dengan penggunaan data *augmentation* pada data latih. Tujuan dari skenario ini

adalah untuk mengevaluasi sejauh mana penambahan variasi data dapat mempengaruhi kinerja model ketika proses pelatihan dilakukan sepenuhnya dari awal.

Pada skenario ketiga, pelatihan model dilakukan menggunakan metode *transfer learning* tanpa data *augmentation*. Dalam skenario ini, bobot pada *backbone* Inception V3 dipertahankan dan hanya lapisan klasifikasi akhir yang dilatih, sehingga pengaruh pemanfaatan bobot pra-latih terhadap performa model dapat diamati tanpa adanya penambahan variasi data.

Skenario keempat mengombinasikan metode *transfer learning* dengan penerapan data *augmentation*. Skenario ini bertujuan untuk menilai kinerja model ketika memanfaatkan bobot pra-latih sekaligus memperoleh keuntungan dari variasi data yang dihasilkan melalui proses augmentasi.

Evaluasi terhadap keempat skenario pelatihan menjadi dasar untuk mengidentifikasi kombinasi metode serta penggunaan data *augmentation* yang paling efektif dalam meningkatkan akurasi klasifikasi kualitas getah kemenyan.


3.8 Evaluasi Model

Setelah proses pelatihan selesai, dilakukan proses evaluasi performa model Inception V3 yang telah dilatih untuk mengklasifikasikan kualitas getah kemenyan. Evaluasi dilakukan menggunakan metrik yang sebelumnya sudah dijelaskan pada Bab II, yaitu akurasi, *precision*, *recall*, dan *F1-score*. Keempat metrik tersebut digunakan untuk menilai seberapa baik model dalam mengenali tiga kelas utama, yaitu kualitas tinggi, sedang, dan rendah. Kemudian, hasil

evaluasi juga divisualisasikan dalam bentuk *confusion matrix*, yang memperlihatkan jumlah prediksi benar dan salah di tiap kelas. Dari matriks ini dapat dilihat apakah model cenderung keliru dalam membedakan antar kelas, misalnya antara kualitas sedang dan rendah. Proses evaluasi dilakukan menggunakan data *testing* sebanyak 15% dari total dataset. Dari hasil pengujian inilah diperoleh performa akhir model, yang nantinya menjadi dasar untuk menentukan apakah model sudah cukup baik untuk diimplementasikan ke dalam aplikasi klasifikasi getah kemenyan berbasis Android.

3.9 Implementasi Model Ke Aplikasi Android

Model terbaik hasil pelatihan diubah ke format TensorFlow Lite (.tflite) supaya ukurannya ringan dan bisa dipakai di ponsel. Setelah itu file model dimasukkan ke proyek Android Studio dan dipanggil melalui TensorFlow Lite Interpreter sehingga aplikasi bisa melakukan inferensi langsung di perangkat (tanpa perlu koneksi internet). Berikut adalah alur aplikasinya :



Gambar 3 2 Alur aplikasi

Pada gambar 3.2 ketika aplikasi dijalankan, pengguna bisa langsung mengambil foto getah lewat kamera atau memilih gambar dari galeri. Setelah gambar dipilih, aplikasi mengirimkannya ke sistem untuk diproses dan dianalisis oleh model. Hasil prediksi kemudian dikembalikan ke aplikasi dalam bentuk

kategori kualitas getah tinggi, sedang, atau rendah bersama nilai *confidence*-nya. Dengan alur ini, pengguna bisa mengetahui kualitas getah secara cepat hanya dengan menggunakan ponsel tanpa perlu alat tambahan.

3.10 Pengujian Dan Evaluasi Aplikasi

Setelah tahap integrasi, dilakukan pengujian untuk memastikan aplikasi dapat berjalan sesuai dengan fungsi yang dirancang. Pengujian mencakup kemudahan penggunaan antarmuka, waktu yang dibutuhkan aplikasi dalam menghasilkan prediksi, serta kesesuaian hasil klasifikasi antara aplikasi dan model pada tahap pelatihan. Aplikasi juga diuji pada berbagai perangkat Android dengan spesifikasi yang berbeda guna memastikan kinerja tetap stabil dan responsif. Sebagai bagian dari evaluasi tersebut, tampilan dan alur fitur aplikasi disajikan dalam bentuk mockup pada tabel 3.4 berikut untuk memberikan gambaran visual mengenai fungsi setiap halaman. Hasil pengujian ini menjadi dasar penilaian kelayakan aplikasi sebagai alat bantu praktis dalam penentuan mutu getah kemenyan

Tabel 3. 4 *Mockup Mobile KemenyanScan*

Halaman	Fungsi dan Penjelasan
Home 	Halaman utama yang menampilkan gambaran umum aplikasi serta menyediakan akses cepat ke fitur identifikasi, riwayat hasil identifikasi, dan profil pengguna.
Identifikasi 	Halaman yang digunakan untuk melakukan proses pengenalan mutu getah kemenyan melalui pengambilan atau unggahan citra, kemudian diproses oleh model klasifikasi untuk menghasilkan prediksi.
Identifikasi riwayat 	Halaman yang menampilkan daftar hasil identifikasi yang telah dilakukan sebelumnya, sehingga pengguna dapat melihat kembali hasil klasifikasi secara kronologis.

