

**PENERAPAN *CONVOLUTIONAL NEURAL NETWORK* DAN
MOBILENETV2 UNTUK MENILAI AKTIVITAS
ANTIOKSIDAN PRENIL FLAVONOID**

TUGAS AKHIR

Diajukan Oleh:

ADHE MERA ULFA

NIM. 210705058

**Mahasiswa Fakultas Sains dan Teknologi
Program Studi Teknologi Informasi**



**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI AR-RANIRY
BANDA ACEH 2026 M / 1447 H**

LEMBAR PERSETUJUAN

PENERAPAN *CONVOLUTIONAL NEURAL NETWORK* DAN *MOBILENETV2* UNTUK MENILAI AKTIVITAS ANTIOKSIDAN PRENIL FLAVONOID

TUGAS AKHIR

Diajukan kepada Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh
Sebagai Salah Satu Beban Studi Program Sarjana dalam
Ilmu Teknologi Informasi

Oleh:

ADHE MERA ULFA

210705058

Mahasiswa Fakultas Sains dan Teknologi
Program Studi Teknologi Informasi


Disetujui Untuk Dimunaqasyahkan oleh:

Pembimbing I

Pembimbing II



Dr. Hendri Ahmadian, M.I.M

NIP. 198301042014031002


Anjar Purba Asmara, M.Sc., Ph.D.

NIP. 19850909201403002

Mengetahui,
Ketua Program Studi Teknologi Informasi


Malahayati, M.T.

NIP. 198301272015032003

LEMBAR PENGESAHAN

PENERAPAN *CONVOLUTIONAL NEURAL NETWORK* DAN *MOBILENETV2* UNTUK MENILAI AKTIVITAS ANTIOKSIDAN PRENIL FLAVONOID

TUGAS AKHIR

Telah Diuji Oleh Panitia Ujian Munaqasyah Tugas Akhir
Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh dan Dinyatakan Lulus
Serta Diterima Sebagai Salah Satu Beban Studi Program Sarjana (S1)
Dalam Program Studi Teknologi Informasi

Pada Hari/Tanggal: 03 Februari 2026

15 Sya'ban 1447 H


Di Darussalam, Banda Aceh

Panitia Ujian Munaqasyah Tugas Akhir:

Ketua,

Sekretaris,


Dr. Hendri Ahmadian, M.I.M
NIP. 198301042014031002


Anjar Purba Asmara, M.Sc., Ph.D
NIP. 19850909201403002

Penguji I,


Penguji II,


Malahayati, M.T
NIP. 198301272015032003


Khairan AR, M.Kom
NIP. 198607042014031001

Mengetahui,
Dekan Fakultas Sains dan Teknologi
UIN Ar-Raniry Banda Aceh




Prof. Dr. Ir Muhammad Dirhamsyah, M.T., IPU
NIP. 196210021988111001

LEMBAR PERNYATAAN KEASLIAN

Yang bertanda tangan di bawah ini:

Nama : Adhe Mera Ulfa
NIM : 210705058
Program Studi : Teknologi Informasi
Fakultas : Sains dan Teknologi
Judul Tugas Akhir : Penerapan *Convolutional Neural Network* dan *MobileNetV2* Untuk Menilai Aktivitas Antioksidan Prenil Flavonoid

Dengan ini menyatakan bahwa dalam penulisan tugas akhir ini, saya:

1. Tidak menggunakan ide orang lain tanpa mampu mengembangkan dan mempertanggung jawabkan.
2. Tidak melakukan plagiasi terhadap naskah orang lain.
3. Tidak menggunakan karya orang lain tanpa menyebutkan sumber asli atau tanpa izin pemilik karya.
4. Tidak memanipulasi dan memalsukan data.
5. Mengerjakan sendiri karya ini dan mampu bertanggung jawab atas karya ini.

Bila dikemudian hari ada tuntutan dari pihak lain atas karya saya, dan telah melalui pembuktian yang dapat dipertanggung jawabkan dan ternyata memang ditemukan bukti bahwa saya telah melanggar pernyataan ini, maka saya siap dikenakan sanksi berdasarkan aturan yang berlaku di Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh.

Demikian Pernyataan ini saya buat dengan sesungguhnya dan tanpa paksaan dari pihak manapun.

Banda Aceh, 03 Februari 2026

Yang Menyatakan


Adhe Mera Ulfa

ABSTRAK

Nama : Adhe Mera Ulfa
NIM : 210705058
Program Studi : Teknologi Informasi
Judul : Penerapan *Convolutional Neural Network* dan *MobileNetV2*
Untuk Menilai Aktivitas Antioksidan Prenil Flavonoid
Tanggal Sidang : 03 Februari 2026
Jumlah Halaman : 95
Pembimbing I : Dr. Hendri Ahmadian, M.I.M
Pembimbing II : Anjar Purba Asmara, M.Sc., Ph.D

Prenil flavonoid merupakan kelompok senyawa flavonoid yang memiliki aktivitas biologis tinggi, salah satunya sebagai antioksidan. Aktivitas antioksidan umumnya ditentukan melalui uji eksperimental seperti metode DPPH dengan parameter IC_{50} , namun metode ini membutuhkan waktu, biaya, dan sumber daya yang besar. Oleh karena itu, diperlukan pendekatan komputasional untuk mendukung skrining awal aktivitas antioksidan. Penelitian ini menerapkan Convolutional Neural Network (CNN) untuk mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid berdasarkan citra struktur molekul serta membandingkannya dengan arsitektur MobileNetV2. Dataset terdiri dari 153 citra struktur molekul yang dibagi ke dalam dua kelas, yaitu senyawa aktif dan tidak aktif berdasarkan nilai IC_{50} . Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score. Hasil menunjukkan bahwa CNN dasar memperoleh akurasi 53% namun mengalami underfitting dengan recall kelas senyawa aktif sebesar 0,00. Sebaliknya, MobileNetV2 memperoleh akurasi yang sama tetapi menunjukkan kinerja yang lebih baik dengan recall 0,79 dan F1-score 0,61 pada kelas senyawa aktif. Dengan demikian, MobileNetV2 dinilai lebih efektif dibandingkan CNN dasar dalam mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid.

Kata kunci: Prenil flavonoid, antioksidan, Convolutional Neural Network, MobileNetV2, citra struktur molekul.

ABSTRACT

Name : Adhe Mera Ulfa
NIM : 210705058
Studi Program : Information Technology
Title : Application of Convolutional Neural Network and MobileNetV2 to Assess the Antioxidant Activity of Prenylated Flavonoids
Date of Defense : 03 February 2026
Number of Pages : 95
Supervisor I : Dr. Hendri Ahmadian, M.I.M
Supervisor II : Anjar Purba Asmara, M.Sc., Ph.D

Prenyl flavonoids are a class of flavonoid compounds with high biological activity, particularly as antioxidants. Antioxidant activity is commonly determined through experimental assays such as the DPPH method using the IC_{50} parameter; however, these methods require substantial time, cost, and resources. Therefore, a computational approach is needed to support the initial screening of antioxidant activity. This study applies a Convolutional Neural Network (CNN) to classify the antioxidant activity of prenyl flavonoid compounds based on molecular structure images and compares its performance with the MobileNetV2 architecture. The dataset consists of 153 molecular structure images classified into two classes, namely active and inactive compounds, based on IC_{50} values. Model performance was evaluated using accuracy, precision, recall, and F1-score metrics. The results show that the basic CNN achieved an accuracy of 53% but suffered from underfitting, with a recall of 0.00 for the active compound class. In contrast, MobileNetV2 achieved the same accuracy but demonstrated better performance, with a recall of 0.79 and an F1-score of 0.61 for the active compound class. Therefore, MobileNetV2 is considered more effective than the basic CNN in classifying the antioxidant activity of prenyl flavonoid compounds.

Keywords: Prenyl flavonoids, antioxidants, Convolutional Neural Network, MobileNetV2, molecular structure images.

KATA PENGANTAR

Puji syukur kehadiran Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan penyusunan tugas akhir ini dengan baik dan lancar. Shalawat serta salam senantiasa tercurahkan kepada junjungan Nabi besar Muhammad SAW yang telah membawa umat manusia dari zaman kegelapan menuju zaman yang penuh dengan ilmu pengetahuan dan cahaya Islam.

Dengan izin dan pertolongan Allah SWT, penulis berhasil menyelesaikan tugas akhir yang berjudul **“Penerapan *Convolutional Neural Network* dan *Mobilenetv2* Untuk Menilai Aktivitas Antioksidan Prenil Flavonoid”**. Penulis berharap tugas akhir ini dapat memberikan manfaat dan kontribusi bagi pengembangan ilmu pengetahuan, khususnya dalam bidang teknologi informasi dan kimia komputasi, terutama dalam penerapan metode *deep learning* untuk skrining dan klasifikasi aktivitas senyawa bioaktif.

Tugas akhir ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Strata 1 (S1) pada Program Studi Teknologi Informasi, Fakultas Sains dan Teknologi, Universitas Islam Negeri Ar-Raniry Darussalam Banda Aceh. Penulisan tugas akhir ini tidak lepas dari berbagai bantuan, dukungan, bimbingan, dan doa dari banyak pihak. Oleh karena itu, pada kesempatan ini penulis ingin menyampaikan penghargaan dan ucapan terima kasih yang sebesar-besarnya kepada:

1. Orang tua tercinta, Ayah dan Mama yang merupakan sumber kekuatan terbesar bagi penulis. Doa yang tak pernah putus, kasih sayang yang tulus, serta semangat dan pengorbanan yang senantiasa diberikan menjadi pondasi utama bagi penulis dalam menempuh pendidikan hingga menyelesaikan tugas akhir ini. Penulis juga menyampaikan terima kasih kepada seluruh keluarga besar atas perhatian, nasihat, motivasi, serta dukungan yang telah membantu penulis melewati setiap proses dengan baik.
2. Saudara kandung penulis, Ayu Kartika Yuni, A.Md.Keb., yang senantiasa memberikan doa, perhatian, serta dukungan moral kepada penulis. Kehadiran beliau sebagai kakak menjadi sumber semangat dan penguat tersendiri bagi

penulis dalam menjalani proses perkuliahan hingga penyusunan tugas akhir. Nasihat, motivasi, dan kepedulian yang diberikan turut membantu penulis untuk tetap berusaha, bertahan, dan menyelesaikan tugas akhir ini dengan penuh tanggung jawab.

