

**PEMETAAN SEBARAN BANTUAN RUMAH LAYAK HUNI
MENGUNAKAN TEKNOLOGI *DEEP LEARNING*
EFFICIENTNET-B0 DAN SISTEM INFORMASI GEOGRAFIS
(SIG) DI KOTA BANDA ACEH**

TUGAS AKHIR

Diajukan oleh:

PUTRI NABILAH TAMA

NIM. 220705034

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



**FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI AR-RANIRY
BANDA ACEH
2026 M /1448 H**

LEMBAR PERSETUJUAN

PEMETAAN SEBARAN BANTUAN RUMAH LAYAK HUNI MENGUNAKAN TEKNOLOGI *DEEP LEARNING* *EFFICIENTNET-B0* DAN SISTEM INFORMASI GEOGRAFIS (SIG) DI KOTA BANDA ACEH

TUGAS AKHIR

Diajukan kepada Fakultas Sains dan Teknologi
Universitas Islam Negeri Ar-Raniry Banda Aceh
Sebagai Salah Satu Beban Studi Memperoleh Gelar Sarjana (S1)
Pada Prodi Teknologi Informasi

Oleh:

PUTRI NABILAH TAMA
NIM. 220705034

Mahasiswa Fakultas Sains dan Teknologi
Program Studi Teknologi Informasi

Disetujui Untuk di Munaqasyahkan Oleh:

Pembimbing I,


Mulkan Fadhli, M.T
NIP. 198811282020121006

Pembimbing II,


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

Mengetahui,
Ketua Program Studi Teknologi Informasi


Malahayati, M.T
NIP. 198301272015032003

LEMBAR PENGESAHAN

PEMETAAN SEBARAN BANTUAN RUMAH LAYAK HUNI MENGUNAKAN TEKNOLOGI *DEEP LEARNING* *EFFICIENTNET-B0* DAN SISTEM INFORMASI GEOGRAFIS (SIG) DI KOTA BANDA ACEH

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 (S-1)
Dalam Program Studi Teknologi Informasi

Pada Hari/Tanggal: Senin, 27 Juli 2026 M

12 Safar 1448 H

Di Darussalam, Banda Aceh

Panitia Ujian Munaqasyah Tugas Akhir

Ketua,


Sekretaris,


Mulkan Fadhli, M.T
NIP. 198811282020121006


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

Penguji I,

Penguji II,



Aulia Svarif Aziz, M.Sc
NIP. 199305212022031001


Nazaruddin Ahmad, M.T
NIP. 198206052014031002

Mengetahui:

Dekan Fakultas Sains dan Teknologi
UIN Ar-Raniry Banda Aceh




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

LEMBAR PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini:

Nama : Putri Nabilah Tama
Nim : 220705034
Prodi : Teknologi Informasi
Fakultas : Sains dan Teknologi
Judul : Pemetaan Sebaran Bantuan Rumah Layak Huni
Menggunakan Teknologi *Deep Learning*
EfficientNet-B0 Dan Sistem Informasi
Geografis (SIG) Di Kota Banda Aceh

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

1. Tidak menggunakan ide orang lain tanpa mampu mengembangkan dan mempertanggungjawabkan;
2. Tidak melakukan plagiasi terhadap naskah karya 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 bertanggungjawab atas karya ini.

Bila dikemudian hari ada tuntutan dari pihak lain atas karya saya, dan telah melalui pembuktian yang dapat dipertanggungjawabkan dan ternyata memang ditemukan bukti bahwa saya telah melanggar pernyataan ini, maka saya siap dikenai 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, 27 Juli 2026

Yang Menyatakan



(Putri Nabilah Tama)

ABSTRAK

Nama : Putri Nabilah Tama
NIM : 220705034
Program Studi : Teknologi Informasi
Judul : Pemetaan Sebaran Bantuan Rumah Layak Huni Menggunakan Teknologi *Deep Learning EfficientNet-B0* Dan Sistem Informasi Geografis (SIG) Di Kota Banda Aceh

Tanggal Sidang : 27 Juli 2026
Jumlah Halaman : 79 Halaman
Pembimbing I : Mulkan Fadhli, M.T
Pembimbing II : Dr.Hendri Ahmadian, M.I.M.
Kata Kunci : *Deep Learning, EfficientNet-B0*, Sistem Informasi Geografis (SIG), *Transfer Learning*, Klasifikasi Citra, Bantuan Rumah Layak Huni.

Penyaluran bantuan rumah layak huni memerlukan informasi yang akurat agar proses validasi penerima manfaat dapat dilakukan secara tepat sasaran. Penelitian ini bertujuan mengimplementasikan *Deep Learning EfficientNet-B0* yang diintegrasikan dengan Sistem Informasi Geografis (SIG) untuk menghasilkan pemetaan sebaran bantuan rumah layak huni di Kota Banda Aceh. Dataset yang digunakan terdiri atas 1.196 citra rumah, meliputi 598 citra rumah layak huni dan 598 citra rumah tidak layak huni, yang diperoleh dari citra *Google Earth* berdasarkan koordinat GPS hasil survei lapangan. Proses klasifikasi dilakukan menggunakan model *EfficientNet-B0* dengan pendekatan *transfer learning*, kemudian dievaluasi menggunakan *accuracy, precision, recall, F1-score*, dan *confusion matrix*. Hasil klasifikasi selanjutnya diintegrasikan ke dalam QGIS untuk menghasilkan peta sebaran berdasarkan koordinat geografis. Hasil penelitian menunjukkan bahwa model *EfficientNet-B0* memperoleh akurasi sebesar 98,35% dengan nilai *precision, recall*, dan *F1-score* yang tinggi, serta mampu melakukan prediksi secara konsisten pada data citra baru. Integrasi dengan Sistem Informasi Geografis berhasil menghasilkan peta sebaran rumah layak huni dan rumah tidak layak huni yang dapat dimanfaatkan sebagai informasi pendukung dalam proses validasi penerima manfaat bantuan rumah layak huni di Kota Banda Aceh, meskipun belum dilakukan implementasi secara langsung pada instansi pemerintah.

ABSTRACT

Name : Putri Nabilah Tama
Student Number : 220705034
Departement : Information Technology
Title : Mapping the Distribution of Decent Housing Aid Using Deep Learning EfficientNet-B0 Technology and Geographic Information Systems (GIS) in Banda Aceh City

Date : 27 July 2026
Number Of Pages : 79 Pages
Supervisor I : Mulkan Fadhli, M.T
Supervisor II : Dr.Hendri Ahmadian, M.I.M.
Keywords : Deep Learning, EfficientNet-B0, Geographic Information System (GIS), Transfer Learning, Image Classification, Decent Housing Assistance.

The distribution of livable housing assistance requires accurate information to ensure that the validation process of beneficiaries can be carried out effectively and appropriately. This study aims to implement the EfficientNet-B0 Deep Learning model integrated with a Geographic Information System (GIS) to produce a spatial distribution map of livable housing assistance in Banda Aceh City. The dataset consisted of 1,196 house images, including 598 images of livable houses and 598 images of non-livable houses, obtained from Google Earth imagery based on GPS coordinates collected during field surveys. The classification process was performed using the EfficientNet-B0 model with a transfer learning approach and evaluated using accuracy, precision, recall, F1-score, and the confusion matrix. The classification results were then integrated into QGIS to generate a spatial distribution map based on the geographic coordinates of each object. The results showed that the EfficientNet-B0 model achieved an accuracy of 98.35%, with high precision, recall, and F1-score values, demonstrating consistent prediction performance on new image data. The integration with the Geographic Information System successfully produced a distribution map of livable and non-livable houses, which can serve as supporting information for the beneficiary validation process of livable housing assistance programs in Banda Aceh City. However, the system has not yet been directly implemented or evaluated within government agencies.

KATA PENGANTAR

Puji dan syukur penulis panjatkan ke hadirat Allah SWT atas segala limpahan rahmat, hidayah, dan karunia-Nya. Berkat izin dan pertolongan-Nya, penulis dapat menyelesaikan skripsi ini dengan baik sebagai salah satu syarat untuk meraih gelar Sarjana. Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad SAW, suri teladan umat manusia, yang telah membimbing umatnya dari masa kegelapan menuju jalan yang terang penuh ilmu pengetahuan dan keimanan.

Dengan penuh rasa syukur dan kerendahan hati, penulis mempersembahkan skripsi yang berjudul **“Pemetaan Sebaran Bantuan Rumah Layak Huni Menggunakan Teknologi *Deep Learning EfficientNet-B0* dan Sistem Informasi Geografis (SIG) di Kota Banda Aceh**”. Skripsi ini disusun sebagai bentuk kontribusi akademik penulis sekaligus sebagai bagian dari penyelesaian studi pada Fakultas Sains dan Teknologi, Universitas Islam Negeri Ar-Raniry Banda Aceh.