Halaman Profile 	Halaman yang menampilkan informasi pengguna serta pengaturan dasar aplikasi yang berkaitan dengan akun.
---	---



BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

- a. Model Inception V3 mampu melakukan klasifikasi kualitas getah kemenyan ke dalam kategori tinggi, sedang, dan rendah dengan hasil yang konsisten. Pendekatan *deep learning* berbasis citra efektif dalam mengenali ciri visual getah kemenyan.
- b. Penambahan data melalui teknik data augmentation terbukti meningkatkan kinerja model, memperbaiki kemampuan generalisasi, serta menekan terjadinya *overfitting* selama pelatihan.
- c. Hasil evaluasi menunjukkan bahwa pelatihan dari awal menghasilkan akurasi tertinggi, sementara *transfer learning* lebih efisien dalam hal waktu pelatihan dan kebutuhan komputasi, sehingga penggunaannya dapat disesuaikan dengan tujuan sistem.
- d. Secara umum, sistem klasifikasi berbasis deep learning memberikan penilaian kualitas getah kemenyan yang lebih objektif dan konsisten dibandingkan metode manual, serta memiliki potensi penerapan dalam bentuk aplikasi *mobile*.

5.2 Saran

- a. Penelitian lanjutan disarankan memperluas dataset citra getah kemenyan dengan menambah variasi kondisi pencahayaan, latar belakang, dan jenis kemenyan untuk meningkatkan kemampuan generalisasi model.

- b. Studi berikutnya dapat mengkaji penggunaan arsitektur *deep learning* lain, penggabungan model, serta penyesuaian *hyperparameter* dan teknik augmentasi data yang lebih beragam guna memperoleh kinerja klasifikasi yang lebih optimal.
- c. Aplikasi *mobile* dapat diuji dan dikembangkan lebih lanjut melalui pengujian pada lebih banyak perangkat serta kondisi penggunaan yang beragam agar sistem semakin andal dan siap digunakan secara luas.



DAFTAR PUSTAKA

- Abduh, M. Y., Rahmanita, A. T., Maulana, E. R., Nadhira, V. F., & Istri, T. (2022a). *Valorization of Lower Grade Resin , Bark , and Fruit of Styrax Sumatrana*. 5(1), 30–36. <https://doi.org/10.53894/ijirss.v5i1.349>
- Abduh, M. Y., Rahmanita, A. T., Maulana, E. R., Nadhira, V. F., & Istri, T. (2022b). *Valorization of Lower Grade Resin , Bark , and Fruit of Styrax Sumatrana*. *Valorization of Lower Grade Resin , Bark , and Fruit of Styrax Sumatrana*. March. <https://doi.org/10.53894/ijirss.v5i1.349>
- Alappat, A. L., Nakhate, P., Suman, S., Chandurkar, A., Pimpalkhute, V., & Jain, T. (2021). *CBIR using Pre-Trained Neural Networks*. 2011(3). <http://arxiv.org/abs/2110.14455>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Dujaili, A. Al, Duan, Y., Shamma, O. Al, Santamaría, J., Fadhel, M. A., Amidie, M. Al, & Farhan, L. (2021). Review of deep learning : concepts , CNN architectures , challenges , applications , future directions. In *Journal of Big Data*. Springer International Publishing. <https://doi.org/10.1186/s40537-021-00444-8>
- Baur, C., Wiestler, B., Albarqouni, S., & Navab, N. (n.d.). *Scale-Space Autoencoders for Unsupervised Anomaly Segmentation in Brain MRI*. 1–9.
- Descriptor, D., Vuong, Q., Phu, T. V., Le, T. T., & Khuc, Q. Van. (2021). *Exploring Inner-City Residents ' and Foreigners ' Commitment*. <https://doi.org/10.17632/8sv4j2r9wk.2>
- Fakhrabadi, A. K., & Shahbazzadeh, M. J. (2025). *OPEN A hybrid inception-dilated-ResNet architecture for deep learning- based prediction of COVID-19 severity*. 1–19.
- Farhan, M., Ryandra, D., Arsitektur, P., Inceptionv, R.-, Dalam, I., Covid, K., Farhan, M., Ryandra, D., Arsitektur, P., & Inceptionv, R.-. (2021). *PERBANDINGAN ARSITEKTUR RESNET-50 DAN BERDASARKAN CITRA X-RAY MUHAMMAD FARHAN DWI RYANDRA PERBANDINGAN ARSITEKTUR RESNET-50 DAN INCEPTIONV3 DALAM KLASIFIKASI COVID 19 BERDASARKAN CITRA X-RAY SKRIPSI Diajukan sebagai salah satu syarat untuk memperoleh Gela*.