3. Bapak Dr. Hendri Ahmadian, S.Si., M.I.M. selaku Dosen Pembimbing I dan Bapak Anjar Purba Asmara, M.Sc., Ph.D. selaku Dosen Pembimbing II, yang dengan penuh kesabaran dan dedikasi telah memberikan bimbingan, masukan, arahan, serta motivasi sejak awal penyusunan hingga selesainya tugas akhir ini. Di tengah kesibukan masing-masing, kedua pembimbing telah meluangkan waktu untuk memberikan saran dan kritik yang membangun, sehingga sangat membantu penulis dalam proses penelitian dan penyempurnaan tugas akhir ini.
4. Bapak Ghufran Ibnu Yasa, M.T., selaku Pembimbing Akademik, yang telah memberikan arahan serta bimbingan akademik kepada penulis selama masa perkuliahan. Dukungan dan pendampingan beliau turut membantu penulis dalam menjalani proses studi hingga tahap akhir penyusunan tugas akhir.
5. Ketua Program Studi, Ibu Malahayati, M.T., Sekretaris Program Studi Bapak Khairan AR, M.Kom., Bapak/Ibu Dosen Pengajar pada Program Studi Teknologi Informasi, serta Staf Program Studi, Ibu Cut Ida Rahmadiana, S.Si. yang telah memberikan ilmu, bimbingan, dan dukungan administratif selama penulis menempuh pendidikan.
6. Dekan Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh, Bapak Prof. Dr. Ir. M. Dirhamsyah, M.T., IPU., atas dukungan dan fasilitas akademik yang kondusif selama masa studi penulis.
7. Mindarina, S.Kom., Era Syafina, S.Kom., Muti'ah, S.Kom., Safar Amara, S.Kom., Azzahra, S.Kom., serta seluruh rekan mahasiswa Program Studi Teknologi Informasi angkatan 2021, yang telah menjadi teman seperjuangan sejak awal masa perkuliahan. Kebersamaan, dukungan, canda, serta semangat yang diberikan dalam berbagai situasi baik suka maupun duka menjadi bagian berharga yang turut menemani proses penyusunan tugas akhir ini hingga selesai.
8. Diri penulis sendiri, yang telah berusaha dengan sungguh-sungguh, menjaga komitmen, serta terus belajar dan berproses dalam memahami setiap tahapan

penelitian. Di tengah berbagai keterbatasan, tantangan, dan kendala yang dihadapi, penulis berupaya untuk tetap bertahan, bangkit, dan menyelesaikan tugas akhir ini dengan penuh tanggung jawab.

Penulis menyadari bahwa tugas akhir ini masih memiliki keterbatasan, baik dari segi pembahasan, kedalaman analisis, maupun penyajiannya. Oleh karena itu, penulis sangat mengharapkan adanya kritik dan saran yang bersifat membangun dari berbagai pihak sebagai bahan evaluasi dan perbaikan guna penyempurnaan penelitian di masa yang akan datang.

Akhir kata, penulis berharap agar tugas akhir ini dapat memberikan manfaat dan menambah wawasan bagi pembaca, peneliti, serta pihak-pihak yang berkepentingan. Selain itu, penulis juga berharap karya ini dapat menjadi kontribusi sederhana dalam pengembangan ilmu pengetahuan, khususnya di bidang Teknologi Informasi. Semoga Allah SWT senantiasa melimpahkan rahmat, keberkahan, serta rida-Nya kepada kita semua. Aamiin ya Rabbal 'alamin..

Banda Aceh, 29 Januari 2026

Penulis,

Adhe Mera Ulfa


DAFTAR ISI

LEMBAR PERSETUJUAN	i
LEMBAR PENGESAHAN	ii
LEMBAR PERNYATAAN KEASLIAN	iii
ABSTRAK	iv
ABSTRACT	v
KATA PENGANTAR.....	vi
DAFTAR ISI.....	ix
DAFTAR GAMBAR.....	xi
DAFTAR TABEL.....	xii
BAB I PENDAHULUAN	1
1.1 Latar Belakang Masalah.....	1
1.2 Rumusan Masalah	3
1.3 Tujuan.....	4
1.4 Manfaat Penelitian.....	4
BAB II TINJAUAN PUSTAKA.....	5
2.1 Penelitian Terdahulu.....	5
2.2 Mekanisme DPPH scavenging	6
2.3 Klasifikasi Prenil Flavonoid.....	7
2.4 <i>Convolutional Neural Network</i> (CNN)	10
2.4.1 Definisi <i>Convolutional Neural Network</i> (CNN)	10
2.4.2 Mekanisme <i>Convolutional Neural Network</i> (CNN)	10
2.5 <i>MobileNetV2</i>	11
2.6 Google Collab.....	12
2.7 Python.....	13
BAB III METODOLOGI PENELITIAN	14
3.1 Rancangan Penelitian	14
3.2 Waktu, Lokasi dan Objek Penelitian	14
3.3 Populasi dan Sampel.....	15
3.4 Alat dan Bahan Penelitian	15
3.5 Teknik Pengumpulan Data	16
3.6 Teknik Analisis Data	65

BAB IV HASIL DAN PEMBAHASAN.....	66
4.1 Tahapan Persiapan Data	66
4.2 Pengumpulan Data.....	66
4.3 Data <i>Preprocessing</i>	68
4.3.1 Penyesuaian ukuran citra (<i>Image Resizing</i>)	68
4.3.2 Normalisasi Nilai Piksel (<i>Rescaling</i>)	69
4.3.3 Augmentasi Data.....	69
4.3.4 Pembentukan Data Generator dan Pembagian Dataset.....	70
4.4 Pelatihan Model.....	70
4.4.1 Pelatihan Model CNN	71
4.4.2 Pelatihan Model <i>MobileNetV2</i>	71
4.5 Evaluasi Model.....	72
4.5.1 Evaluasi Model CNN	72
4.5.2 Evaluasi Model <i>MobileNetV2</i>	74
4.6 Hasil Pembahasan.....	76
BAB V KESIMPULAN DAN SARAN	79
5.1 Kesimpulan.....	79
5.2 Saran	80
DAFTAR PUSTAKA	81

DAFTAR GAMBAR

Gambar 2.1 Struktur kimia 3-methoxyxanthohumol H	9
Gambar 2.2 Struktur kimia 3-epi-lupinifolinol	9
Gambar 2.3 Struktur Convolutional Neural Network (CNN).....	11
Gambar 2.4 Arsitektur MobileNetV2	12
Gambar 3.1 Teknik Analisis Data.....	65
Gambar 4.1 Pembuatan struktur molekul menggunakan ChemSketch.....	67
Gambar 4.2 Struktur Senyawa Prenil Xanthohumol.....	67
Gambar 4.3 struktur senyawa molekul sebelum dilakukan proses resizing.....	68
Gambar 4.4 struktur senyawa molekul setelah dilakukan proses resizing.....	69
Gambar 4.5 struktur senyawa molekul setelah dilakukan proses augmentasi	70
Gambar 4.6 Tampilan grafik akurasi dan Loss Model CNN	73
Gambar 4.7 Confusion Matrix Model CNN	73
Gambar 4.8 Tampilan grafik akurasi dan Loss Model MobileNetV2	74
Gambar 4.9 Confusion Matrix Model MobileNetV2.....	75



DAFTAR TABEL

Tabel 2.1 Perbandingan Penelitian Terdahulu	5
Tabel 2.2 Subkelas Prenil Flavonoid dan Aktivitas Biologisnya.....	8
Tabel 3.1 Spesifikasi Perangkat Keras dan Platform	15
Tabel 3.2 Daftar dataset senyawa yang akan diuji.....	17
Tabel 4.1 Hasil Evaluasi Model CNN Berdasarkan Classification Report.....	74
Tabel 4.2 Hasil Evaluasi Model MobileNetV2 Berdasarkan Classification Report	75



BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Prenil flavonoid merupakan senyawa flavonoid yang telah mengalami modifikasi struktur kimia melalui penambahan gugus prenil, yaitu rantai hidrokarbon bercabang yang berasal dari unit isoprenoid lima karbon. Gugus ini dapat memiliki variasi struktur seperti *3,3-dimetilallyl*, *geranyl*, *lavandulyl*, atau *farnesyl* yang memungkinkan terjadinya transformasi lebih lanjut melalui reaksi oksidasi, dehidrasi, maupun siklisasi sehingga membentuk *moiety* yang lebih kompleks. Keberagaman struktur ini memberikan kontribusi signifikan terhadap variasi aktivitas biologis senyawa flavonoid prenil, termasuk aktivitas antioksidan, antimikroba, dan antikanker. Mayoritas flavonoid prenil alami yang ditemukan merupakan senyawa C-prenil dengan potensi bioaktivitas yang berbeda tergantung pada jenis dan posisi gugus prenil yang dimilikinya (Santos & Silva, 2020).

Aktivitas antioksidan merupakan salah satu sifat biologis utama yang banyak dikaji pada senyawa prenil flavonoid karena perannya dalam menangkal radikal bebas yang dapat menyebabkan stres oksidatif dan berbagai penyakit degeneratif. Namun, hubungan antara struktur kimia dan aktivitas antioksidan senyawa prenil flavonoid bersifat kompleks dan tidak selalu bersifat linier. Perubahan kecil pada struktur molekul, khususnya pada posisi atau jumlah gugus prenil, dapat menyebabkan perbedaan yang signifikan terhadap nilai aktivitas antioksidan yang dihasilkan. Kompleksitas hubungan struktur–aktivitas ini menimbulkan tantangan tersendiri dalam proses analisis dan evaluasi potensi antioksidan senyawa secara efisien dan sistematis.

Seiring dengan perkembangan teknologi, bidang kimia dan biomedis mulai mengintegrasikan kecerdasan buatan, khususnya model *deep learning*, dalam proses analisis dan prediksi sifat biologis senyawa. Salah satu model yang menonjol dalam hal ini adalah *Convolutional Neural Network* (CNN). CNN terbukti efektif dalam mengenali pola dari data citra dan spektral karena kemampuannya dalam mengekstrak fitur penting secara otomatis tanpa intervensi manusia secara langsung. Hal ini menjadikan CNN sebagai pilihan model yang tepat dalam

klasifikasi dan prediksi aktivitas biologis senyawa kimia, termasuk evaluasi aktivitas antioksidan (Wang et al., 2018).

Dalam konteks analisis struktur molekul, CNN dapat dimanfaatkan untuk mengolah representasi visual struktur kimia senyawa dan mengklasifikasikannya berdasarkan tingkat aktivitas antioksidan. Pendekatan ini memungkinkan pemetaan hubungan antara struktur molekul dan aktivitas biologis secara lebih komprehensif, karena CNN mampu menangkap pola visual kompleks yang mungkin sulit diidentifikasi melalui pendekatan konvensional berbasis perhitungan deskriptor. Oleh karena itu, penerapan CNN dalam analisis senyawa prenil flavonoid menjadi pendekatan yang menjanjikan untuk mendukung proses skrining awal senyawa bioaktif secara komputasional.

Perkembangan arsitektur CNN yang semakin beragam juga membuka peluang untuk meningkatkan efisiensi dan kinerja model. Salah satu arsitektur CNN yang banyak dikembangkan adalah *MobileNetV2*, yang dirancang dengan konsep *depthwise separable convolution* dan *inverted residual blocks*. Arsitektur ini memungkinkan pengurangan jumlah parameter dan kompleksitas komputasi secara signifikan, sehingga lebih efisien dalam proses pelatihan dan lebih stabil ketika diterapkan pada dataset dengan ukuran terbatas. Dalam analisis citra struktur molekul, *MobileNetV2* berpotensi memberikan performa yang kompetitif dalam mengekstraksi fitur visual penting yang berkaitan dengan aktivitas biologis senyawa (Rafli et al., 2025).

Berdasarkan latar belakang tersebut, penelitian ini berfokus pada penerapan model CNN untuk menilai aktivitas antioksidan senyawa prenil flavonoid berdasarkan representasi visual struktur molekul. Model dikembangkan untuk mengklasifikasikan senyawa ke dalam dua kategori, yaitu aktif dan tidak aktif, dengan penentuan label klasifikasi yang mengacu pada data eksperimental dari literatur menggunakan prooksidan *Inhibitory Concentration of 50% (IC₅₀)* sebagai parameter aktivitas antioksidan. Selain itu, penelitian ini juga mengevaluasi penggunaan arsitektur CNN konvensional dan CNN berbasis *MobileNetV2* untuk membandingkan kinerja model dalam mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid.