Proses penyusunan skripsi ini tentu tidak terlepas dari dukungan, doa, bimbingan, serta bantuan dari berbagai pihak. Oleh karena itu, dengan penuh rasa hormat dan terima kasih, penulis menyampaikan apresiasi yang sebesar-besarnya kepada:

1. Teristimewa dan terutama penulis sampaikan dengan penuh cinta terima kasih setulus-tulusnya kepada kedua orang tua penulis tersayang. Kepada cinta pertama dan panutan penulis Ayah Jumadil Taimi. Terima kasih atas setiap cucuran keringat dan kerja keras yang engkau tukarkan sebuah nafkah demi anakmu bisa sampai di tahap ini, meskipun ayah tidak sempat merasakan pendidikan dibangku perkuliahan, namun selalu senantiasa memberikan yang terbaik untuk keluarga dan anak-anak nya, dan terima kasih telah menjadi contoh untuk selalu menjadi seorang anak perempuan yang kuat. Kepada pintu surgaku dan belahan jiwaku, Mama Lestari. Terima kasih atas segala sumber kekuatan, motivasi, pesan, dan doa yang senantiasa dilangitkan untuk anaknya, serta kasih sayang tanpa batas yang tak pernah *lekap oleh waktu*, atas kesabaran dan pengorbanan yang selalu mengiringi

perjalanan hidup anakmu. Terima kasih atas segala hal yang ayah dan mama berikan yang tak terhitung jumlahnya, *Nyawaku nyala karnamu*.

2. Kepada adik-adik tersayang, Namira Dwi Tama, Muhammad Al-Gazaly, dan Gaishan Raffasya Hafis, yang selalu membuat penulis termotivasi untuk bisa terus belajar menjadi sosok kakak yang dapat memberikan pengaruh positif. Terima kasih untuk selalu mendoakan, memberikan dukungan kepada penulis hingga bisa menyelesaikan karya tulis ilmiah ini, dan menjadi alasan penulis bertahan sejauh ini, *Tumbuh lebih baik dibanding diriku*.
3. Kakak sepupu penulis, Adila Putri Efilda, Terima kasih telah menjadi sosok kakak untuk anak pertama ini. Terima kasih telah menjadi pendengar yang baik di setiap keluh kesah, memberikan motivasi, semangat, serta keyakinan kepada penulis untuk terus bertahan dan menyelesaikan setiap proses perkuliahan. Dukungan dan perhatian yang diberikan menjadi salah satu alasan penulis mampu menyelesaikan perjalanan akademik ini hingga memperoleh gelar sarjana.
4. Bapak Mulkan Fadhli, M.T., selaku penasehat akademik dan dosen pembimbing I yang telah meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan, serta masukan yang membangun sehingga penelitian ini dapat tersusun secara lebih terarah dan sistematis.
5. Bapak Dr. Hendri Ahmadian, M.I.M., selaku dosen pembimbing II yang telah memberikan banyak masukan, arahan, serta saran yang membangun sehingga penulis dapat menyelesaikan skripsi ini dengan lebih baik. Terima kasih atas kesabaran dan perhatian yang diberikan selama proses bimbingan.
6. Bapak Prof. Dr. Ir. M. Dirhamsyah, M.T., IPU., selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Ar-Raniry Banda Aceh yang telah memberikan fasilitas dan kesempatan kepada penulis untuk menempuh pendidikan di fakultas ini.
7. Ibu Malahayati, M.T. dan Bapak Khairan AR, M.Kom., selaku Ketua dan Sekretaris Program Studi Teknologi Informasi, yang telah memberikan

arahan, kebijakan, serta dukungan akademik sehingga penulis dapat menyelesaikan studi dengan baik.

8. Ibu Cut Ida Rahmadiana, S.Si., selaku staf Program Studi Teknologi Informasi, yang dengan penuh kesabaran dan keramahan telah banyak membantu penulis dalam pengurusan administrasi akademik.
9. Kepada seluruh keluarga besar penulis senantiasa memberikan do'a, dukungan, semangat, perhatian, serta motivasi selama proses pendidikan hingga penyusunan skripsi ini selesai. Kehangatan keluarga menjadi tempat penulis kembali menguatkan diri di tengah berbagai proses dan perjuangan yang dilalui.
10. Seseorang yang tak kalah penting kehadirannya, yaitu Vikri Darwis sebagai partner sejak tahun 2022 terima kasih telah menemani dan kebersamaan setiap proses penulis, menjadi yang terdepan saat penulis memerlukan bantuan ataupun sesuatu, tidak pernah mengeluh menghadapi penulis, untuk telinga yang hampir setiap hari mendengarkan keluh kesah penulis, selalu meminjamkan pundaknya ketika penulis rapuh dan menjadi *support system* terbaik penulis. Terima kasih atas waktunya dan hal baik yang diberikan selama ini, *semua bentuknya kau rayakan*.
11. Sahabat seperjuangan tersayang, Hilda Sabrina Hashar, Siti Mariatul Ulfa, dan Munisa, telah menjadi bagian penting dalam perjalanan perkuliahan penulis. Terima kasih karena selalu hadir dalam suka maupun duka, menjadi tempat berbagi cerita, keluh kesah, tawa, dan semangat di tengah proses yang tidak mudah ini. Terima kasih telah berjalan bersama hingga sampai di titik ini. Semoga persahabatan yang terjalin tidak hanya berhenti di bangku perkuliahan, tetapi terus tumbuh dalam setiap langkah kehidupan ke depan.
12. Seluruh teman-teman Angkatan 2022 Program Studi Teknologi Informasi Universitas Islam Negeri Ar-Raniry Banda Aceh, yang telah menjadi bagian dari perjalanan akademik penulis. Terima kasih atas kebersamaan, kerja sama, serta pengalaman yang telah dibagikan selama masa perkuliahan.
13. Seluruh pihak yang tidak dapat penulis sebutkan satu per satu, yang telah memberikan bantuan, doa, dukungan, motivasi, maupun kontribusi dalam

berbagai bentuk selama proses penyusunan skripsi ini. Penulis mengucapkan terima kasih yang sebesar-besarnya.

14. Terakhir, penulis ingin menyampaikan rasa terima kasih yang paling tulus kepada diri penulis sendiri, Putri Nabilah Tama. Terima kasih karena telah mampu bertahan, berjuang, dan tidak memilih menyerah di setiap proses yang telah dilalui. Menjadi anak perempuan yang membawa harapan orang tua bukanlah hal yang mudah. Ada banyak air mata yang tidak terlihat, rasa lelah yang dipendam sendiri, serta perjuangan yang mungkin tidak pernah diketahui oleh orang lain. Namun, semua itu menjadi bagian dari proses yang membentuk penulis menjadi pribadi yang lebih kuat, lebih sabar, dan lebih menghargai setiap langkah kecil yang berhasil dilewati. Terima kasih karena tetap percaya pada diri sendiri, bahkan ketika keadaan terasa begitu berat. Terima kasih karena terus bangkit setiap kali merasa gagal, terus belajar setiap kali melakukan kesalahan, dan terus berjalan meskipun langkah terasa pelan. Skripsi ini bukan hanya tentang memperoleh gelar sarjana, tetapi juga menjadi bukti bahwa setiap usaha, doa, dan kesabaran pada akhirnya akan menemukan jalannya. Semoga perjalanan ini menjadi awal dari langkah-langkah baik berikutnya. Semoga Allah SWT senantiasa memberikan kesehatan, keberkahan, kemudahan, serta menghadirkan orang-orang baik di setiap perjalanan kehidupan. Jangan pernah berhenti bermimpi, tetap rendah hati, dan terus menjadi pribadi yang bermanfaat bagi keluarga, masyarakat, serta orang-orang di sekitar. Terima kasih telah bertahan sejauh ini. Kamu sudah melakukan yang terbaik.