- Fariza, A. (2024). *Tooth and Supporting Tissue Anomalies Detection from Panoramic Radiography Using Integrating Convolution Neural Network with Normalization*. 17(2). <https://doi.org/10.22266/ijies2024.0430.19>
- Goła, M., Sulewski, P., Adam, W., & Kłoczko-gajewska, A. (2020). *On the Way to Sustainable Agriculture — Eco-Efficiency of Polish Commercial Farms*.
- Gordon-rodriguez, E., Pleiss, G., Loaiza-ganem, G., & Cunningham, J. P. (2020). *Uses and Abuses of the Cross-Entropy Loss : Case Studies in Modern Deep Learning arXiv : 2011 . 05231v1 [stat . ML] 10 Nov 2020*. 1–11.
- Harahap, A. A., Novita, R., Ahsyar, T. K., & Riau, K. (2024). *Classification of Beef and Pork with Deep Learning Approach*. 07(01), 55–65.
- Hernandez-garcia, A., & König, P. (2016). *Data augmentation instead of explicit regularization*. 2014.
- Iqbal, M., Rozi, F., Adiwijaya, N. O., & Swasono, D. I. (2023). *Identifikasi Kinerja Arsitektur Transfer Learning VGG16 , ResNet-50 , dan Inception-V3 Dalam Pengklasifikasian Citra Penyakit Daun Tomat Identification of VGG16 , ResNet-50 , and Inception-V3 Transfer Architecture Performance in Image Classification of Tomato Leaf Diseases*. 5(2), 145–154.
- Kholibrina, C. R., Aswandi, A., Panjaitan, L. K., Nurhayati, N., Yusuf, R., Kholibrina, C. R., Aswandi, A., & Panjaitan, L. K. (2025). *Phytochemical Compounds from Various Grades of Sumatra Benzoin Resin Phytochemical Compounds from Various Grades of Sumatra Benzoin Resin*. 0–14. <https://doi.org/10.20944/preprints202509.0842.v1>
- Marchenko, E. I., Fateev, S. A., Eremin, N. N., Qi, C., Eugene, A., Tarasov, A. B., & Systems, U. O. (2021). *CRYSTAL CHEMICAL INSIGHTS ON LEAD IODIDE PEROVSKITES DOPING FROM REVISED EFFECTIVE RADII OF METAL IONS*. 1–42.
- Martinez-Alpiste, I., Golcarenenrenji, G., Wang, Q., & Alcaraz-Calero, J. M. (2022). *Smartphone-based real-time object recognition architecture for portable and constrained systems*. *Journal of Real-Time Image Processing*, 19(1), 103–115. <https://doi.org/10.1007/s11554-021-01164-1>
- Mohamed, A. H., Refaat, M., & Hemeida, A. M. (2022). *Image classification based deep learning : A Review*. 2(1).