Penerapan CNN dalam penelitian ini mencakup tahapan seperti pengumpulan data struktur molekul, konversi data menjadi citra dua atau tiga dimensi, pelatihan model menggunakan data nilai IC_{50} , serta evaluasi performa model melalui validasi. Pendekatan ini tidak hanya memungkinkan pemetaan hubungan antara struktur kimia dengan aktivitas biologis, tetapi juga dapat mengidentifikasi fitur struktural penting, seperti posisi dan jumlah gugus prenil, yang berpengaruh terhadap potensi antioksidan. Hal ini sangat bermanfaat dalam proses desain senyawa baru dan skrining awal untuk seleksi senyawa bioaktif (Hentabli et al., 2022).

Di sisi lain, model konvensional seperti uji *2,2-diphenyl-1-picrylhydrazyl* (DPPH), *2,2'-azinobis(3-ethylbenzothiazoline-6-sulfonic acid)* (ABTS), dan *Ferric Reducing Antioxidant Power* (FRAP) meskipun akurat, memerlukan waktu, biaya, dan tenaga ahli dalam pelaksanaannya, terutama ketika menghadapi ratusan struktur senyawa. Oleh karena itu, pendekatan berbasis CNN menjadi alternatif yang menjanjikan karena mampu mengenali pola kompleks dari citra struktur kimia tanpa memerlukan perhitungan deskriptor manual (Ryu et al., 2018).

Dengan demikian, pengembangan model CNN, termasuk pemanfaatan arsitektur *MobileNetV2*, diharapkan dapat menjadi solusi komputasional yang mendukung penilaian aktivitas antioksidan senyawa prenil flavonoid secara efisien dan sistematis. Penelitian ini menjadi bagian dari upaya integrasi antara kimia komputasi dan kecerdasan buatan yang diharapkan dapat memberikan kontribusi ilmiah dalam pengembangan metode skrining senyawa bioaktif serta mendukung percepatan penelitian di bidang farmasi dan biomedis.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana penerapan *Convolutional Neural Network* (CNN) dalam mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid berdasarkan citra struktur molekul?
2. Bagaimana perbandingan kinerja CNN dasar dan *MobileNetV2* dalam mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid berdasarkan nilai IC_{50} ?

3. Bagaimana performa CNN dasar dan *MobileNetV2* berdasarkan hasil evaluasi menggunakan metrik penilaian yang diterapkan dalam penelitian?

1.3 Tujuan

Tujuan dari penelitian ini adalah sebagai berikut:

1. Menerapkan *Convolutional Neural Network* (CNN) dalam proses klasifikasi aktivitas antioksidan senyawa prenil flavonoid berdasarkan citra struktur molekul.
2. Menganalisis perbandingan kinerja CNN dasar dan *MobileNetV2* dalam mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid berdasarkan nilai IC_{50} .
3. Mengevaluasi performa CNN dasar dan *MobileNetV2* menggunakan metrik evaluasi yang digunakan dalam penelitian.

1.4 Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah sebagai berikut:

1. Memberikan kontribusi ilmiah dalam penerapan *Convolutional Neural Network* (CNN) dan *MobileNetV2* pada analisis hubungan antara struktur molekul dan aktivitas antioksidan senyawa prenil flavonoid.
2. Menjadi referensi akademik bagi penelitian selanjutnya yang berkaitan dengan pemanfaatan metode deep learning dalam penilaian aktivitas biologis senyawa kimia berbasis citra struktur molekul.
3. Menyediakan pendekatan komputasional yang dapat digunakan sebagai alat bantu dalam proses penilaian dan skrining awal aktivitas antioksidan senyawa prenil flavonoid secara lebih efisien.
4. Mendukung pengembangan penelitian di bidang kimia komputasi, farmasi, dan bioteknologi melalui pemanfaatan kecerdasan buatan dalam analisis senyawa bioaktif.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Tinjauan terhadap penelitian-penelitian terdahulu merupakan langkah penting untuk menghindari pengulangan riset dan melanggar hak cipta. Studi-studi sebelumnya dijadikan sebagai dasar perbandingan dan rujukan utama. Untuk menggambarkan posisi dan keunikan penelitian ini, berikut disajikan ringkasan temuan dari penelitian-penelitian sebelumnya:

Berdasarkan beberapa penelitian terdahulu, dapat disimpulkan bahwa model CNN telah terbukti efektif dalam melakukan klasifikasi berbasis citra pada berbagai bidang, mulai dari pertanian, pangan, geologi, hingga bidang kesehatan. Keakuratan model CNN yang tinggi pada sebagian besar studi menunjukkan potensi besar teknologi ini dalam mendukung proses otomatisasi dan pengambilan keputusan berbasis data visual. Meskipun demikian, masih terdapat tantangan dalam hal generalisasi model terhadap data baru, seperti terlihat pada tingkat akurasi validasi yang rendah pada beberapa penelitian. Oleh karena itu, pemilihan arsitektur yang sesuai serta pengelolaan data latih dan validasi yang baik menjadi faktor penting dalam penerapan CNN secara optimal. Adapun perbandingan penelitian terdahulu yang menjadi dasar kesimpulan tersebut ditampilkan pada Tabel 2.1.

Tabel 2.1 Perbandingan Penelitian Terdahulu

Penelitian	Model	Topik Penelitian	Hasil Utama	Tingkat Akurasi
(Prasetyo & Mahendra, 2025)	CNN	Deteksi penyakit pada daun kentang.	CNN dapat membedakan daun sehat dan terinfeksi secara visual dengan cukup akurat.	Latih: 95% Uji: 82%
Dina Andriana (2025)	CNN (<i>Transfer Learning MobileNetV2</i>)	Prediksi aktivitas senyawa flavonoid sebagai aktivator GLUT-4 citra molekul.	CNN mampu mengklasifikasikan flavonoid sebagai aktivator GLUT-4 kuat dan lemah dengan akurasi yang cukup baik.	Akurasi validasi: 75%

(Istiqomah & Ardianto, 2024)	CNN (<i>MobileNet V2</i>).	Prediksi dan klasifikasi kanker darah (leukemia) anak-anak.	CNN dengan <i>MobileNetV2</i> berhasil mengklasifikasikan 4 kelas leukemia dengan akurasi sangat tinggi.	100%
(Hermawan & Agustina, 2023)	CNN	Klasifikasi rempah-rempah khas Indonesia.	Model mampu mengenali 7 jenis rempah, namun validasi masih rendah dan perlu peningkatan.	Latih: 99.27% Validasi: 60.22%
(Ezra et al., 2023)	Uji Antioksidan (DPPH, ABTS, dan FRAP)	Analisis kapasitas antioksidan pada ekstrak biji jengkol (<i>Archidendron sp.</i>) menggunakan metode DPPH, ABTS, dan FRAP.	Ekstrak biji jengkol menunjukkan aktivitas antioksidan sedang hingga kuat; metode ABTS dan FRAP lebih dominan dibandingkan DPPH.	Nilai IC ₅₀ : ABTS: 36.389 FRAP: 48.275 DPPH: 174.645
(Malang et al., 2022)	CNN	Klasifikasi citra tanah nikel dan non-nikel.	CNN berhasil mengklasifikasikan tanah berdasarkan kandungan nikel dari citra dengan akurasi tinggi.	96%
(Saputra et al., 2021)	CNN + <i>MobileNet V1</i>	Deteksi 3 penyakit daun padi	Aplikasi mobile klasifikasi penyakit daun padi berhasil mencapai performance yang cukup akurat.	Train: 100% Validasi: 83.33%, CM 92%

2.2 Mekanisme DPPH scavenging

Kemampuan suatu senyawa dalam menangkap radikal bebas berkaitan erat dengan kemampuannya menyumbangkan elektron atau atom hidrogen. Molekul yang mampu menyumbangkan elektron atau hidrogen akan bereaksi dengan senyawa radikal seperti DPPH dan menyebabkan perubahan warna dari ungu menjadi kuning. Perubahan ini terjadi akibat transfer elektron dari senyawa antioksidan kepada radikal DPPH (Handayani et al., 2020).

Aktivitas antioksidan sangat dipengaruhi oleh struktur kimia senyawa yang terkandung dalam sampel. Proses penghambatan terhadap radikal bebas dapat

terjadi melalui mekanisme resonansi elektron dalam struktur senyawa metabolit sekunder, seperti alkaloid dan senyawa fenolik. Relokasi elektron ini mampu menstabilkan radikal bebas, sehingga menghambat terbentuknya radikal baru dan memutus rantai reaksi radikal (Isrianto & Tania, 2019).

Flavonoid merupakan salah satu kelompok senyawa polifenol yang tersusun atas 15 atom karbon dengan struktur dasar C₆-C₃-C₆. Struktur ini terdiri atas dua gugus aromatik (C₆) yang dihubungkan oleh rantai tiga karbon (C₃). Senyawa flavonoid dikenal memiliki aktivitas biologis sebagai antioksidan yang dapat mencegah kerusakan oksidatif dan berbagai penyakit yang disebabkan oleh reaksi radikal bebas (Wang et al., 2018). Salah satu model yang umum digunakan untuk mengevaluasi kemampuan senyawa dalam menangkap radikal bebas adalah model DPPH (2,2-difenil-1-pikrilhidrazil) (Oktaria & Marpaung, 2023).

Uji aktivitas antioksidan dengan model DPPH didasarkan pada kemampuan senyawa antioksidan dalam mereduksi radikal DPPH, yang ditunjukkan melalui perubahan warna larutan. Warna ungu dari DPPH akan memudar menjadi kuning sebagai indikator terjadinya reaksi reduksi oleh senyawa antioksidan. Parameter yang digunakan untuk mengukur efektivitas antioksidan adalah nilai IC₅₀, yaitu konsentrasi senyawa yang mampu mereduksi 50% radikal DPPH. Nilai IC₅₀ yang diperoleh dalam penelitian ini adalah 174,645 µg/mL, sedangkan vitamin C sebagai pembanding memiliki nilai IC₅₀ sebesar 5,4 µg/mL. Semakin rendah nilai IC₅₀, maka semakin tinggi aktivitas antioksidan suatu senyawa (Ezra et al., 2023).

Kombinasi ekstrak dengan perbandingan 2:1 menunjukkan potensi aktivitas antioksidan tertinggi dibandingkan kombinasi lainnya. Aktivitas tersebut didukung oleh kandungan senyawa polifenol, khususnya flavonoid, yang berperan penting dalam mencegah proses oksidasi lipid. Kandungan bioaktif dalam kombinasi ekstrak tersebut diyakini menjadi faktor utama yang berkontribusi terhadap peningkatan potensi antioksidan (Samodra et al., 2023).

2.3 Klasifikasi Prenil Flavonoid

Sebagian besar prenil flavonoid dengan aktivitas antioksidan ditemukan pada keluarga Moraceae dan Fabaceae, meskipun terdapat pula beberapa di keluarga lainnya seperti Apiaceae, Asteraceae, Cannabaceae, dan Euphorbiaceae. Variasi utama dalam struktur kimia prenil flavonoid terletak pada rantai prenil yang

melekat pada struktur dasar flavonoid, dengan sub gugus yang paling umum adalah rantai 3,3-dimetilallyl. Selain itu, terdapat pula unit-unit seperti 1,1 dimetilallyl, geranyl, lavandulyl, dan farnesyl, yang dapat ditemukan pada berbagai tipe struktur flavonoid, seperti chalcones, dihidrochalcones, flavones, flavanones, isoflavones, xanthone, serta molekul kompleks lainnya.


Secara umum, tipe prenil yang paling banyak ditemukan adalah prenil yang terikat pada posisi karbon (C-prenil), sementara flavonoid yang memiliki gugus prenil yang terikat melalui oksigen (O-prenil) relatif lebih jarang dan sebagian besar diperoleh melalui proses sintesis laboratorium, bukan dari sumber alami. Variasi pada rantai prenil, meliputi jumlah karbon, tingkat oksidasi, dehidrasi, siklisasi, maupun reduksi, berkontribusi terhadap keragaman struktur dan potensi bioaktivitas dari prenil flavonoid. Hal ini menunjukkan bahwa variasi kimiawi tersebut memainkan peranan penting dalam menentukan aktivitas antioksidan dan sifat farmakologis dari senyawa ini.