Banda Aceh, 27 Juli 2026

Penulis,




Putri Nabilah Tama

DAFTAR ISI

LEMBAR PERSETUJUAN.....	i
LEMBAR PENGESAHAN	ii
LEMBAR PERNYATAAN KEASLIAN TUGAS AKHIR	iii
ABSTRAK	iv
ABSTRACT	v
KATA PENGANTAR	vi
DAFTAR ISI.....	x
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	4
1.4 Batasan Masalah.....	5
1.5 Manfaat Penelitian.....	5
1.5.1 Manfaat Akademis.....	5
1.5.2 Manfaat Praktis	6
BAB II TINJAUAN PUSTAKA.....	7
2.1 Penelitian Terdahulu.....	7
2.2 Kebaruan Penelitian (<i>Research Novelty</i>).....	9
2.3 Landasan Teori	10
2.3.1 Pemetaan dan Analisis Spasial	10
2.3.2 Rumah Layak Huni dan Kebijakan Bantuan Perumahan	12
2.3.3 Sistem Informasi Geografis (SIG/ GIS).....	12
2.3.4 <i>Deep Learning</i>	13
2.3.5 Klasifikasi Citra	14
2.3.6 <i>Convolutional Neural Network</i> (CNN).....	15
2.3.7 Model <i>EfficientNet-B0</i>	16
2.3.8 Integrasi <i>Deep learning</i> dan Sistem Informasi Geografis (GeoAI).....	18
2.3.9 <i>Confusion Matrix</i>	19
2.3.10 <i>Python</i>	19
2.3.11 Google Colaboratory	20

2.4 Kerangka Berpikir	21
BAB III METODE PENELITIAN.....	23
3.1 Tahapan Penelitian	23
3.2 Jenis Penelitian	24
3.3 Data dan Sumber Data.....	25
3.3.1 Data Primer	25
3.3.2 Data Sekunder.....	26
3.4 Teknik Pengumpulan Data	27
3.5 Pra-pemrosesan Data Citra	28
3.6 Metode Klasifikasi (<i>EfficientNet-B0</i>).....	29
3.7 Evaluasi Model.....	31
3.8 Integrasi Hasil Klasifikasi dengan SIG	33
3.9 Teknis Analisis Data	35
BAB IV HASIL DAN PEMBAHASAN	37
4.1 Implementasi Penelitian	37
4.1.1 Persiapan Dataset.....	37
4.1.2 Pra-pemrosesan Dataset.....	39
4.2 Implementasi Model <i>EfficientNet-B0</i>	41
4.2.1 Arsitektur Model <i>EfficientNet-B0</i>	41
4.2.2 Proses Pelatihan Model.....	43
4.3 Evaluasi Kinerja Model <i>EfficientNet-B0</i>	46
4.3.1 Hasil Pelatihan Model.....	46
4.3.2 Hasil Evaluasi Model.....	47
4.4 Pengujian Model Menggunakan Data Baru	49
4.5 Analisis Perbandingan Kinerja Model	55
4.5.1 Perbandingan <i>EfficientNet-B0</i> dan Custom CNN.....	55
4.6 Implementasi Sistem Informasi Geografis (SIG).....	58
4.6.1 Ekspor Hasil Prediksi	58
4.6.2 Pemetaan Sebaran Rumah Layak Huni	59
BAB V KESIMPULAN DAN SARAN.....	63
5.1 Kesimpulan.....	63
5.2 Saran.....	63

DAFTAR PUSTAKA	65
DAFTAR LAMPIRAN.....	68



DAFTAR GAMBAR

Gambar 2. 1 Ilustrasi Arsitektur <i>EfficientNet-B0</i>	17
Gambar 2. 2 Kerangka Pemikiran Penelitian	22
 Gambar 3. 1 Tahapan Penelitian	23
Gambar 3. 2 Contoh Citra Tampak Atas Rumah Layak Huni dan Rumah Tidak Layak Huni.....	26
Gambar 3. 3 Diagram Alir Pra-pemrosesan Data Citra	28
 Gambar 4. 1 Struktur Folder Dataset	38
Gambar 4. 2 Contoh Citra Dataset	40
Gambar 4. 3 Arsitektur Implementasi Model <i>EfficientNet-B0</i> untuk Klasifikasi Citra Rumah	43
Gambar 4. 4 Diagram Alur Pelatihan Model <i>EfficientNet-B0</i>	44
Gambar 4. 5 <i>Output</i> Proses <i>Warm-up</i> dan <i>Fine-tuning</i>	45
Gambar 4. 6 Grafik <i>Accuracy</i> dan <i>Validation Accuracy</i>	46
Gambar 4. 7 <i>Confusion Matrix</i> Model <i>EfficientNet-B0</i>	48
Gambar 4. 8 Kode Pengujian Model Menggunakan Data Baru.....	50
Gambar 4. 9 Output Proses Pelatihan dan Evaluasi Custom CNN	56
Gambar 4. 10 Grafik Perbandingan Akurasi Validasi <i>EfficientNet-B0</i> dan Custom CNN	57
Gambar 4. 11 Data Hasil Prediksi yang Diekspor ke Format CSV	59
Gambar 4. 12 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kota Banda Aceh	60
Gambar 4. 13 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kecamatan Baiturrahman.....	61
Gambar 4. 14 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kecamatan Ulee Kareng	61
Gambar 4. 15 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kecamatan Syiah Kuala	62

DAFTAR TABEL

Tabel 3. 1 Konfigurasi <i>Hyperparameter</i> Model <i>EfficientNet-B0</i>	30
Tabel 3. 2 Alur Teknis Integrasi Hasil Klasifikasi dengan SIG.....	34
Tabel 4. 1 Spesifikasi Perangkat Penelitian	37
Tabel 4. 2 Distribusi Dataset.....	39
Tabel 4. 3 Hasil Pembagian Dataset	40
Tabel 4. 4 <i>Classification Report</i>	47
Tabel 4. 5 Hasil Pengujian Model Menggunakan Data Baru.....	51
Tabel 4. 6 Validasi Hasil Prediksi Model terhadap Kondisi Lapangan	53
Tabel 4. 7 Perbandingan Akurasi Model	56



BAB I

PENDAHULUAN

1.1 Latar Belakang

Perumahan merupakan salah satu kebutuhan mendasar bagi manusia yang berperan penting dalam meningkatkan kualitas hidup serta kesejahteraan masyarakat. Keberadaan hunian yang layak tidak hanya berkaitan dengan fungsi tempat tinggal semata, tetapi juga berhubungan erat dengan aspek kesehatan, keamanan, serta kondisi lingkungan sosial masyarakat. Oleh sebab itu, penyediaan rumah yang layak huni menjadi salah satu prioritas dalam pelaksanaan pembangunan nasional. Pemerintah Indonesia melalui berbagai program perumahan berupaya menekan jumlah rumah tidak layak huni (RTLH) dengan memberikan bantuan berupa perbaikan maupun pembangunan rumah bagi masyarakat berpenghasilan rendah.

Walaupun berbagai program bantuan perumahan telah dijalankan, persoalan rumah tidak layak huni masih menjadi tantangan yang memerlukan perhatian serius. Berdasarkan data dari Kementerian Pekerjaan Umum dan Perumahan Rakyat, hingga tahun 2023 masih terdapat jutaan rumah tangga di Indonesia yang tinggal di hunian yang belum memenuhi standar kelayakan, baik dari segi kondisi fisik bangunan, akses terhadap sanitasi, maupun ketersediaan infrastruktur dasar lainnya (Kementerian PUPR, 2023). Kondisi tersebut menunjukkan bahwa proses pendataan serta penyaluran bantuan rumah layak huni masih membutuhkan sistem yang lebih efektif agar bantuan yang diberikan dapat tepat sasaran dan sesuai dengan kondisi yang sebenarnya di lapangan.

Dalam konteks Kota Banda Aceh, permasalahan terkait kondisi rumah layak huni juga masih menjadi perhatian pemerintah daerah. Proses pendataan penerima bantuan rumah layak huni hingga saat ini masih banyak dilakukan melalui laporan administratif serta survei lapangan yang membutuhkan waktu relatif lama. Selain itu, data kondisi rumah yang tersedia belum sepenuhnya terintegrasi dalam sistem pemetaan berbasis teknologi yang mampu memberikan gambaran spasial secara menyeluruh mengenai kondisi perumahan di wilayah tersebut. Hal ini

menyebabkan proses evaluasi serta penentuan prioritas bantuan menjadi kurang optimal.

Sejumlah penelitian sebelumnya telah dilakukan untuk mengatasi permasalahan terkait pemetaan kondisi permukiman dan rumah tidak layak huni. Penelitian yang dilakukan oleh (Meileni et al., 2022) memanfaatkan Sistem Informasi Geografis untuk memetakan distribusi rumah tidak layak huni pada suatu wilayah. Hasil penelitian tersebut menunjukkan bahwa penggunaan SIG mampu menyajikan visualisasi data spasial secara lebih jelas sehingga mempermudah pemerintah dalam mengidentifikasi pola persebaran rumah tidak layak huni serta menentukan wilayah yang perlu mendapatkan prioritas penanganan.