- Muneeb, M., F. Feng, S., & Henschel, A. (2022). *Deep Learning Pipeline for Image Classification on Mobile Phones*. 1–20.
<https://doi.org/10.5121/csit.2022.120901>
- Naveen, N., & Cholli, N. G. (2024). Enhancing Early Alzheimer's Disease Detection: Leveraging Pre-trained Networks and Transfer Learning. *International Journal of Intelligent Systems and Applications*, 16(1), 52–69.
<https://doi.org/10.5815/ijisa.2024.01.05>
- PyTorch. (2023). *Torchvision models documentation*.
<https://pytorch.org/vision/stable/models.html>
- Qi, S., Zhang, Y., Wang, C., Zhou, J., & Cao, X. (2023). A Survey of Orthogonal Moments for Image Representation: Theory, Implementation, and Evaluation. *ACM Computing Surveys*, 55(1). <https://doi.org/10.1145/3479428>
- Salehin, I. (2023). *A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain*.
- Shorten, C., & Khoshgoftaar, T. M. (2021). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*.
<https://doi.org/10.1186/s40537-019-0197-0>
- Steiner, A., Wightman, R., & Uszkoreit, J. (2022). *How to train your ViT? Data , Augmentation , and Regularization in Vision Transformers*. 18.
- Sunarti, T. C., Syamsu, K., Fahma, F., & Julianti, E. (2025). Kandungan kimia kemenyan Sumatra Utara (*Styrax benzoin*) dan prospek pengembangannya : tinjauan literatur. 19(3), 530–539.
<https://doi.org/10.21107/agrointek.v19i3.27527>
- Susanti, N., Angelina, C., Nainggolan, P., & Lubis, S. L. (2025). *Formulasi dan Aktivitas Antibakteri Sediaan Sampo Ekstrak Getah Kemenyan (Styrax benzoin)*. 8, 91–99.
- Tanbin, M., Tanny, Y., Sultana, T., Biswas, E., Modok, C. K., Akter, A., Uddin, M. S., & Hossain, D. (2025). *DERIENet : A Deep Ensemble Learning Approach for High-Performance Detection of Jute Leaf Diseases*. 1–27.
- Togawa, S., & Jin'no, K. (2025). Understanding convolutional neural networks through Z-transform: Frequency domain analysis of kernel feature extraction.

- Nonlinear Theory and Its Applications, IEICE, 16(4), 878–895.*
<https://doi.org/10.1587/nolta.16.878>
- Ura, R., Handayani, D., Azwar, F., & Wakhid, N. (2023). *Morfologi Benih, Pertumbuhan, dan Indeks Mutu Bibit Kemenyan Durame (. 20(2), 91–104.*
- Utara, D. I. S., Dan, K., & Berbagai, S. F. (2020). *KARAKTERISTIK DAN SIFAT FISIKO-KIMIA BERBAGAI KUALITAS KEMENYAN. March 2006.*
<https://doi.org/10.20886/jpjh.2006.24.1.47-61>
- Widad, R. (2024). *Implementation of Machine Learning in Android Applications. 4523, 1–36.* <https://urn.fi/URN:NBN:fi:amk-2024052515749>
- Wulandari, I., Yasin, H., Widiari, T., Statistika, D., & Diponegoro, U. (2020). *Klasifikasi citra digital bumbu dan rempah dengan algoritma convolutional neural network (cnn) 1,2,3. 9, 273–282.*
- Xia, W., Peng, R., Chu, H., Zhu, X., Yang, Z., & Yang, L. (n.d.). *An Overall Real-Time Mechanism for Classification and Quality Evaluation of Rice.*
- Yamaguchi, S., Kanai, S., Kumagai, A., & Chijiwa, D. (2025). Transfer learning with pre - trained conditional generative models. In *Machine Learning* (Vol. 114, Nomor 4). Springer US. <https://doi.org/10.1007/s10994-025-06748-7>
- Yu, W., Zhou, P., Yan, S., & Wang, X. (2024). *InceptionNeXt: When Inception Meets ConvNeXt. 5672–5683.*
- Zafar, A., Saba, N., Arshad, A., Alabrah, A., Riaz, S., Suleman, M., Zafar, S., & Nadeem, M. (2024). *Convolutional Neural Networks: A Comprehensive Evaluation and Benchmarking of Pooling Layer Variants.*
- Zhao, X., Wang, L., Zhang, Y., Han, X., & Deveci, M. (2024). A review of convolutional neural networks in computer vision. In *Artificial Intelligence Review* (Vol. 57, Nomor 4). Springer Netherlands. <https://doi.org/10.1007/s10462-024-10721-6>

DAFTAR LAMPIRAN

1. Dokumentasi



PAPER NAME

VICA SARIANI SITUMORANG_skripsi2_u
LDGqzqvly9XHfOF2zOJOrcqHsCvOQbV3
q00DYef.docx

AUTHOR

VICA SARIANI SITUMORANG

WORD COUNT

11948 Words

CHARACTER COUNT

77440 Characters

PAGE COUNT

77 Pages

FILE SIZE

2.1MB

SUBMISSION DATE

Apr 20, 2026 11:02 AM GMT+7

REPORT DATE

Apr 20, 2026 11:04 AM GMT+7

● **6% Overall Similarity**

The combined total of all matches, including overlapping sources, for each database.