Dalam uraian ini, istilah "prenyl" digunakan secara umum untuk mencakup berbagai gugus seperti prenil, isopentenil, geranyl, serta farnesil, termasuk derivat furano maupun kromano yang mengandung gugus methyl. Dengan demikian, keberagaman struktur dan distribusi alami dari prenil flavonoid menunjukkan potensi besar sebagai agen antioksidan yang alami maupun sintetis, serta memberikan dasar bagi pengembangan lebih lanjut di bidang kimia organik dan farmasi (Santos & Silva, 2020).

Tabel 2.2 Subkelas Prenil Flavonoid dan Aktivitas Biologisnya

Subkelas Flavonoid	Jenis Rantai Prenil	Posisi Substitusi	Contoh Senyawa	Aktivitas Biologis
Flavon	1-Dimetilalil	C-6	Sophoflavescenol	Antiinflamasi
Flavanon	Geranil	C-8	Sophoraflavanone G	Antibakteri
Chalcon	Lavandulil	C-3'	Kuraridin	Sitotoksik
Isoflavon	Farnesil	C-6	Glabridin	Antioksidan


Berikut ini disajikan gambar yang menunjukkan struktur kimia dari 3-methoxyxanthohumol H, yang merupakan salah satu senyawa aktif golongan prenil flavonoid.



Gambar 2.1 Struktur kimia 3-methoxyxanthohumol H (Santos & Silva, 2020)

Gambar 2.1 memperlihatkan struktur 3-methoxyxanthohumol H yang termasuk dalam kelompok senyawa prenil flavonoid aktif. Struktur ini memiliki kerangka chalcone terbuka dengan sistem ikatan rangkap terkonjugasi antara cincin aromatik dan gugus karbonil. Keberadaan gugus hidroksi ($-OH$) dan metoksi ($-OCH_3$) berperan sebagai pendonor elektron yang mampu menstabilkan radikal melalui mekanisme resonansi. Selain itu, gugus prenil teroksigenasi yang membentuk cincin tambahan meningkatkan sifat lipofilik senyawa serta berkontribusi dalam memperkuat potensi aktivitas antioksidan. Karakteristik tersebut merupakan ciri umum senyawa prenil flavonoid yang memiliki aktivitas biologis tinggi.

Berikut ini disajikan gambar yang menunjukkan struktur kimia 3-epi-lupinifolinol, yang diklasifikasikan sebagai senyawa prenil flavonoid tidak aktif.



Gambar 2.2 Struktur kimia 3-epi-lupinifolinol (Santos & Silva, 2020)

Gambar 2.2 menampilkan struktur 3-epi-lupinifolinol yang tergolong senyawa prenil flavonoid tidak aktif. Molekul ini memiliki struktur yang lebih kompleks dan bersifat siklik dengan konfigurasi cincin yang relatif kaku serta orientasi gugus fungsi yang berbeda. Meskipun mengandung gugus prenil dan hidroksi, posisi dan orientasi gugus tersebut tidak mendukung terbentuknya sistem konjugasi elektron yang efektif. Selain itu, perbedaan konfigurasi stereokimia pada atom karbon tertentu membatasi kemampuan molekul dalam mendonorkan atom hidrogen atau elektron, sehingga aktivitas antioksidannya relatif rendah.

2.4 Convolutional Neural Network (CNN)


2.4.1 Definisi Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu arsitektur *deep learning* yang termasuk dalam pengembangan jaringan saraf tiruan (*Artificial Neural Network*) dan dirancang secara khusus untuk mengolah data berstruktur dua dimensi, seperti citra. CNN merupakan salah satu teknik pembelajaran mesin yang termasuk dalam kategori model *Multi-Layer Perceptron* (MLP) dan didesain secara khusus untuk mengolah data berstruktur dua dimensi. Model ini digolongkan sebagai Deep Neural Network berdasarkan konfigurasi tingkat jaringannya dan penggunaannya yang luas dalam bidang analisis citra digital (Hidayati & Putra, 2024). Pada masa kini, model CNN dianggap sebagai pendekatan dengan tingkat akurasi tertinggi karena kemampuannya dalam meniru sistem pengenalan visual yang terdapat pada korteks visual manusia (Hakim et al., 2023).

2.4.2 Mekanisme Convolutional Neural Network (CNN)

CNN terdiri atas beberapa lapisan yang dirancang khusus untuk pengenalan citra kompleks secara efektif. CNN memiliki kemampuan yang baik dalam mengekstraksi fitur penting dari citra guna mencapai tingkat kepercayaan (*confidence rate*) yang tinggi, menyerupai cara kerja otak manusia. Dalam proses identifikasi dan klasifikasi, CNN memanfaatkan banyak lapisan yang saling terhubung untuk memperoleh hasil identifikasi yang akurat. Kumpulan lapisan ini membentuk arsitektur CNN yang berfungsi untuk mengenali objek dalam gambar.

Gambar di bawah ini memperlihatkan rangkaian proses CNN dalam menganalisis citra input dan mengklasifikasikannya ke dalam kategori yang sesuai berdasarkan hasil nilai output (Batubara & Awangga, 2020).



Gambar 2.3 Struktur *Convolutional Neural Network* (CNN) (Hakim et al., 2023)


Secara umum, arsitektur CNN terbagi menjadi dua bagian utama, yaitu Feature Extraction Layer (*Feature Learning*) dan *Fully Connected Layer* (Multilayer Perceptron/MLP) yang berfungsi sebagai klasifikasi. Feature Extraction Layer bertugas untuk mengubah gambar input menjadi sejumlah fitur numerik (feature encoding) yang mewakili karakteristik gambar tersebut, yang selanjutnya diproses pada tahap klasifikasi untuk menghasilkan output yang sesuai (Batubara & Awangga, 2020).

2.5 *MobileNetV2*

MobileNetV2 merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan dengan fokus pada efisiensi komputasi dan kebutuhan sumber daya yang rendah. Arsitektur ini dirancang agar dapat diimplementasikan pada perangkat dengan keterbatasan sumber daya, seperti perangkat bergerak dan embedded systems, tanpa menurunkan tingkat akurasi dalam tugas klasifikasi citra. Salah satu ciri utama *MobileNetV2* adalah penerapan depthwise separable convolution, yaitu teknik yang memisahkan proses konvolusi menjadi dua tahap, yakni depthwise convolution dan pointwise convolution. Pendekatan ini terbukti mampu mengurangi jumlah parameter serta beban komputasi secara signifikan dibandingkan dengan konvolusi standar (Rafli et al., 2025).

Selain itu, *MobileNetV2* memperkenalkan konsep inverted residuals dan linear bottleneck yang berfungsi untuk menjaga kelancaran aliran informasi selama proses propagasi jaringan (Zhan, 2024). Struktur inverted residual block memungkinkan model mempertahankan fitur-fitur penting dengan cara memperluas dimensi fitur terlebih dahulu sebelum memproyeksikannya kembali ke dimensi yang lebih rendah. Strategi ini tidak hanya meminimalkan kehilangan informasi, tetapi juga

meningkatkan efisiensi komputasi secara keseluruhan. Dokumentasi *MobileNetV2* menjelaskan bahwa penggunaan blok residual terbalik memungkinkan model mencapai performa yang optimal dengan tingkat kompleksitas yang lebih rendah.



Gambar 2.4 Arsitektur *MobileNetV2* (Rafli et al., 2025)

Keunggulan yang dimiliki *MobileNetV2* menjadikannya sebagai pilihan yang tepat dalam tugas klasifikasi citra yang memerlukan ekstraksi fitur secara konsisten, termasuk pada klasifikasi motif batik seperti motif Kawung yang memiliki pola berulang dan detail visual tertentu. Struktur model yang ringan memungkinkan proses pelatihan berlangsung lebih cepat, sementara kemampuannya dalam menangkap pola tekstur membuatnya efektif dalam membedakan motif batik dengan karakteristik geometris yang serupa (Rafli et al., 2025). Dengan demikian, *MobileNetV2* memiliki potensi besar dalam menghasilkan model klasifikasi yang efisien, akurat, serta mudah diimplementasikan dalam skala yang lebih luas.

2.6 Google Collab

Google Collaboratory atau *Google Collab* merupakan platform komputasi *cloud* yang dikembangkan oleh Google untuk menyediakan lingkungan pengembangan berbasis web yang memungkinkan pengguna menulis dan menjalankan kode Python tanpa memerlukan instalasi perangkat lunak atau konfigurasi sistem tambahan. Platform ini memanfaatkan infrastruktur *cloud* Google yang menyediakan akses gratis terhadap sumber daya komputasi tinggi seperti *Graphics Processing Unit* (GPU) dan *Tensor Processing Unit* (TPU), serta menawarkan fitur kolaborasi yang memungkinkan pengguna berbagi dan bekerja sama dalam pengembangan notebook secara *real-time*. *Google Collab* menjadi solusi efektif bagi pengembang, peneliti, dan pemula dalam bidang pemrograman

Python untuk menjalankan proyek komputasi intensif tanpa terbatas oleh keterbatasan perangkat keras lokal (Nazar, 2024).

2.7 Python

Python merupakan bahasa pemrograman berbasis interpreter yang memiliki kemampuan untuk menerjemahkan kode secara langsung dan dapat dioperasikan pada berbagai sistem operasi seperti Windows, Linux, dan platform lainnya. Keunggulan Python terletak pada adopsi multi-paradigma pemrograman yang menggabungkan konsep pemrograman prosedural yang diadopsi dari bahasa C, konsep pemrograman berorientasi objek yang terinspirasi dari Java, serta konsep pemrograman fungsional yang mengacu pada bahasa Lisp, sehingga fleksibilitas dari kombinasi paradigma tersebut memberikan kemudahan bagi programmer dalam mengembangkan beragam proyek perangkat lunak (Rahman et al., 2023).



BAB III

METODOLOGI PENELITIAN

3.1 Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif berbasis model komputasi untuk menilai aktivitas antioksidan senyawa prenol flavonoid secara objektif melalui data numerik. Pendekatan kuantitatif dipilih karena memungkinkan pengukuran kinerja model secara sistematis dan terukur berdasarkan hasil prediksi yang dihasilkan.

Rancangan penelitian dilakukan dengan membangun dan menguji model *Convolutional Neural Network* (CNN) yang digunakan untuk mengklasifikasikan aktivitas antioksidan senyawa prenol flavonoid berdasarkan representasi visual struktur kimia. Struktur molekul senyawa dikonversi ke dalam bentuk citra dua dimensi, kemudian digunakan sebagai data masukan untuk mempelajari hubungan antara karakteristik struktur kimia dan tingkat aktivitas antioksidan. Penelitian ini menerapkan lebih dari satu arsitektur CNN, yaitu CNN yang dirancang secara khusus serta arsitektur CNN berbasis *MobileNetV2*, guna membandingkan performa model dalam tugas klasifikasi aktivitas antioksidan. Perbandingan ini dilakukan untuk memperoleh model dengan kinerja terbaik berdasarkan hasil evaluasi yang telah ditentukan.

3.2 Waktu, Lokasi dan Objek Penelitian

Penelitian ini dilaksanakan di Program Studi Kimia, Fakultas Sains dan Teknologi, Universitas Islam Negeri Ar-Raniry Banda Aceh. Penelitian berlangsung mulai tanggal 26 Juni 2025 hingga 15 Januari 2026, sampai seluruh tahapan penerapan dan evaluasi model CNN dinyatakan selesai.