Selain itu, penelitian yang dilakukan oleh (Wicaksono et al., 2023) menerapkan pendekatan analisis spasial untuk mengidentifikasi kondisi permukiman berdasarkan data wilayah. Hasil penelitian tersebut menunjukkan bahwa pemanfaatan teknologi spasial mampu meningkatkan efektivitas proses pemetaan wilayah dibandingkan dengan metode pendataan manual, karena data yang dihasilkan dapat disajikan secara visual dan terintegrasi dalam bentuk peta digital.

Penelitian lain yang dilakukan oleh (Taufiqurrahman, Indah Clara Sari, 2024) memanfaatkan teknologi pengolahan citra untuk mengidentifikasi karakteristik bangunan melalui citra udara. Hasil penelitian tersebut menunjukkan bahwa pemanfaatan teknologi pengolahan citra dapat membantu proses identifikasi kondisi bangunan secara lebih cepat dibandingkan dengan metode survei lapangan konvensional yang memerlukan waktu dan tenaga yang lebih besar.

Meskipun berbagai penelitian tersebut telah memberikan kontribusi dalam pemanfaatan teknologi untuk pemetaan kondisi permukiman, masih terdapat beberapa keterbatasan yang perlu diperhatikan. Sebagian penelitian masih menitikberatkan penggunaan Sistem Informasi Geografis hanya sebagai media visualisasi data spasial tanpa mengintegrasikan metode klasifikasi citra secara otomatis. Selain itu, beberapa penelitian masih memerlukan proses interpretasi citra secara manual untuk menentukan kondisi rumah, sehingga proses analisis menjadi relatif lebih lama dan berpotensi menimbulkan subjektivitas dalam proses identifikasi.

Berdasarkan keterbatasan tersebut, diperlukan suatu pendekatan teknologi yang mampu melakukan identifikasi kondisi rumah secara otomatis melalui citra digital sehingga proses pemetaan dapat dilakukan dengan lebih cepat dan sistematis. Salah satu teknologi yang berkembang pesat dalam bidang pengolahan citra adalah *Deep Learning*, khususnya metode *Convolutional Neural Network* (CNN) yang memiliki kemampuan dalam mengenali pola visual pada citra digital. Teknologi ini mampu mempelajari berbagai fitur visual dari objek yang terdapat pada citra sehingga dapat digunakan untuk melakukan klasifikasi kondisi bangunan berdasarkan karakteristik visual yang terlihat.

Dalam rangka meningkatkan efektivitas pendataan kondisi perumahan, pemanfaatan teknologi berbasis data spasial menjadi salah satu pendekatan yang dapat diterapkan. Salah satu teknologi yang sering digunakan dalam analisis wilayah adalah Sistem Informasi Geografis (SIG). Teknologi ini memungkinkan pengolahan serta visualisasi data spasial sehingga mampu memberikan gambaran yang lebih terstruktur mengenai kondisi suatu wilayah. Melalui penggunaan SIG, informasi terkait persebaran permukiman dan kondisi rumah dapat disajikan dalam bentuk peta digital yang memudahkan proses analisis maupun pengambilan keputusan (Meileni et al., 2022).

Oleh karena itu, penelitian ini mengusulkan penerapan teknologi *Deep Learning* dengan menggunakan model *EfficientNet-B0* yang diintegrasikan dengan Sistem Informasi Geografis (SIG) untuk memetakan sebaran bantuan rumah layak huni di Kota Banda Aceh. Model *EfficientNet-B0* dipilih karena memiliki arsitektur jaringan yang efisien serta mampu melakukan klasifikasi citra dengan performa yang baik dalam mengenali berbagai pola visual pada objek bangunan.

Melalui pemanfaatan citra satelit wilayah Kota Banda Aceh, model *EfficientNet-B0* diharapkan mampu melakukan klasifikasi kondisi rumah secara otomatis berdasarkan karakteristik visual yang terdapat pada citra. Hasil klasifikasi tersebut selanjutnya akan diintegrasikan dengan Sistem Informasi Geografis sehingga menghasilkan peta sebaran kondisi rumah layak huni secara spasial. Pendekatan ini tidak dimaksudkan untuk menggantikan metode survei lapangan yang telah dilakukan sebelumnya, tetapi dapat berfungsi sebagai sistem pendukung

yang membantu pemerintah dalam melakukan identifikasi awal kondisi rumah secara lebih cepat dan efisien.

Dengan adanya integrasi antara teknologi *Deep Learning* dan Sistem Informasi Geografis, penelitian ini diharapkan dapat memberikan gambaran spasial yang lebih akurat mengenai kondisi perumahan di Kota Banda Aceh. Selain itu, hasil penelitian ini juga diharapkan dapat berpotensi menjadi informasi pendukung pemerintah daerah dalam melakukan evaluasi terhadap distribusi bantuan rumah layak huni serta menentukan prioritas wilayah yang memerlukan penanganan secara lebih tepat sasaran.

1.2 Rumusan Masalah

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

1. Bagaimana penerapan integrasi antara *deep learning* model *EfficientNet-B0* dan Sistem Informasi Geografis (SIG) dapat digunakan untuk memetakan sebaran rumah tidak layak huni di Kota Banda Aceh?
2. Bagaimana akurasi dari model *EfficientNet-B0* dalam klasifikasi kondisi rumah berdasarkan citra udara atau satelit?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah dikemukakan, tujuan dari penelitian ini adalah sebagai berikut:

1. Menganalisis dan mengimplementasikan integrasi antara *deep learning* model *EfficientNet-B0* dan Sistem Informasi Geografis (SIG) dalam sistem pemetaan sebaran rumah tidak layak huni di Kota Banda Aceh.
2. Menghitung tingkat akurasi model *EfficientNet-B0* dalam melakukan klasifikasi kondisi rumah berdasarkan data citra udara atau citra satelit.

1.4 Batasan Masalah

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

1. Objek penelitian ini mencakup seluruh kecamatan yang berada dalam wilayah administrasi Kota Banda Aceh.
2. Data penelitian meliputi citra satelit atau citra udara tampak atas (top view) rumah, data penerima bantuan rumah layak huni, serta shapefile batas wilayah administratif dari sumber data dalam rentang waktu (2024-2026) untuk keperluan analisis spasial.
3. Sumber data citra diperoleh dari data terbuka seperti Google Earth, dengan resolusi menengah untuk kebutuhan klasifikasi citra.
4. Metode penelitian menggunakan pendekatan kuantitatif berbasis citra digital dengan model *Deep learning EfficientNet-B0* yang diintegrasikan ke dalam Sistem Informasi Geografis (SIG).
5. Analisis penelitian difokuskan pada kondisi fisik rumah yang tampak dari citra, tanpa mempertimbangkan aspek sosial ekonomi penghuni.
6. Hasil penelitian terbatas pada peta digital sebaran rumah layak huni, dan tidak mencakup pengembangan sistem implementatif berbasis aplikasi.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat baik dari segi akademis maupun praktis, sebagai berikut:

1.5.1 Manfaat Akademis


- a. Memberikan kontribusi terhadap pengembangan kajian ilmiah di bidang Sistem Informasi Geografis (SIG) dan kecerdasan buatan (*Artificial Intelligence*), khususnya penerapan *deep learning* dalam analisis spasial berbasis citra.
- b. Menjadi referensi bagi peneliti selanjutnya dalam mengintegrasikan model *EfficientNet-B0* dengan Sistem Informasi Geografis (SIG) untuk

mendukung pemetaan spasial dan klasifikasi kondisi rumah maupun objek sejenisnya.

- c. Memperkaya literatur akademik mengenai penerapan teknologi *deep learning* dan Sistem Informasi Geografis (SIG) dalam mendukung analisis spasial pada bidang perumahan dan pembangunan wilayah.

1.5.2 Manfaat Praktis

- a. Menyediakan sistem pemetaan berbasis teknologi yang menghasilkan informasi spasial mengenai sebaran rumah layak huni dan rumah tidak layak huni sebagai informasi pendukung dalam proses validasi penerima manfaat bantuan rumah layak huni di Kota Banda Aceh.
- b. Menyediakan informasi hasil klasifikasi kondisi rumah yang terintegrasi dengan data spasial sehingga berpotensi dimanfaatkan sebagai bahan pendukung dalam proses validasi penerima manfaat bantuan rumah layak huni.
- c. Memberikan informasi berbasis data spasial yang dapat dijadikan sebagai salah satu bahan pertimbangan dalam proses perencanaan dan pengambilan keputusan terkait program bantuan rumah layak huni.