- 4% Internet database
- 2% Publications database
- Crossref database
- Crossref Posted Content database
- 5% Submitted Works database

● **Excluded from Similarity Report**

- Bibliographic material
- Cited material
- Abstract
- Small Matches (Less than 15 words)



UNIVERSITAS MEDAN AREA

FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate / Jalan Gedung PBSI Medan 20223
Kampus II : Jalan Sei Serayu Nomor 70 A / Jalan Setia Budi Nomor 79 B, Medan 20112 Telepon : (061) 8225602, 8201994
Fax : (061) 8226331 HP : 0811 607 259 website: www.uma.ac.id Email : univ_medanarea@uma.ac.id

Nomor : 2579/FT/01.10/X/2025

14 Oktober 2025

Lampiran : -

Hal : Pembimbing Tugas Akhir

Yth. Pembimbing Tugas Akhir

Dr Arnes Sembiring ST, M. Kom (Sebagai Pembimbing)
di Tempat

Dengan hormat, sehubungan telah dipenuhinya persyaratan untuk memperoleh Tugas Akhir dari mahasiswa atas :

Nama : VICA SARIANI SITUMORANG

NIM : 228160087

Jurusan : TEKNIK INFORMATIKA

Maka dengan hormat kami mengharapkan kesediaan saudara :

Dr Arnes Sembiring ST, M. Kom (Sebagai Pembimbing)

Adapun Tugas Akhir Skripsi berjudul :

"Klasifikasi kualitas getah kemenyan menggunakan arsitektur Googlenet Inception V3 berbasis citra "

SK Pembimbing ini berlaku selama enam bulan terhitung sejak SK ini diterbitkan. Jika proses pembimbing melebihi batas waktu yang telah ditetapkan, SK ini dapat ditinjau ulang.

Demikian kami sampaikan, atas kesediaan saudara diucapkan terima kasih.

Dekan,



Dr Eng. Supriatno.ST, MT.



UNIVERSITAS MEDAN AREA

FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate ☎ (061) 7360168, Medan, 20223
 Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Serayu Nomor 70 A ☎ (061) 42402994, Medan, 20122
 Website: www.teknik.uma.ac.id E-mail: univ.medanarea@uma.ac.id

Nomor : 344 / FT 6/01.10/XI/2025
 Lamp :
 Hal : Penelitian Dan Pengambilan Data Tugas Akhir

27 November 2025

Yth. Kepala Desa Sibaganding
 Desa Sibaganding, Pahae Julu
 Di
 Tapanuli Utara

Dengan hormat,

Kami mohon kesediaan Bapak/Ibu berkenan untuk memberikan izin dan kesempatan kepada mahasiswa kami tersebut dibawah ini :

NO	NAMA	NPM	PRODI
1	Vica Sariani Situmorang	228160087	Teknik Informatika

Untuk melaksanakan Penelitian dan Pengambilan Data Tugas Akhir pada perusahaan/Instansi yang Bapak/Ibu Pimpin.

Perlu kami jelaskan bahwa Pengambilan Data tersebut adalah semata-mata untuk tujuan ilmiah dan Skripsi yang merupakan salah satu syarat bagi mahasiswa tersebut untuk mengikuti ujian sarjana pada Fakultas Teknik Universitas Medan Area dan tidak untuk dipublikasikan, dengan judul penelitian :

Klasifikasi Kualitas Getah Kemenyan Menggunakan Arsitektur GoogleNet Inception V3 Berbasis Citra

Atas perhatian dan kerja sama yang baik diucapkan terima kasih

Dekan,


 Eng. Supriatno, ST, MT

Tembusan :

1. Ka. BPMPP
2. Mahasiswa
3. File



**PEMERINTAH KABUPATEN TAPANULI UTARA
KECAMATAN PAHAE JULU
DESA SIBAGANDING**

Kabupaten Tapanuli Utara, Provinsi Sumatera Utara

Kode Pos : 22463

SURAT KETERANGAN SELESAI PENELITIAN

Nomor : 140/ /12.02.05.2005/XII/2025

Yang bertanda tangan dibawah ini, Kepala Desa Sibaganding, Kecamatan Pahae Julu, Kabupaten Tapanuli Utara dengan ini menerangkan bahwa :

Nama : VICA SARIANI SITUMORANG
NIM : 228160087
Jenis Kelamin : Perempuan
Program Studi : 1. Informatika

Telah selesai melakukan penelitian di wilayah Desa Sibaganding, Kec. Pahae Julu terhitung sejak tanggal 27 November 2025 s/d 27 Desember 2025, dengan judul :

"Klasifikasi Kualitas Getah Kemenyan Menggunakan Arsitektur GoogleNet/ Inception V3 Berbasis Citra"

Demikian Surat Keterangan ini diperbuat untuk dapat dipergunakan seperlunya.

Dikeluarkan di : Desa Sibaganding
Pada tanggal : 29 Desember 2025

KEPALA DESA SIBAGANDING

REMON SITOMPUL