Objek penelitian dalam penelitian ini adalah senyawa prenol flavonoid yang dianalisis berdasarkan struktur kimia dan aktivitas antioksidannya, yang selanjutnya digunakan sebagai data masukan dalam penerapan *Convolutional Neural Network* (CNN) untuk menilai aktivitas antioksidan.

3.3 Populasi dan Sampel

Populasi dalam penelitian ini adalah seluruh data senyawa prenil flavonoid yang memiliki informasi struktur kimia dan aktivitas antioksidan yang terdokumentasi dalam literatur ilmiah, khususnya pada penelitian yang dilaporkan oleh Santos dan Silva (2020).

Sampel penelitian berupa data sekunder senyawa prenil flavonoid yang digunakan sebagai data masukan dalam penerapan model *Convolutional Neural Network* (CNN) untuk klasifikasi aktivitas antioksidan. Pemilihan sampel dilakukan berdasarkan kriteria tertentu, yaitu senyawa memiliki struktur kimia yang jelas dan informasi aktivitas antioksidan yang dapat digunakan sebagai label klasifikasi.

Aktivitas antioksidan senyawa diklasifikasikan ke dalam dua kategori, yaitu aktif dan tidak aktif, berdasarkan nilai IC_{50} yang dilaporkan dalam literatur. Berdasarkan proses seleksi tersebut, diperoleh sebanyak 153 senyawa prenil flavonoid sebagai sampel penelitian, yang terdiri atas 83 senyawa dengan aktivitas antioksidan aktif dan 70 senyawa dengan aktivitas antioksidan tidak aktif.

Dataset ini selanjutnya digunakan sebagai data pelatihan dan pengujian pada model CNN, termasuk arsitektur CNN yang dirancang secara khusus serta arsitektur berbasis *MobileNetV2*, untuk mengevaluasi kemampuan model dalam mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid.

3.4 Alat dan Bahan Penelitian

Perangkat yang digunakan dalam penelitian ini berperan sebagai media untuk melaksanakan proses pengolahan, pelatihan model CNN, serta pengolahan data. Spesifikasi perangkat dapat dilihat pada tabel 3.1.

Tabel 3.1 Spesifikasi Perangkat Keras dan Platform

Komponen	Spesifikasi / Keterangan
Perangkat Keras	DESKTOP-676T6BI
Prosesor	Intel(R) Celeron(R) N4000 CPU @ 1.10GHz
RAM	4,00 GB
Penyimpanan	1.13 TB
Sistem Operasi	Windows 11 Home Single Language, Versi 24H2, Build OS 26100.4351
Platform Cloud	Google Colab (berbasis Google Compute Engine)
Perangkat Lunak	ChemSketch (membuat ulang gambar struktur kimia)





3.5 Teknik Pengumpulan Data





Teknik pengumpulan data dalam penelitian ini dilakukan melalui peninjauan literatur dengan mengekstraksi data struktur kimia dan nilai aktivitas antioksidan (IC_{50}) senyawa prenil flavonoid dari artikel ilmiah (Santos & Silva, 2020), menggambar ulang struktur molekul menggunakan perangkat lunak ChemSketch, serta mengelompokkan senyawa ke dalam kategori aktif ($IC_{50} < 50 \mu\text{g/mL}$) dan tidak aktif ($IC_{50} \geq 50 \mu\text{g/mL}$) berdasarkan kriteria Oktaria dan Marpaung (2023) sebagai dasar pelatihan model *Convolutional Neural Network* (CNN).




Berdasarkan teknik pengumpulan data yang telah dijelaskan, diperoleh dataset senyawa prenil flavonoid yang digunakan dalam penelitian ini. Daftar senyawa yang diklasifikasikan ke dalam kategori aktif dan tidak aktif berdasarkan nilai IC_{50} disajikan pada Tabel 3.2.









Tabel 3.2 Daftar dataset senyawa yang akan diuji





No	Nama Senyawa	Struktur	IC ₅₀	Aktivitas
1.	2,3,4,4,5-pentahydroxy-6-methoxy-3-prenylchalcone		30.3	Aktif
2.	7-Prenylbaicalein		8.8	Aktif
3.	7-Geranylbaicalein		8.7	Aktif
4.	7-Farnesylbaicalein		10.6	Aktif




5.	Kuraridin		2.89	Aktif
6.	Kuraridinol		2.19	Aktif
7.	Kushenol C		0.62	Aktif
8.	Hydroxyartoflavone A		20.9	Aktif





9.	Isocycloartobiloxanthone		7.2	Aktif
10	Artogomezianone		36.9	Aktif
11	Cudraflavone B		40.6	Aktif




12.	Artelastoheterol		42.2	Aktif
13.	Artonol A		43.3	Aktif
14.	Cycloartobiloxanthone		26.8	Aktif





15.	Cycloartelastoxanthone		18.7	Aktif
16.	Artoflavone A		24.2	Aktif
17.	Pyranocycloartobiloxanthone A		20.2	Aktif




18.	4',5,7-Trihydroxy-8-prenylisoflavone		6.42	Aktif
19.	Alpinum isoflavone		8.3	Aktif
20.	Elastichalcone B		11.3	Aktif
21.	Cycloartocarpesin B		11.89	Aktif




22	Sophoraflavanone G		5.26	Aktif
23.	Kurarinone		3.42	Aktif
24.	Artoindonesianin C		>120	Tidak Aktif




25.	Novel flavanone A		75.3	Tidak Aktif
26.	Euchrestaflavanone C		52.5	Tidak Aktif
27.	Artocarpin		4.70	Aktif
28.	8-Geranyl-3-(hydroxyprenyl)isoetin		156.9	Tidak Aktif




29.	Cyclocommunol		>300	Tidak Aktif
30.	Glyasperin A		2.5	Aktif
31.	4,5-dihydroxy-6,7-(2,2-dimethylpyrano)-2-methoxy-8-(-, -dimethyl)allylflavone		>400	Tidak Aktif




32.	Khonklonginol A		7919	Tidak Aktif
33.	Flemichin D		538	Tidak Aktif
34.	Macakurzin C		Tidak Terdeteksi	Tidak Aktif
35.	Artonol B		>120	Tidak Aktif



36.	Cudraflavone A		>300	Tidak Aktif
37.	Chaplashin		>400	Tidak Aktif
38.	Cycloartocarpin		690	Tidak Aktif



39.	5,7-Dihydroxy-6-prenylflavanone		Tidak Terdeteksi	Tidak Aktif
40.	5,7-Dihydroxy-4'-methoxy-6-methyl-8-prenylflavanone		Tidak Terdeteksi	Tidak Aktif
41.	Cycloheterophyllin		9.6	Aktif

42.	Bartericin A		47.85	Aktif
43.	6,8-diprenylerioidictyol		32.12	Aktif
44.	Isobavachalcone		88.33	Tidak Aktif





45.	6-prenylapigenin		86.43	Tidak Aktif
46.	Dorsmanin F		53.89	Tidak Aktif
47.	Euchrestaflavanone B		34.6	Aktif




48.	Propolin A		9	Aktif
49.	Propolin B		10.9	Aktif
50.	Prokinawan		5.2	Aktif



51.	Propolin E		62.6	Tidak Aktif
52.	Nymphaeol A		6.5	Aktif




53.	Nymphaeol B		7.1	Aktif
54.	Nymphaeol C		9.8	Aktif




55.	3'-geranylnaringenin		64.2	Tidak Aktif
56.	Isonymphaeol-B		8.5	Aktif
57.	Artonin A		6.0	Aktif




58.	2-O-methylartonin E		Tidak Terdeteksi	Tidak Aktif
59.	2-O-methylisoartonin E		Tidak Terdeteksi	Tidak Aktif
60.	2-O-methyldihydroisoartonin E		Tidak Terdeteksi	Tidak Aktif
61.	2-O-methylartonin V		Tidak Terdeteksi	Tidak Aktif





62.	Artobiloxanthone		Tidak Terdeteksi	Tidak Aktif
63.	Leachianone		3.17	Aktif
64.	Kushenol E		3.35	Aktif



65.	Kurarinol		3.64	Aktif
66.	Cyclogeracommunin		73.3	Tidak Aktif




67.	Artomandin		38	Aktif
68.	10-oxoartogomezianone		>300	Tidak Aktif
69.	8-geranylapigenin		>300	Tidak Aktif





70.	Artonin M		>300	Tidak Aktif
71.	Cyclomorusin		>300	Tidak Aktif
72.	3,5,2,4-tetrahydroxy-6,6-dimethylpyrano (2,3:7,6)-8-prenylflavone		35	Aktif




73.	2'',3''-epoxykhonklonginol A		2553	Tidak Aktif
74.	Lupinifolinol		1768	Tidak Aktif
75.	3-epi-lupinifolinol		681	Tidak Aktif




76.	2-hydroxylupinifolinol		252	Tidak Aktif
77.	Angustone C		24.38	Aktif
78.	4'-acetylalpinum isoflavone		2.32	Aktif
79.	3'-hydroxycycloartocarpin		152.9	Tidak Aktif




80.	4'-O-methyllicoflavanone		648.1	Tidak Aktif
81.	Shinpterocarpin		909.8	Tidak Aktif




82.	Phaseollin		241.9	Tidak Aktif
83.	8-prenyldaidzein		174.2	Tidak Aktif
84.	Flemichapparin A		131.0	Tidak Aktif





85.	Artonin E		151.6	Tidak Aktif
86.	Cudraflavone C		3.35	Aktif
87.	Tephrosin		55.58	Tidak Aktif
88.	Broussoflavonol F		708.54	Tidak Aktif





89.	4-O-methylalpinum isoflavone		83.6	Tidak Aktif
90.	5,7-Dihydroxy-6-methyl-8-prenylflavanone		Tidak Terdeteksi	Tidak Aktif
91.	5-dihydroxy-7-methoxy-6-prenylflavanone		Tidak Terdeteksi	Tidak Aktif




92.	5,7-dihydroxy-4-methoxy-8-prenylflavanone		Tidak Terdeteksi	Tidak Aktif
93.	Isoxanthohumol		7.6	Aktif
94.	4'-O-acetylisoxanthohumol		59.7	Tidak Aktif




95.	7,4'-di-O-acetylisoxanthohumol		73.5	Tidak Aktif
96.	4,4'-di-O-pivaloylxanthohumol		37	Aktif
97.	Xanthohumol		6.0	Aktif




98.	Erynone		Tidak Terdeteksi	Aktif
99.	Wighteone		Tidak Terdeteksi	Tidak Aktif
100.	Luteone		Tidak Terdeteksi	Tidak Aktif





101.	Ficusin A		42.4	Aktif
102.	Ficusin C		49.3	Aktif
103.	6-[(1R,6R)-3-methyl-6-(1-methylethenyl)-2-cyclohexen-1-yl]-5,7,4'-trihydroxyisoflavone		43.3	Aktif
104.	2',4',6'-trihydroxy-3'-prenylchalcone		817.94	Tidak Aktif





105.	Artonin B		4.5	Aktif
106.	4-O-acetylxanthohumol		15	Aktif
107.	4-O-decanoylxanthohumol		Tidak Terdeteksi	Aktif
108.	Desmethylxanthohumol		0.54	Aktif





109.	Isoglabranin		130.0	Tidak Aktif
110.	Glabranin		128.9	Tidak Aktif
111.	7-methoxyisoglabranin		128.2	Tidak Aktif




112.	Heliteretifolin		135.6	Tidak Aktif
113.	Licochalcone A		Tidak Terdeteksi	Tidak Aktif
114.	Morusin		Tidak Terdeteksi	Tidak Aktif