BAB II TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian mengenai pemetaan rumah layak huni dan pemanfaatan teknologi spasial telah banyak dilakukan dalam beberapa tahun terakhir, terutama menggunakan pendekatan deskriptif kuantitatif yang mengintegrasikan Sistem Informasi Geografis (SIG) dengan algoritma kecerdasan buatan (AI). Salah satu studi relevan berjudul “Pemanfaatan Sistem Informasi Geografis untuk Pemetaan Kelayakan Bantuan Rumah Tidak Layak Huni di Kabupaten Kubu Raya.” Penelitian tersebut bertujuan untuk menilai kelayakan rumah penerima bantuan dengan metode overlay peta tematik berbasis SIG yang memadukan data sosial ekonomi dan kondisi fisik bangunan. Hasilnya menunjukkan bahwa SIG mampu menampilkan sebaran spasial wilayah prioritas penerima bantuan secara jelas. Namun, proses klasifikasi masih dilakukan secara manual, sehingga efisiensi dan ketepatan analisis datanya belum maksimal. Temuan ini menegaskan bahwa SIG perlu dioptimalkan dengan dukungan teknologi analisis otomatis seperti *Deep learning* (Meileni et al., 2022).

Penelitian mengenai penerapan deep learning dalam analisis citra rumah untuk menentukan penerima bantuan langsung tunai pernah dilakukan dengan judul “Implementasi *Deep learning* menggunakan Algoritma *EfficientDet* untuk Sistem Deteksi Kelayakan Penerima Bantuan Langsung Tunai Berdasarkan Citra Rumah di Wilayah Kabupaten Kediri.” Studi ini menggunakan pendekatan deskriptif kuantitatif dengan metode deep learning untuk mengklasifikasikan citra rumah ke dalam kategori layak atau tidak layak menerima bantuan. Hasil penelitian menunjukkan bahwa algoritma *EfficientDet* berhasil mencapai tingkat akurasi keseluruhan sebesar 93%, dengan nilai *precision* 96%, *recall* 92%, dan *F1-score* 94%. Temuan ini memperlihatkan efektivitas *deep learning* dalam melakukan klasifikasi citra rumah secara otomatis, memberikan keunggulan dari segi kecepatan dan ketepatan dibandingkan metode manual. Hasil tersebut juga memperkuat posisi metode deep learning sebagai dasar dari *model EfficientNet-B0* yang digunakan dalam penelitian ini (Akbari et al., 2023).

Selanjutnya, penelitian berjudul “*Integrasi Sistem Informasi Geografis dan Machine Learning untuk Identifikasi Rumah Tidak Layak Huni di Kota Malang.*” Dengan pendekatan deskriptif kuantitatif, penelitian ini mengombinasikan algoritma *Random Forest* dan data spasial berbasis SIG. Hasilnya menunjukkan bahwa integrasi pembelajaran mesin dengan SIG meningkatkan akurasi identifikasi rumah tidak layak huni hingga 89% serta mempercepat proses analisis. Meski demikian, penggunaan *machine learning* konvensional masih memiliki keterbatasan, terutama dalam mengenali fitur citra kompleks. Penelitian ini memberikan dasar penting bagi penerapan metode *Deep learning* seperti *EfficientNet-B0* yang menawarkan efisiensi dan akurasi lebih tinggi dalam klasifikasi citra spasial (Wicaksono et al., 2023).

Selain itu, penelitian komparatif antara model *MobileNetV1* dan *EfficientNet-B0* untuk klasifikasi citra lanskap berbasis transfer learning juga dilakukan untuk menilai efektivitas dan efisiensi masing-masing arsitektur dalam pengolahan citra. Dengan menggunakan pendekatan deskriptif kuantitatif, penelitian ini menemukan bahwa meskipun *MobileNetV1* sedikit lebih unggul dalam akurasi, model *EfficientNet-B0* menunjukkan efisiensi komputasi yang lebih baik serta keseimbangan optimal antara kedalaman, lebar, dan resolusi jaringan. Hasil ini menegaskan bahwa *EfficientNet-B0* lebih sesuai diterapkan pada dataset berukuran besar yang memerlukan pemrosesan cepat namun tetap akurat. Penelitian tersebut sangat relevan karena menegaskan keunggulan arsitektur *EfficientNet-B0* dalam konteks pemetaan dan analisis rumah layak huni, menjadikannya pilihan tepat untuk pemrosesan citra spasial yang efisien dan presisi (Burhanuddin et al., 2025).

Sementara itu, melalui penelitian berjudul “*Penerapan Deep learning Model EfficientNet-B0 untuk Klasifikasi Citra Bangunan Berdasarkan Kondisi Fisik*” menggunakan metode deskriptif kuantitatif untuk mengklasifikasikan citra bangunan layak dan tidak layak huni. Hasil penelitian memperlihatkan bahwa *EfficientNet-B0* mampu mencapai akurasi hingga 96,4% dengan efisiensi komputasi yang lebih baik dibandingkan model CNN tradisional. Temuan tersebut membuktikan bahwa *EfficientNet-B0* unggul dalam menyeimbangkan kedalaman, lebar, dan resolusi jaringan, sehingga sangat relevan untuk digunakan dalam

analisis citra spasial perumahan seperti pada penelitian ini (Taufiqurrahman, Indah Clara Sari, 2024).

Sementara itu, penelitian berjudul “Penerapan *EfficientNet-B0* pada Model CNN untuk Deteksi Dini Katarak” menggunakan pendekatan deskriptif kuantitatif untuk mengevaluasi kinerja model *EfficientNet-B0* dalam klasifikasi citra medis guna mendeteksi penyakit katarak sejak dini. Studi ini melibatkan ribuan data citra retina dan mencapai akurasi klasifikasi hingga 98%, menunjukkan kemampuan tinggi model ini dalam mengenali pola visual secara efisien. Keunggulan tersebut menegaskan bahwa arsitektur *EfficientNet-B0* memiliki potensi besar untuk diterapkan pada analisis citra rumah layak huni, guna meningkatkan kecepatan serta ketelitian pemetaan spasial dalam mendukung program bantuan perumahan berbasis data (Saragih & Kurniawan, 2025).

Berdasarkan berbagai penelitian tersebut, dapat disimpulkan bahwa penggunaan SIG dan teknologi kecerdasan buatan telah mendorong kemajuan besar dalam analisis spasial dan perencanaan kebijakan bantuan perumahan. Namun, sebagian besar penelitian terdahulu masih mengandalkan metode klasifikasi manual atau algoritma machine learning konvensional yang belum optimal dari segi efisiensi dan akurasi.

2.2 Kebaruan Penelitian (*Research Novelty*)

Berdasarkan telaah terhadap berbagai penelitian terdahulu, diketahui bahwa Sistem Informasi Geografis (SIG) telah banyak diterapkan untuk memetakan persebaran rumah tidak layak huni. Di sisi lain, metode *machine learning* maupun *deep learning* juga telah dimanfaatkan untuk mengklasifikasikan kondisi rumah berdasarkan citra. Meskipun demikian, sebagian besar penelitian masih mengembangkan klasifikasi citra dan pemetaan sebagai dua proses yang berdiri sendiri, sehingga hasil klasifikasi belum terintegrasi secara maksimal dengan sistem informasi spasial dalam mendukung proses pemetaan (Akbari et al., 2023; Meileni et al., 2022; Wicaksono et al., 2023).

Keunggulan atau kebaruan penelitian ini terletak pada integrasi model *Deep Learning EfficientNet-B0* dengan Sistem Informasi Geografis (SIG) untuk membangun sistem yang mampu melakukan klasifikasi sekaligus

memvisualisasikan sebaran rumah layak huni dan rumah tidak layak huni di Kota Banda Aceh. Selain menghasilkan peta berbasis koordinat geografis, penelitian ini juga menguji kemampuan model menggunakan citra baru yang tidak termasuk dalam proses pelatihan serta membandingkan kinerja *EfficientNet-B0* dengan model *Custom CNN* guna menilai efektivitas penerapan metode *transfer learning* (Burhanuddin et al., 2025; Taufiqurrahman, Indah Clara Sari, 2024).

Melalui pendekatan tersebut, penelitian ini tidak hanya menghasilkan model klasifikasi dengan performa yang tinggi, tetapi juga menyajikan informasi spasial dalam bentuk peta sebaran yang dapat dimanfaatkan sebagai informasi pendukung pada proses validasi penerima manfaat bantuan rumah layak huni di Kota Banda Aceh.

2.3 Landasan Teori

Landasan teori merujuk pada rangkaian logika atau pemikiran yang terdiri dari kumpulan konsep, definisi, dan proposisi yang diatur secara terstruktur. Secara umum, landasan teori memiliki tiga peran utama, yakni memberikan penjelasan (*Explanation*), memungkinkan ramalan (*Prediction*), dan memfasilitasi pengendalian (*Control*). Berikut adalah landasan teori dari penelitian “Pemetaan Sebaran Bantuan Rumah Layak Huni Menggunakan Teknologi *Deep learning EfficientNet-B0* dan Sistem Informasi Geografis (SIG)”.

2.3.1 Pemetaan dan Analisis Spasial

Pemetaan dan analisis spasial merupakan elemen penting dalam kajian ilmiah yang berfokus pada distribusi geografis serta pengelolaan data yang berbasis lokasi. Analisis spasial dalam studi penggunaan lahan telah mengalami kemajuan signifikan melalui penggabungan teknologi Sistem Informasi Geografis (SIG), penginderaan jauh, dan model pembelajaran mesin (*machine learning*) guna memahami dinamika perubahan tata ruang secara lebih komprehensif (Supiyandi & Mailok, 2025).

Peta tematik yang dihasilkan melalui proses analisis spasial berperan penting sebagai alat visualisasi yang mampu menggambarkan pola sebaran,

mengidentifikasi klaster wilayah, serta menentukan area prioritas untuk intervensi kebijakan (Santi et al., 2020). Dalam konteks kebijakan perumahan dan program bantuan sosial, pemetaan spasial membantu proses penentuan calon penerima manfaat berdasarkan lokasi dengan lebih tepat, sesuai dengan karakteristik wilayah, sehingga menghindari pendekatan yang bersifat umum dan tidak spesifik terhadap kebutuhan lokal.

Teknik analisis spasial meliputi berbagai metode, seperti overlay peta, analisis autokorelasi spasial (misalnya Indeks Moran dan LISA), serta klasifikasi wilayah berdasarkan nilai daya dukung lingkungan (*carrying capacity*) atau tingkat kepadatan hunian. Penerapan metode-metode tersebut dalam kajian mengenai kelayakan rumah sangat bermanfaat untuk mengidentifikasi daerah dengan kondisi fisik bangunan yang kurang memadai maupun wilayah yang masih belum mendapatkan pemerataan bantuan secara optimal.

Dalam konteks penelitian ini, yang berfokus pada pemetaan sebaran bantuan rumah layak huni di Kota Banda Aceh dengan memanfaatkan teknologi analisis citra dan SIG, teori pemetaan dan analisis spasial berfungsi sebagai dasar konseptual untuk beberapa langkah penting, antara lain:

1. Membuat peta digital yang menampilkan kondisi fisik hunian berdasarkan hasil klasifikasi citra;
2. Melakukan proses overlay antara hasil analisis citra dengan data penerima bantuan untuk menentukan wilayah prioritas;
3. Mengidentifikasi dan menganalisis pola sebaran penerima bantuan serta mengevaluasi ketimpangan spasial antara rumah layak dan tidak layak huni.

Oleh karena itu, pemahaman yang mendalam terhadap konsep pemetaan dan analisis spasial menjadi krusial dalam penelitian ini, terutama untuk mendukung integrasi metode *Deep learning* dengan SIG agar menghasilkan peta sebaran yang akurat, representatif, serta relevan sebagai dasar pengambilan keputusan dalam kebijakan perumahan.

2.3.2 Rumah Layak Huni dan Kebijakan Bantuan Perumahan

Rumah layak huni merupakan tempat tinggal yang memenuhi kriteria dasar, meliputi ketahanan struktur bangunan, kondisi fisik yang sehat, serta tersedianya fasilitas sanitasi dan utilitas pokok yang memadai. Berdasarkan penelitian di Indonesia, meskipun pemerintah telah melaksanakan berbagai program pembangunan dan perbaikan rumah secara nasional, masih terdapat kesenjangan yang cukup besar antara jumlah rumah yang dinyatakan layak dengan yang benar-benar memenuhi standar kelayakan minimum (Atikah, 2022).

Berbagai program pemerintah, seperti Bantuan Stimulan Perumahan Swadaya (BSPS) dan program Rehabilitasi Rumah Tidak Layak Huni (RTLH), dirancang untuk mempercepat peningkatan akses masyarakat berpenghasilan rendah terhadap hunian yang layak melalui bantuan fisik dan pendampingan teknis. Namun, hasil evaluasi menunjukkan bahwa pelaksanaan program tersebut masih menghadapi berbagai kendala, seperti pendataan yang belum akurat, distribusi bantuan yang belum sepenuhnya tepat sasaran, serta sistem pemantauan yang belum berjalan efektif (Nurjannahtin A , Dr. Endang Indartuti, MSi, 2024)

Dalam upaya meningkatkan efektivitas kebijakan perumahan, integrasi antara data administratif dengan data spasial menjadi faktor penting. Pemanfaatan analisis spasial dan sistem berbasis lokasi terbukti mampu membantu pemerintah daerah dalam mengidentifikasi wilayah prioritas penerima bantuan secara lebih akurat (Fahmi Idris, Mukhrijal, 2023). Oleh sebab itu, penelitian ini mengadopsi pendekatan berbasis teknologi *deep learning* dan Sistem Informasi Geografis (SIG) untuk melakukan klasifikasi citra rumah, yang diharapkan dapat memperkuat sistem penentuan sasaran serta evaluasi program rumah layak huni secara lebih objektif dan efisien.

2.3.3 Sistem Informasi Geografis (SIG/ GIS)

Sistem Informasi Geografis (SIG) adalah teknologi berbasis komputer yang berfungsi untuk mengumpulkan, menyimpan, mengelola, serta melakukan analisis terhadap data yang memiliki referensi lokasi atau aspek spasial. Melalui SIG, berbagai informasi keruangan dapat diolah sehingga mampu menampilkan

hubungan, pola, dan persebaran geografis dari suatu fenomena. Sistem Informasi Geografis SIG memiliki peran penting dalam proses pengambilan keputusan berbasis lokasi karena dapat mengintegrasikan beragam sumber data menjadi informasi spasial yang lebih komprehensif (Akmal, 2023).

Secara konseptual, SIG terdiri atas beberapa komponen utama, yaitu data spasial, perangkat keras, perangkat lunak, metode analisis, serta pengguna yang berperan dalam pengelolaan dan interpretasi informasi. Sistem ini juga memungkinkan penggabungan berbagai layer data mulai dari aspek fisik, sosial ekonomi, hingga infrastruktur ke dalam peta tematik yang membantu memahami karakteristik dan perbedaan antarwilayah. Hal ini sejalan dengan temuan (Chaniago & Taki, 2022) yang menegaskan bahwa SIG tidak hanya berfungsi sebagai alat visualisasi, melainkan juga sebagai instrumen analitis untuk mengidentifikasi pola dan kecenderungan spasial.

Dalam berbagai bidang seperti geografi, perencanaan wilayah, dan kajian permukiman, SIG digunakan dalam proses overlay, analisis keterhubungan, identifikasi klaster, serta evaluasi kondisi lingkungan. Penerapan konsep-konsep tersebut memberikan landasan bagi peneliti untuk memahami bagaimana suatu fenomena tersebar dan saling berinteraksi di berbagai wilayah. Meski demikian, penerapan SIG masih menghadapi sejumlah tantangan, terutama terkait kualitas data dan keterbatasan tenaga ahli (Zaroujtaghi et al., 2025).

2.3.4 Deep Learning

Deep learning merupakan cabang dari machine learning yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*) untuk mempelajari pola serta representasi data secara otomatis. Pendekatan ini bekerja melalui mekanisme ekstraksi fitur secara bertahap, di mana setiap lapisan jaringan memproses karakteristik data mulai dari elemen sederhana hingga pola yang lebih kompleks. Dalam bidang pengolahan citra, *Deep learning* terutama melalui arsitektur *Convolutional Neural Network* (CNN) memiliki kemampuan tinggi dalam mengidentifikasi pola visual seperti bentuk, tekstur, dan struktur objek, sehingga memberikan performa lebih unggul dibandingkan metode berbasis fitur buatan (Tilasefana & Putra, 2023).

Secara konseptual, model CNN modern menggunakan operasi konvolusi, pooling, dan fungsi aktivasi non-linear untuk memproses informasi spasial secara efisien. Konsep *transfer learning* juga menjadi bagian penting dalam *Deep Learning*, yaitu pemanfaatan model yang telah dilatih sebelumnya untuk diterapkan pada dataset baru guna mempercepat proses pelatihan dan meningkatkan kemampuan generalisasi, terutama ketika ketersediaan data terbatas. Hasil penelitian di tingkat nasional menunjukkan bahwa tahapan fundamental, seperti pra-pemrosesan (*normalisasi*, *augmentasi*), validasi silang, serta evaluasi menggunakan metrik kinerja seperti *accuracy*, *precision*, *recall*, dan *F1-score*, merupakan komponen penting dalam penerapan *Deep learning* untuk klasifikasi citra (Wardhana & Sibaroni, 2021).