115.	Licoricidin		Tidak Terdeteksi	Tidak Aktif
116.	Licorisoflavan A		Tidak Terdeteksi	Tidak Aktif
117.	3-hydroxyxanthohumol		2.5	Aktif





118.	Xanthogalenol		28.3	Aktif
119.	4-O-methylxanthohumol		11.8	Aktif
120.	2,2,4-trihydroxy-6-methoxy-3-prenylchalcone		5.9	Aktif
121.	2,3,4-trihydroxy-6-methoxy-3-prenylchalcone		4.8	Aktif




122.	2H-chromene-6,8-diyl)]bis[3-(2,3,4-trihydroxyphenyl)prop 2-en-1-one]		0.54	Aktif
123.	2,3,4,5-tetrahydroxy-6-methoxy-3-prenylchalcone		3.2	Aktif
124.	3-methoxyxanthohumol H		36.9	Aktif
125.	5-prenyl-xanthohumol		9.7	Aktif



126.	Xanthohumol H		9.2	Aktif
127.	Xanthohumol C		12.5	Aktif
128.	1'',2''-dihydroxanthohumol C		15.4	Aktif
129.	3'-geranyl-6'-O-methylchalconaringenin		8.2	Aktif




130.	2'-O-methyl-3'-prenylchalconaringenin		10.4	Aktif
131.	3-hydroxyxanthohumol H		32.8	Aktif
132.	8-prenylnaringenin		67	Tidak Aktif




133.	Dorsmanin C		Tidak Terdeteksi	Tidak Aktif
134.	Floranol		Tidak Terdeteksi	Tidak Aktif
135.	Artocarpetin A		100	Tidak Aktif




136.	Dehydrocycloxanthohumol		32	Aktif
137.	Dehydrocycloxanthohumol hydrate		37	Aktif
138.	3-geranylchalconaringenin		Tidak Terdeteksi	Aktif
139.	4-O-5-C-diprenylxanthohumol		88	Tidak Aktif

140.	Tetrahydroxanthohumol		92	Tidak Aktif
141.	6-prenylnaringenin		78	Tidak Aktif
142.	6,8-diprenylnaringenin		85	Tidak Aktif


143.	6-geranylnaringenin		84	Tidak Aktif
144.	8-geranylnaringenin		68	Tidak Aktif

145.	2,4-dihydroxy-3,4,6-trimethoxy-3-prenylchalcone		Tidak Terdeteksi	Aktif
146.	4,6-dihydroxy-2,4-dimethoxy-3-prenylchalcone		Tidak Terdeteksi	Aktif
147.	3-hydroxyxanthohumol C		Tidak Terdeteksi	Aktif

148.	3-methoxyxanthohumol C		Tidak Terdeteksi	Aktif
149.	3-methoxyxanthohumol		Tidak Terdeteksi	Aktif
150.	4,4'-Di-O-acetyl-xanthohumol		11.75	Aktif

151.	4-O-pivaloylxanthohumol		Tidak Terdeteksi	Aktif
152.	4-O dodecanoylxanthohumol		Tidak Terdeteksi	Aktif
153.	4,4-di-O-dodecanoylxanthohumol		Tidak Terdeteksi	Aktif

3.6 Teknik Analisis Data



Gambar 3.1 Teknik Analisis Data

BAB IV

HASIL DAN PEMBAHASAN

4.1 Tahapan Persiapan Data

Tahapan persiapan data merupakan tahap awal yang sangat penting dalam penelitian ini karena kualitas data yang digunakan akan sangat memengaruhi kinerja model CNN. Pada tahap ini, data citra struktur molekul senyawa prenil flavonoid dikumpulkan, diseleksi, dan disiapkan agar memiliki format yang seragam serta layak digunakan sebagai masukan model.

Dataset yang digunakan dalam penelitian ini berjumlah 153 citra struktur molekul, yang terdiri atas 83 senyawa dengan aktivitas antioksidan aktif dan 70 senyawa dengan aktivitas antioksidan tidak aktif. Komposisi data yang relatif seimbang ini diharapkan dapat membantu model CNN dalam mempelajari pola visual struktur molekul secara lebih optimal serta mengurangi potensi bias klasifikasi.

Pada tahap persiapan data dilakukan pengecekan kelengkapan struktur kimia, keseragaman format gambar, serta kualitas visual citra molekul. Seluruh citra molekul disiapkan dalam format gambar yang sama untuk memastikan konsistensi data. Langkah ini bertujuan agar model CNN dapat mengekstraksi fitur visual struktur molekul secara efektif tanpa dipengaruhi oleh perbedaan format atau kualitas citra.


4.2 Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan melalui dua pendekatan utama. Pendekatan pertama dilakukan dengan mengambil gambar struktur molekul senyawa prenil flavonoid yang disajikan dalam artikel ilmiah oleh Santos dan Silva (2020). Pendekatan ini dipilih karena sumber tersebut menyediakan informasi struktur kimia dan aktivitas antioksidan yang telah divalidasi secara ilmiah.

Pendekatan kedua dilakukan dengan menggambar ulang struktur molekul menggunakan perangkat lunak kimia ChemSketch. Proses ini bertujuan untuk memastikan kejelasan dan keseragaman representasi visual struktur molekul. Struktur molekul yang telah digambar ulang kemudian disimpan dalam format


gambar PNG dan digunakan sebagai bagian dari dataset penelitian. Daftar struktur molekul senyawa prenil flavonoid yang digunakan disajikan pada Tabel 3.1.

Tangkapan layar proses pembuatan gambar struktur molekul menggunakan perangkat lunak ChemSketch yang digunakan dalam penelitian ini. Seperti terlihat pada gambar 4.1.



Gambar 4.1 Pembuatan struktur molekul menggunakan ChemSketch

Setiap gambar struktur molekul digunakan sebagai data masukan (input) visual pada model CNN untuk memprediksi aktivitas antioksidan berdasarkan pola visual yang terbentuk dari susunan atom dan gugus fungsi senyawa. Contoh citra struktur molekul ditunjukkan pada Gambar 4.2 yang memperlihatkan struktur senyawa prenil xanthohumol.



Gambar 4.2 Struktur Senyawa Prenil Xanthohumol

Gambar 4.2 menunjukkan struktur molekul xanthohumol, salah satu senyawa prenil flavonoid yang digunakan dalam penelitian ini. Struktur molekul dalam bentuk citra seperti ini dianalisis menggunakan model CNN untuk mengidentifikasi pola visual tertentu yang berkaitan dengan aktivitas antioksidan. Seluruh struktur molekul dalam dataset memiliki format representasi yang seragam, sehingga proses

pelatihan dan pengujian model CNN dapat dilakukan secara konsisten dan terkontrol.


4.3 Data Preprocessing

Tahapan *data preprocessing* dilakukan untuk menyiapkan citra struktur senyawa molekul agar dapat diproses secara optimal oleh model *Convolutional Neural Network* (CNN) dan *MobileNetV2*. Preprocessing yang tepat sangat penting karena kualitas data masukan berpengaruh langsung terhadap kemampuan model dalam mengekstraksi fitur dan melakukan klasifikasi secara akurat.

Pada penelitian ini, dataset berupa citra dua dimensi struktur senyawa molekul yang terbagi ke dalam dua kelas, yaitu *Senyawa Aktif* dan *Senyawa Tidak Aktif*. Seluruh data citra disimpan dalam format RGB dan memiliki variasi ukuran serta resolusi yang berbeda-beda. Oleh karena itu, dilakukan beberapa tahapan preprocessing sebagai berikut.

4.3.1 Penyesuaian ukuran citra (*Image Resizing*)

Langkah pertama dalam proses *data preprocessing* adalah penyesuaian ukuran citra (*image resizing*). Gambar 4.3 memperlihatkan contoh citra struktur senyawa molekul sebelum dilakukan proses *resizing*, di mana setiap citra masih memiliki ukuran dan resolusi yang bervariasi. Perbedaan ukuran tersebut dapat menyebabkan ketidakkonsistenan dimensi masukan pada model jaringan saraf. Oleh karena itu, seluruh citra senyawa diseragamkan ukurannya menjadi 224×224 piksel, sebagaimana ditunjukkan pada Gambar 4.4, yang merupakan hasil citra setelah dilakukan proses *resizing*. Ukuran ini dipilih karena merupakan ukuran standar masukan yang digunakan pada arsitektur *Convolutional Neural Network* (CNN) dan *MobileNetV2*.



Gambar 4.3 struktur senyawa molekul sebelum dilakukan proses resizing



Gambar 4.4 struktur senyawa molekul setelah dilakukan proses resizing

Penyesuaian ukuran citra bertujuan untuk memastikan bahwa seluruh data masukan memiliki dimensi yang konsisten sehingga dapat diproses secara seragam oleh model. Selain itu, proses *resizing* juga membantu mengurangi kompleksitas komputasi serta mempercepat proses pelatihan model tanpa menghilangkan informasi visual utama yang merepresentasikan struktur molekul.

4.3.2 Normalisasi Nilai Piksel (*Rescaling*)


Setelah dilakukan penyeragaman ukuran, nilai piksel citra dinormalisasi dengan cara membagi setiap nilai piksel dengan 255. Proses ini mengubah rentang nilai piksel dari 0–255 menjadi 0–1. Normalisasi dilakukan untuk meningkatkan stabilitas proses pelatihan dan mempercepat konvergensi model selama optimisasi bobot.

Normalisasi nilai piksel juga membantu mencegah dominasi nilai besar pada proses perhitungan gradien, sehingga model dapat mempelajari pola fitur secara lebih efektif.

4.3.3 Augmentasi Data

Pada tahap awal penelitian, dilakukan *augmentasi data* untuk meningkatkan variasi citra pelatihan. Teknik augmentasi yang diterapkan meliputi rotasi, pergeseran (*shift*), pembesaran (*zoom*), serta pembalikan citra (*horizontal flip*). Gambar 4.5 memperlihatkan contoh citra struktur senyawa molekul setelah dilakukan proses augmentasi, di mana terjadi perubahan orientasi (rotasi) dan posisi citra dibandingkan dengan citra aslinya.

Contoh Gambar Setelah Augmentasi



Gambar 4.5 struktur senyawa molekul setelah dilakukan proses augmentasi

Penerapan augmentasi data bertujuan untuk memperkaya variasi data latih sehingga model diharapkan mampu meningkatkan kemampuan generalisasi. Namun, berdasarkan karakteristik citra struktur molekul yang bersifat simbolik dan memiliki makna visual yang spesifik, perubahan geometrik seperti rotasi dan pembalikan citra berpotensi mengubah interpretasi struktur kimia yang terkandung di dalam citra.

4.3.4 Pembentukan Data Generator dan Pembagian Dataset

Setelah proses preprocessing selesai, dataset selanjutnya disiapkan menggunakan data generator untuk mengatur pemuatan data serta pembagian dataset. Pembagian data dilakukan menjadi data latih dan data validasi dengan rasio 80% untuk data latih dan 20% untuk data validasi menggunakan parameter *validation_split*.

Data dimuat dalam bentuk *batch* dengan ukuran *batch size* sebesar 16 untuk meningkatkan efisiensi komputasi selama pelatihan. Data latih diacak (*shuffle*) guna meningkatkan variasi pembelajaran, sedangkan data validasi tidak diacak agar evaluasi model tetap konsisten. Tahap ini memastikan data disajikan secara terstruktur dan siap digunakan dalam proses pelatihan serta evaluasi model.