Pemahaman mengenai konsep-konsep tersebut menjadi landasan utama dalam penelitian ini, karena *Deep learning* digunakan untuk mengidentifikasi kondisi fisik rumah berdasarkan citra satelit maupun udara. Keluaran dari proses klasifikasi kemudian diintegrasikan ke dalam Sistem Informasi Geografis (SIG) untuk memetakan persebaran rumah layak dan tidak layak huni secara spasial.

2.3.5 Klasifikasi Citra

Klasifikasi citra merupakan proses pengelompokan piksel pada sebuah citra ke dalam kategori tertentu. Tujuan utamanya adalah mereplikasi kemampuan manusia dalam menafsirkan informasi visual, sehingga komputer mampu mengidentifikasi atau mengklasifikasikan objek pada citra digital secara otomatis. Salah satu pendekatan yang banyak digunakan untuk melakukan klasifikasi citra adalah *deep learning* (Akbari et al., 2023).

Dalam teori dasar pengolahan citra, metode klasifikasi umumnya terbagi menjadi dua kategori utama, yaitu:

1. Klasifikasi berbasis piksel, yang menentukan kelas berdasarkan nilai spektral tiap piksel secara individual.
2. Klasifikasi berbasis objek (*Object-Based Image Analysis/OBIA*), yang menggunakan segmen atau objek citra sebagai unit analisis sehingga lebih sesuai untuk citra beresolusi tinggi.

Metode klasifikasi modern banyak memanfaatkan algoritma machine learning dan deep learning, seperti *Convolutional Neural Network* (CNN). CNN bekerja melalui proses ekstraksi fitur otomatis (*automatic feature extraction*), sehingga mampu mengenali pola visual seperti bentuk, tekstur, dan struktur objek dengan tingkat akurasi lebih tinggi dibandingkan metode tradisional.

Konsep klasifikasi citra ini menjadi landasan penting dalam penelitian ini karena digunakan untuk membedakan kondisi fisik rumah (layak atau tidak layak) berdasarkan citra satelit atau udara, sebelum hasil klasifikasinya dihubungkan dengan Sistem Informasi Geografis (SIG) untuk pemetaan spasial.

2.3.6 *Convolutional Neural Network* (CNN)

Convolutional Neural Network (CNN) adalah salah satu arsitektur jaringan saraf tiruan yang dikembangkan untuk menangani data dengan struktur grid, seperti citra digital. Secara prinsip, CNN beroperasi melalui tiga komponen inti lapisan konvolusi, pooling, dan fungsi aktivasi yang berperan dalam mengekstraksi fitur visual dari level sederhana hingga kompleks. Proses konvolusi memungkinkan jaringan mengenali pola lokal pada gambar, misalnya tepi, tekstur, atau bentuk objek, sedangkan pooling berfungsi mereduksi dimensi data sehingga proses pembelajaran menjadi lebih efisien tanpa kehilangan informasi penting. Berkat kemampuannya dalam melakukan ekstraksi fitur secara otomatis, CNN menjadi metode yang banyak digunakan pada berbagai aplikasi analisis citra (Agri Kristal, 2022).


Dalam kajian nasional, CNN sering diaplikasikan pada bidang penginderaan jauh dan pemrosesan citra spasial karena kemampuannya dalam mengidentifikasi objek seperti bangunan, vegetasi, dan elemen permukaan bumi lainnya (Maulidiya et al., 2024). Efektivitas CNN juga ditingkatkan melalui teknik *transfer learning*, yaitu pemanfaatan model yang telah dilatih sebelumnya untuk memperbaiki performa pada dataset baru yang berukuran terbatas. Selain itu, teori dasar penerapan CNN mencakup tahapan pra-pemrosesan seperti normalisasi dan augmentasi data, serta evaluasi performa menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* (Rangga Gelar Guntara, 2023).

Secara teoritis, konsep CNN mendasari penelitian ini dalam proses identifikasi karakteristik fisik rumah melalui citra satelit atau udara. Fitur visual seperti pola atap, bentuk bangunan, dan kondisi struktur dianalisis melalui lapisan-lapisan CNN untuk menghasilkan klasifikasi rumah layak dan tidak layak huni. Hasil tersebut kemudian diintegrasikan ke dalam Sistem Informasi Geografis (SIG) guna mendukung pemetaan spasial yang lebih akurat dan informatif.

2.3.7 Model *EfficientNet-B0*

EfficientNet-B0 merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) yang dirancang menggunakan prinsip *compound scaling*, yaitu metode penskalaan yang menyesuaikan kedalaman jaringan, lebar layer, dan resolusi input secara seimbang. Pendekatan ini memungkinkan model mencapai tingkat akurasi yang tinggi tanpa membutuhkan jumlah parameter yang besar, sehingga lebih efisien dibandingkan arsitektur CNN tradisional (Tan & Le., 2019). Selain itu, *EfficientNet-B0* memanfaatkan blok *Mobile Inverted Bottleneck Convolution* (MBConv) yang efektif dalam menangkap pola visual yang kompleks, menjadikannya sesuai untuk tugas klasifikasi citra, termasuk identifikasi permukiman dan bangunan (Dianto et al., 2025).

Berbagai penelitian nasional menunjukkan bahwa *EfficientNet-B0* mampu memberikan performa generalisasi yang baik, khususnya ketika diimplementasikan melalui teknik transfer learning pada dataset lokal. Model ini juga dinilai unggul dalam aspek akurasi sekaligus efisiensi komputasi, sehingga ideal digunakan pada sistem dengan sumber daya terbatas. Penelitian komparatif terhadap arsitektur CNN ringan memperlihatkan bahwa *EfficientNet-B0* mampu mempertahankan stabilitas performa pada beragam jenis citra, mulai dari objek berukuran kecil hingga struktur fisik yang kompleks (Sitorus et al., 2025). Berdasarkan keunggulan tersebut, *EfficientNet-B0* dipilih dalam penelitian ini untuk mengklasifikasikan kondisi fisik rumah berdasarkan citra satelit atau udara, sebelum hasil analisis tersebut dipetakan dalam Sistem Informasi Geografis (SIG) untuk memetakan sebaran rumah layak huni.



Gambar 2. 1 Ilustrasi Arsitektur *EfficientNet-B0*

Berdasarkan arsitektur pada Gambar 2.1, proses diawali dengan lapisan *Conv2D* untuk mengekstraksi fitur dasar citra, seperti tepi dan pola visual awal bangunan. Selanjutnya, fitur diproses melalui beberapa *MBConv Block* (*Mobile Inverted Bottleneck Convolution*) yang menjadi komponen utama *EfficientNet-B0*. *MBConv Block* berperan dalam memungkinkan model mengekstraksi fitur visual secara efisien melalui perpaduan antara *depthwise convolution*, fungsi aktivasi Swish, serta mekanisme *Squeeze and Excitation*. Proses dalam *MBConv Block* ini dilakukan secara berulang guna memastikan proses ekstraksi fitur berjalan secara optimal.

Pengulangan tersebut bertujuan agar model mampu mengenali karakteristik visual mulai dari tingkat sederhana hingga tingkat kompleks yang penting dalam proses klasifikasi kelayakan hunian. Dari sisi struktur, repetisi ini mencerminkan penerapan prinsip *compound scaling*, yaitu pendekatan yang mengoptimalkan akurasi dengan menambah kedalaman layer secara proporsional. Dengan demikian,

model *EfficientNet-B0* tetap memiliki performa yang baik tanpa mengorbankan efisiensi komputasi.

Mekanisme *Squeeze and Excitation* berperan dalam menyesuaikan bobot kanal fitur berdasarkan tingkat kepentingannya, sehingga model dapat lebih fokus pada karakteristik visual yang relevan untuk penilaian kelayakan hunian, seperti kondisi atap, bentuk bangunan, serta keteraturan lingkungan sekitar rumah. Hal ini menjadikan *EfficientNet-B0* efektif dalam membedakan rumah layak huni dan rumah tidak layak huni berdasarkan informasi visual citra.

Pada tahap akhir, fitur yang telah diekstraksi diringkas menggunakan *Global Average Pooling*, kemudian diteruskan ke *Dense Layer* untuk menghasilkan keluaran klasifikasi. Dengan struktur yang efisien dan kemampuan ekstraksi fitur yang kuat, *EfficientNet-B0* dinilai sesuai untuk digunakan dalam penelitian klasifikasi kondisi rumah berbasis citra, khususnya pada pemetaan rumah layak huni dan tidak layak huni yang membutuhkan akurasi tinggi dan efisiensi komputasi (Burhanuddin et al., 2025).