4.4 Pelatihan Model

Pada tahap pelatihan model, penelitian ini menggunakan dua pendekatan berbeda, yaitu *Convolutional Neural Network* (CNN) dasar dan model transfer learning *MobileNetV2*. Kedua model dilatih menggunakan data hasil preprocessing

dan pembagian dataset yang telah dilakukan sebelumnya. Pelatihan dilakukan untuk mempelajari pola visual pada citra struktur molekul dalam mengklasifikasikan senyawa aktif dan senyawa tidak aktif.

Proses pelatihan menerapkan fungsi loss binary cross-entropy dan algoritma optimasi Adam dengan learning rate awal sebesar 0,0001. Untuk meningkatkan stabilitas dan kinerja model, digunakan mekanisme callback berupa early stopping dan learning rate reduction berdasarkan nilai validation loss.

4.4.1 Pelatihan Model CNN

Pelatihan model CNN dilakukan menggunakan arsitektur CNN dasar yang terdiri dari beberapa lapisan konvolusi, batch normalization, max pooling, serta lapisan fully connected. Model ini dirancang untuk mengekstraksi fitur visual dari citra struktur molekul secara bertahap, mulai dari fitur sederhana hingga fitur yang lebih kompleks.

Pada proses pelatihan, digunakan batch size sebesar 16 dan jumlah epoch maksimum sebanyak 30. Untuk mengatasi ketidakseimbangan jumlah data antar kelas, diterapkan class weight pada proses pelatihan. Pendekatan ini bertujuan agar model CNN tidak bias terhadap kelas tertentu dan mampu mengenali karakteristik senyawa aktif maupun senyawa tidak aktif secara lebih proporsional.

Selain itu, mekanisme early stopping digunakan untuk menghentikan pelatihan secara otomatis ketika nilai validation loss tidak mengalami perbaikan dalam beberapa epoch berturut-turut. Reduce Learning Rate on Plateau juga diterapkan untuk menurunkan learning rate secara adaptif sehingga proses pembaruan bobot dapat berjalan lebih optimal.

4.4.2 Pelatihan Model *MobileNetV2*

Pelatihan model *MobileNetV2* dilakukan dengan pendekatan transfer learning, di mana model dasar *MobileNetV2* yang telah dilatih pada dataset ImageNet digunakan sebagai feature extractor. Pada tahap awal, sebagian besar layer pada model dasar dibekukan untuk mempertahankan fitur umum yang telah dipelajari sebelumnya.

Beberapa layer akhir dibuka untuk proses fine-tuning agar model dapat menyesuaikan representasi fitur dengan karakteristik citra struktur molekul. Pada bagian atas model ditambahkan lapisan Global Average Pooling, lapisan dense,

serta dropout untuk meningkatkan kemampuan klasifikasi dan mengurangi risiko overfitting.

Proses pelatihan *MobileNetV2* menggunakan konfigurasi pelatihan yang sama dengan model CNN, termasuk fungsi loss, algoritma optimasi, jumlah epoch, serta mekanisme callback. Pendekatan ini memungkinkan perbandingan performa yang lebih adil antara model CNN dasar dan model *MobileNetV2*.

4.5 Evaluasi Model

Evaluasi model dilakukan untuk menilai kinerja model CNN dan *MobileNetV2* dalam mengklasifikasikan citra struktur molekul menjadi senyawa aktif dan senyawa tidak aktif. Evaluasi dilakukan menggunakan grafik akurasi dan loss, *confusion matrix*, serta metrik klasifikasi yang meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik evaluasi tersebut dihitung berdasarkan nilai true positive (TP), true negative (TN), false positive (FP), dan false negative (FN) yang diperoleh dari *confusion matrix*, dengan rumus sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$


$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Pendekatan ini digunakan untuk memberikan gambaran menyeluruh mengenai kemampuan dan keterbatasan masing-masing model dalam melakukan klasifikasi.

4.5.1 Evaluasi Model CNN

Hasil pelatihan model CNN menunjukkan bahwa performa model belum optimal. Berdasarkan grafik akurasi dan loss yang ditampilkan pada Gambar 4.6, terlihat bahwa nilai akurasi pelatihan dan validasi berada pada kisaran 53–63%.

Namun demikian, nilai validation loss justru mengalami peningkatan yang signifikan seiring bertambahnya epoch, yang mengindikasikan bahwa model mengalami kesulitan dalam melakukan generalisasi terhadap data validasi. Selain itu, grafik *loss* memperlihatkan fluktuasi yang cukup tajam selama proses pelatihan. Kondisi ini menunjukkan bahwa pembaruan bobot model tidak berlangsung secara stabil, meskipun mekanisme *early stopping* dan *learning rate reduction* telah diterapkan.



Gambar 4.6 Tampilan grafik akurasi dan Loss Model CNN

Berdasarkan *confusion matrix* pada Gambar 4.7, model CNN cenderung memprediksi seluruh data ke dalam satu kelas, yaitu Senyawa Tidak Aktif. Hal ini menyebabkan model gagal mendeteksi kelas Senyawa Aktif.



Gambar 4.7 Confusion Matrix Model CNN

Hasil ini diperkuat oleh hasil *classification report* (Tabel 4.1) yang menunjukkan nilai *recall* sebesar 1,00 untuk kelas Senyawa Tidak Aktif dan 0,00 untuk kelas Senyawa Aktif.


Tabel 4.1 Hasil Evaluasi Model CNN Berdasarkan Classification Report

Kelas	Precision	Recall	F1-score	Support
Senyawa Tidak Aktif	0,53	1,00	0,70	16
Senyawa Aktif	0,00	0,00	0,00	14
Accuracy			0,53	30
Macro Average	0,27	0,50	0,35	30
Weighted Average	0,28	0,53	0,37	30

Secara keseluruhan, meskipun nilai akurasi model CNN mencapai 53%, nilai tersebut tidak mencerminkan performa klasifikasi yang baik karena model mengalami *class bias*. Hal ini menunjukkan bahwa model CNN belum mampu mengekstraksi fitur pembeda yang representatif dari citra struktur molekul.

4.5.2 Evaluasi Model *MobileNetV2*


MobileNetV2 menunjukkan performa yang lebih stabil selama proses pelatihan. Grafik akurasi dan loss yang ditunjukkan pada Gambar 4.8 memperlihatkan bahwa nilai loss cenderung menurun dan tidak mengalami lonjakan ekstrem. Meskipun akurasi validasi berada pada kisaran 46–53%, pola pembelajaran model terlihat lebih konsisten.



Gambar 4.8 Tampilan grafik akurasi dan Loss Model *MobileNetV2*

Berdasarkan *confusion matrix* pada Gambar 4.9, *MobileNetV2* mampu mengklasifikasikan kedua kelas dengan distribusi yang lebih seimbang dibandingkan CNN dasar. Model tidak lagi memprediksi seluruh data ke dalam satu

kelas, melainkan mampu mengenali baik senyawa aktif maupun senyawa tidak aktif.



Gambar 4.9 Confusion Matrix Model *MobileNetV2*

Hasil *classification report* menunjukkan bahwa *MobileNetV2* memperoleh nilai *recall* sebesar 0,79 untuk kelas Senyawa Aktif dan 0,31 untuk kelas Senyawa Tidak Aktif. Nilai *F1-score* kelas Senyawa Aktif juga lebih tinggi dibandingkan model CNN, yang menandakan bahwa *MobileNetV2* lebih efektif dalam mendeteksi senyawa aktif.

Tabel 4.2 Hasil Evaluasi Model *MobileNetV2* Berdasarkan Classification Report

Kelas	Precision	Recall	F1-score	Support
Senyawa Tidak Aktif	0,62	0,31	0,42	16
Senyawa Aktif	0,50	0,79	0,61	14
Accuracy			0,53	30
Macro Average	0,56	0,55	0,51	30
Weighted Average	0,57	0,53	0,51	30

Keunggulan *MobileNetV2* ini dipengaruhi oleh penggunaan pendekatan *transfer learning*, di mana model memanfaatkan fitur awal hasil pelatihan pada dataset ImageNet sehingga mampu mengekstraksi pola visual kompleks dari citra struktur molekul.

4.6 Hasil Pembahasan

Pada penelitian ini, evaluasi performa model dilakukan secara komprehensif untuk membandingkan kemampuan *Convolutional Neural Network* (CNN) dasar dan *MobileNetV2* dalam mengklasifikasikan citra senyawa menjadi dua kelas, yaitu *Senyawa Aktif* dan *Senyawa Tidak Aktif*. Evaluasi tidak hanya didasarkan pada nilai akurasi, tetapi juga dianalisis melalui grafik pelatihan, confusion matrix, classification report, serta implementasi sistem prediksi menggunakan nilai threshold tertentu. Pendekatan ini bertujuan untuk memberikan gambaran menyeluruh mengenai kinerja masing-masing model, baik dari sisi kuantitatif maupun perilaku prediksi.

Berdasarkan hasil pelatihan model CNN, grafik akurasi dan loss menunjukkan bahwa model mengalami ketidakstabilan selama proses training. Nilai *training accuracy* dan *validation accuracy* berfluktuasi tanpa menunjukkan tren peningkatan yang signifikan. Sementara itu, nilai *validation loss* justru cenderung meningkat seiring bertambahnya epoch, yang mengindikasikan bahwa model tidak mampu melakukan generalisasi dengan baik terhadap data validasi.

Evaluasi menggunakan confusion matrix dan classification report memperlihatkan bahwa model CNN hanya mampu mengenali satu kelas saja. Nilai recall untuk kelas *Senyawa Tidak Aktif* mencapai 1.00, sedangkan recall untuk kelas *Senyawa Aktif* bernilai 0.00. Hal ini menunjukkan bahwa seluruh data uji diklasifikasikan ke dalam satu kelas yang sama. Akurasi keseluruhan yang diperoleh sebesar 53% tidak mencerminkan kemampuan klasifikasi yang baik, melainkan disebabkan oleh distribusi data uji yang relatif seimbang antar kelas.

Kelemahan model CNN semakin terlihat pada tahap implementasi sistem prediksi. Nilai probabilitas prediksi yang dihasilkan model berada pada rentang yang sangat sempit, dengan nilai minimum sebesar 0.358, nilai maksimum 0.448, dan nilai rata-rata 0.407. Rentang prediksi ini menunjukkan bahwa model CNN tidak memiliki tingkat keyakinan yang cukup dalam membedakan kedua kelas. Dengan penerapan threshold sebesar 0.5 pada sistem prediksi, seluruh nilai probabilitas berada di bawah ambang batas tersebut, sehingga semua citra senyawa diklasifikasikan ke dalam satu kelas yang sama.

Hasil ini menegaskan bahwa permasalahan utama CNN bukan terletak pada pemilihan threshold, melainkan pada ketidakmampuan model dalam menghasilkan distribusi probabilitas yang informatif. Kondisi ini mengindikasikan terjadinya underfitting, di mana arsitektur CNN yang digunakan belum cukup efektif dalam mengekstraksi fitur visual penting dari citra struktur senyawa. Dengan demikian, CNN dasar pada penelitian ini belum dapat digunakan sebagai sistem prediksi yang andal.

Berbeda dengan CNN, model *MobileNetV2* menunjukkan performa yang lebih stabil selama proses pelatihan. Grafik akurasi dan loss memperlihatkan penurunan loss yang lebih terkendali serta peningkatan akurasi pelatihan yang lebih konsisten. Meskipun nilai akurasi validasi masih berada pada kisaran 53%, distribusi prediksi yang dihasilkan oleh *MobileNetV2* lebih bervariasi dan tidak terpusat pada satu rentang sempit seperti pada CNN.

Hasil confusion matrix dan classification report *MobileNetV2* menunjukkan peningkatan yang signifikan, khususnya pada kelas *Senyawa Aktif*. Nilai recall untuk kelas tersebut mencapai 0.79, sementara F1-score sebesar 0.61. Hal ini menunjukkan bahwa *MobileNetV2* mampu mendeteksi sebagian besar senyawa aktif dengan cukup baik, serta menghasilkan distribusi prediksi yang lebih seimbang antar kelas dibandingkan CNN.

Pada tahap sistem prediksi, *MobileNetV2* mampu menghasilkan nilai probabilitas yang melampaui dan berada di bawah threshold 0.6, sehingga sistem dapat mengklasifikasikan citra ke dalam kedua kelas secara fungsional. Dengan kata lain, *MobileNetV2* tidak hanya unggul secara metrik evaluasi, tetapi juga berhasil diimplementasikan sebagai sistem prediksi yang berjalan sesuai tujuan penelitian.

Keunggulan *MobileNetV2* ini dipengaruhi oleh penggunaan arsitektur depthwise separable convolution dan transfer learning, yang memungkinkan model memanfaatkan pengetahuan awal dari dataset berskala besar. Hal ini sangat membantu dalam kondisi dataset penelitian yang terbatas, serta membuat *MobileNetV2* lebih adaptif terhadap pola visual kompleks pada citra struktur senyawa.

Berdasarkan seluruh hasil evaluasi, dapat disimpulkan bahwa CNN dasar belum mampu melakukan klasifikasi dan prediksi senyawa dengan baik. Model ini gagal menghasilkan pemisahan kelas yang jelas, baik pada metrik evaluasi maupun pada sistem prediksi berbasis threshold. Sebaliknya, *MobileNetV2* menunjukkan kemampuan prediksi yang lebih baik, dengan distribusi probabilitas yang lebih representatif dan hasil klasifikasi yang lebih seimbang.

Perbedaan performa ini menegaskan bahwa penggunaan CNN sederhana tanpa optimasi lanjutan kurang sesuai untuk klasifikasi citra senyawa yang memiliki karakteristik visual kompleks. *MobileNetV2* terbukti lebih efektif dalam mengekstraksi fitur penting dan membangun decision boundary yang lebih jelas antar kelas.

Hasil penelitian ini sejalan dengan penelitian oleh Pratama et al., (2025) pada klasifikasi korosi, yang menunjukkan bahwa *MobileNetV2* secara konsisten mengungguli CNN sederhana pada hampir seluruh metrik evaluasi, termasuk akurasi, precision, recall, F1-score. *MobileNetV2* pada penelitian tersebut mencapai akurasi uji sebesar 95%, jauh lebih tinggi dibandingkan CNN sederhana.

Hasil serupa juga pada penelitian oleh Qur'ani et al. (2024) pada deteksi penyakit daun jagung, di mana *MobileNetV2* memperoleh akurasi 95% dan menunjukkan distribusi prediksi yang lebih seimbang dibandingkan CNN dasar yang hanya mencapai akurasi 91%. Kedua penelitian tersebut menegaskan bahwa *MobileNetV2* memiliki kemampuan generalisasi dan efisiensi yang lebih baik.

Hasil dan pembahasan ini menunjukkan bahwa model CNN belum layak digunakan sebagai sistem prediksi senyawa, sedangkan *MobileNetV2* telah mampu menjalankan fungsi prediksi dengan lebih baik. Oleh karena itu, *MobileNetV2* direkomendasikan sebagai model utama dalam pengembangan sistem klasifikasi senyawa berbasis citra, dengan catatan bahwa optimasi lanjutan masih diperlukan untuk meningkatkan performa secara keseluruhan.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan mengenai klasifikasi aktivitas antioksidan senyawa prenil flavonoid menggunakan citra struktur molekul, maka dapat disimpulkan sebagai berikut:

1. CNN dasar berhasil diterapkan secara teknis dalam proses klasifikasi citra struktur molekul senyawa prenil flavonoid menjadi dua kelas, yaitu senyawa aktif dan senyawa tidak aktif. Namun, berdasarkan hasil evaluasi, CNN belum mampu melakukan klasifikasi dan prediksi secara optimal. Hal ini ditunjukkan oleh ketidakstabilan grafik akurasi dan loss selama proses pelatihan, serta kegagalan model dalam melakukan generalisasi terhadap data uji. Dengan demikian, meskipun CNN dapat diimplementasikan, model ini belum layak digunakan sebagai sistem prediksi aktivitas antioksidan dalam penelitian ini.
2. Hasil perbandingan menunjukkan bahwa *MobileNetV2* memiliki kinerja yang lebih baik dibandingkan CNN dasar dalam mengklasifikasikan aktivitas antioksidan senyawa prenil flavonoid berdasarkan nilai IC_{50} . CNN hanya mampu mengenali satu kelas dengan nilai recall kelas Senyawa Tidak Aktif sebesar 1.00 dan recall kelas Senyawa Aktif sebesar 0.00, sehingga seluruh data uji diklasifikasikan ke dalam satu kelas. Sebaliknya, *MobileNetV2* mampu mengenali kedua kelas dengan lebih seimbang, khususnya pada kelas Senyawa Aktif yang memperoleh nilai recall sebesar 0.79 dan F1-score sebesar 0.61. Hal ini menunjukkan bahwa *MobileNetV2* lebih efektif dalam mengekstraksi fitur visual penting dari citra struktur molekul.
3. Evaluasi berdasarkan metrik akurasi, precision, recall, dan F1-score menunjukkan bahwa kedua model memiliki nilai akurasi sebesar 53%. Namun, nilai tersebut tidak sepenuhnya merepresentasikan kualitas model. CNN mengalami underfitting yang ditandai dengan distribusi probabilitas prediksi yang sempit (0,358–0,448), sehingga tidak mampu memenuhi threshold 0.6 pada sistem klasifikasi. Sementara itu, *MobileNetV2* menghasilkan probabilitas prediksi yang lebih bervariasi dan dapat melampaui threshold yang

ditetapkan, sehingga sistem dapat berfungsi secara optimal dalam proses klasifikasi.

5.2 Saran

Berdasarkan hasil dan kesimpulan penelitian, maka beberapa saran yang dapat diberikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Penelitian selanjutnya disarankan untuk melakukan optimasi lebih lanjut pada model CNN, seperti penyesuaian arsitektur, penambahan jumlah data, penggunaan regularisasi, atau penerapan teknik data augmentation untuk mengurangi risiko underfitting.
2. Mengingat dataset yang digunakan relatif terbatas, penelitian selanjutnya disarankan untuk menggunakan dataset dengan jumlah citra yang lebih besar dan variasi struktur molekul yang lebih beragam agar model memiliki kemampuan generalisasi yang lebih baik.
3. *MobileNetV2* yang telah terbukti mampu berfungsi sebagai sistem prediksi dapat dikembangkan lebih lanjut dengan optimasi threshold, evaluasi metrik tambahan seperti AUC, serta integrasi dengan sistem pendukung keputusan di bidang kimia atau farmasi untuk membantu analisis awal aktivitas antioksidan senyawa.

DAFTAR PUSTAKA

- Ezra, P. J., Limanan, D., Ferdinal, F., & Yulianti, E. (2023). Gambaran variasi uji kapasitas antioksidan DPPH, FRAP dan ABTS pada ekstrak biji jengkol (*Archidenfron* sp.). *Tarumanagara Medical Journal*, 5(2), 337–344. <https://doi.org/10.24912/tmj.v5i2.24762>
- Hakim, M. N. M., Nugroho, A. B., & Minarno, A. E. (2023). Prediksi Tumor Otak Menggunakan Metode Convolutional Neural Network. *Informatika Mulawarman : Jurnal Ilmiah Ilmu Komputer*, 17(1), 48. <https://doi.org/10.30872/jim.v17i1.5246>
- Handayani, S., Najib, A., Wisdawati, W., &, & Khoiriyah, A. (2020). Aktivitas Antioksidan *Caulerpa lentillifera* J. Agardh dengan Metode Perendaman Radikal Bebas 1, 1-diphenyl-2 picrylhydrazil. *Journal of Chemical Information and Modeling*, 53(9), 1689–1699. <https://doi.org/10.24252/kesehatan.v13i1.13848>
- Hermawan, S., & Agustina, N. (2023). *Implementasi Convolutional Neural Network untuk Klasifikasi Rempah – Rempah Khas Indonesia*. 7(1), 1–7.
- Hidayati, T., & Putra, B. F. (2024). Implementasi Deep Learning Untuk Image Classification menggunakan Convolutional Neural Network Pada Citra Wayang (Studi Kasus : SDN Leuwibatu 03). *Scientia Sacra: Jurnal Sains, Teknologi Dan Masyarakat*, 4(1), 1–7.
- Isrianto, P. L., & Tania, P. O. A. (2019). ANTIOXIDANT ACTIVITY IN COMBINATION EXTRACT OF *Acorus calamus* L. (DLINGU) AND *Allium sativum* (GARLIC). *International Journal of Applied Biology*, 3(1), 1. <https://doi.org/10.20956/ijab.v3i1.5471>
- Malang, S. U., Akademi, S., Aub, T., Soil, A., & Network, C. N. (2022). *Implementasi Convolutional Neural Network untuk Klasifikasi Citra Soil Nikel dan Non Nikel*. 6(1), 85–90.
- Nazar, R. (2024). Implementasi Pemrograman Python Menggunakan Google Colab. *Jurnal Informatika Dan Komputer (JIK)* , 15(1), 50–56.

- Oktaria, D., & Marpaung, M. P. (2023). PENETAPAN KADAR FLAVONOID TOTAL DAN AKTIVITAS ANTIOKSIDAN EKSTRAK AKAR NIPAH (*Nypa fruticans* Wurmb) DENGAN METODE SPEKTROFOTOMETRI UV-Vis. *Lantanida Journal*, 11(1), 36. <https://doi.org/10.22373/lj.v11i1.16087>
- Prasetyo, K., & Mahendra, R. (2025). *Performance Analysis of Baseline Convolutional Neural Networks for Identifying Potato Disease Types Analisis Kinerja Convolutional Neural Networks Baseline untuk Identifikasi Jenis Jenis Penyakit Kentang*. 5(April), 609–615.
- Rahman, S., Sembiring, A., Siregar, D., Khair, H., Gusti Prahmana, I., Puspadini, R., & Zen, M. (2023). Python : Dasar Dan Pemrograman Berorientasi Objek. In *Penerbit Tahta Media*.
- Samodra, G., Alfathani, N. F., & Octaviani, P. (2023). Uji Aktivitas Antioksidan Ekstrak Etanol Kombinasi Daun Kersen (*Muntingia calabura* L.) dan Daun Kelor (*Moringa oleifera* L) dengan Metode DPPH (2,2-Diphenyl-1-Picrylhydrazyl). *Pharmakon: Jurnal Farmasi Indonesia*, 20(1), 19–26. <https://doi.org/10.23917/pharmakon.v20i1.22293>
- Santos, C. M. M., & Silva, A. M. S. (2020). The antioxidant activity of prenylflavonoids. *Molecules*, 25(3). <https://doi.org/10.3390/molecules25030696>
- Saputra, R. A., Wasyianti, S., Supriyatna, A., & Saefudin, D. F. (2021). *Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi*. 9(2), 185–189.
- Wang, T. yang, Li, Q., & Bi, K. shun. (2018). Bioactive flavonoids in medicinal plants: Structure, activity and biological fate. *Asian Journal of Pharmaceutical Sciences*, 13(1), 12–23. <https://doi.org/10.1016/j.ajps.2017.08.004>