2.3.8 Integrasi *Deep learning* dan Sistem Informasi Geografis (GeoAI)

Integrasi antara *Deep learning* dan Sistem Informasi Geografis (SIG), yang dikenal sebagai GeoAI, merupakan pendekatan yang menggabungkan kemampuan kecerdasan buatan dalam memahami pola visual dengan analisis ruang pada SIG. Algoritma *Deep learning* seperti *Convolutional Neural Network* (CNN) dapat mengekstraksi karakteristik penting dari citra secara otomatis, sehingga proses klasifikasi objek atau area pada citra menjadi lebih akurat (Meileni et al., 2022).

Penerapan integrasi ini memfasilitasi pemetaan spasial dari data prediksi *Deep Learning* untuk menganalisis korelasi serta distribusi fenomena di permukaan bumi. Salah satu implementasinya terlihat pada studi identifikasi kawasan kumuh, di mana model CNN mengekstraksi informasi kepadatan dan kondisi fisik atap melalui citra satelit, yang selanjutnya diproses dalam sistem SIG untuk memetakan tingkat kerawanan wilayah (Meileni et al., 2022).

Selain itu, teknologi GeoAI juga berperan dalam mendeteksi kerusakan infrastruktur dan perubahan lahan pasca-bencana secara otomatis, sehingga

pemerintah dapat mengambil keputusan berbasis lokasi dengan lebih cepat dibandingkan metode konvensional. Melalui otomatisasi segmentasi wilayah dan pembuatan peta tematik, GeoAI dalam penelitian ini digunakan untuk mengintegrasikan klasifikasi kondisi rumah ke dalam analisis SIG, guna menyajikan pemetaan bantuan rumah layak huni yang lebih akurat dan informatif.

2.3.9 *Confusion Matrix*

Confusion matrix adalah metode yang digunakan untuk menilai kinerja suatu model pembelajaran mesin dengan membandingkan hasil prediksi model terhadap nilai sebenarnya pada data uji. Matriks ini menampilkan distribusi prediksi dalam bentuk tabel, di mana baris merepresentasikan kelas sebenarnya dan kolom menunjukkan kelas yang diprediksi oleh model (Akbari et al., 2023).

Secara konseptual, *Confusion Matrix* terdiri atas empat komponen utama yang menjadi dasar penilaian performa model, yaitu:

1. *True Positive (TP)* – kondisi ketika model berhasil memprediksi kelas positif dengan benar (misalnya, rumah “layak” teridentifikasi benar sebagai “layak”).
2. *True Negative (TN)* – kondisi ketika model memprediksi kelas negatif secara tepat (rumah “tidak layak” terdeteksi benar sebagai “tidak layak”).
3. *False Positive (FP)* – kesalahan prediksi ketika model mengklasifikasikan rumah tidak layak sebagai layak.
4. *False Negative (FN)* – kesalahan prediksi ketika rumah layak diklasifikasikan sebagai tidak layak.

2.3.10 *Python*

Python merupakan bahasa pemrograman tingkat tinggi yang banyak dimanfaatkan dalam analisis data, machine learning, dan pengolahan citra berkat sintaks yang mudah dipahami serta ketersediaan pustaka yang sangat luas. Pada penelitian yang menggunakan pendekatan *Deep Learning*, *Python* menyediakan berbagai library seperti TensorFlow, Keras, NumPy, dan OpenCV yang mendukung tahapan pra-pemrosesan citra, pembangunan arsitektur CNN, hingga

evaluasi model menggunakan metrik kinerja seperti *accuracy*, *precision*, *recall*, dan *F1-score* (Supiyandi & Mailok, 2025).

Dalam ranah pengolahan citra, Python memungkinkan pelaksanaan operasi teknis seperti normalisasi, augmentasi, pengubahan ukuran (*resizing*), serta penyaringan (*filtering*) melalui modul seperti *OpenCV* dan *scikit-image*. Fitur tersebut menjadikan Python banyak digunakan dalam penelitian klasifikasi gambar di tingkat nasional, khususnya ketika diperlukan proses pra-pemrosesan yang terstruktur dan konsisten (Dianto et al., 2025).

Selain itu, Python juga menyediakan pustaka pengolahan data spasial, termasuk GeoPandas dan Rasterio, yang memungkinkan pengintegrasian hasil klasifikasi citra dengan Sistem Informasi Geografis (SIG). Kemampuan ini mendukung pembuatan peta tematik dan analisis spasial, sehingga *Python* menjadi alat penting dalam penelitian yang mengkombinasikan citra digital dengan data geografis (Agri Kristal, 2022).

2.3.11 Google Colaboratory

Google Colaboratory (Google Colab) merupakan platform komputasi berbasis cloud yang menyediakan lingkungan *Jupyter Notebook* untuk menjalankan kode Python tanpa perlu melakukan instalasi pada perangkat pengguna. Secara konseptual, Colab mendukung proses analisis data dan pengembangan model machine learning melalui ketersediaan berbagai pustaka penting seperti NumPy, Pandas, dan Scikit-learn. Platform ini juga menawarkan akses GPU dan TPU yang membantu mempercepat proses pelatihan model dengan kebutuhan komputasi tinggi.

Google Colab dapat terhubung langsung dengan Google Drive, sehingga mempermudah penyimpanan data maupun pengelolaan berkas notebook. Selain itu, antarmuka yang bersifat interaktif mendukung berbagai tahap pemrosesan data, pelatihan model, serta visualisasi hasil analisis. Dalam beberapa publikasi nasional, Colab dimanfaatkan sebagai sarana pemrograman karena kemampuannya menjalankan algoritma machine learning secara efektif di lingkungan komputasi berbasis cloud (Hadi et al., 2025).

Dengan kelebihan tersebut, Google Colab menjadi pilihan yang relevan dalam penelitian yang melibatkan machine learning dan pengolahan citra, khususnya ketika peneliti tidak memiliki perangkat keras dengan kapasitas tinggi secara lokal.

2.4 Kerangka Berpikir


Permasalahan sebaran rumah tidak layak huni (RTLH) di Kota Banda Aceh masih terjadi karena proses pendataan mengandalkan observasi manual yang bersifat subjektif, sehingga sering menimbulkan ketidakakuratan data dan ketidaktepatan sasaran bantuan (Atikah, 2022). Kondisi ini menunjukkan perlunya metode identifikasi yang lebih objektif dan berbasis data.

Dalam teori analisis spasial, SIG memanfaatkan data geolokasi untuk menilai persebaran objek dan menyajikannya dalam bentuk peta tematik sebagai dasar pengambilan keputusan. Namun, SIG memerlukan data masukan yang valid agar representasi spasial yang dihasilkan akurat.

Di sisi lain, perkembangan *Deep learning* khususnya CNN dan arsitektur modern seperti *EfficientNet* mampu mengekstraksi fitur visual dari citra secara otomatis sehingga objek dapat diklasifikasikan dengan akurasi tinggi. Penggabungan *Deep learning* dengan SIG dikenal sebagai GeoAI, yang memungkinkan hasil klasifikasi citra dipetakan secara spasial. Integrasi CNN dan SIG meningkatkan kecepatan pemetaan dan ketelitian dalam identifikasi objek wilayah (Meileni et al., 2022).

Berdasarkan konsep tersebut, alur pemikiran penelitian ini adalah:

1. Menggunakan citra satelit/udara sebagai data visual rumah.
2. Menerapkan *EfficientNet-B0* untuk mengklasifikasikan kondisi rumah menjadi layak atau tidak layak.
3. Mengintegrasikan hasil klasifikasi ke dalam SIG berdasarkan koordinat geografis.
4. Menghasilkan peta sebaran RTLH yang menunjukkan pola, klaster, dan distribusi permukiman.
5. Menjadikan peta tersebut sebagai dasar evaluasi dan perencanaan bantuan rumah layak huni.




Gambar 2. 2 Kerangka Pemikiran Penelitian

Dengan pendekatan GeoAI ini, penelitian diharapkan mampu menghadirkan pemetaan RTLH yang lebih objektif, cepat, dan relevan sebagai dukungan kebijakan perumahan di Banda Aceh.

BAB III METODE PENELITIAN

3.1 Tahapan Penelitian

Tahapan penelitian ini menjelaskan langkah-langkah yang diambil oleh penulis dalam pelaksanaan penelitian. Urutan Langkah-langkah penelitian dapat dilihat pada Gambar 3.1.



Gambar 3. 1 Tahapan Penelitian

Rangkaian penelitian dimulai dengan pengumpulan data citra rumah yang bersumber dari citra udara atau foto bangunan yang mencerminkan kondisi fisik hunian masyarakat. Pemanfaatan citra bangunan sebagai data utama terbukti efektif dalam mengkaji kondisi rumah dan telah banyak digunakan dalam penelitian sejenis (Agri Kristal, 2022). Data citra yang terkumpul kemudian diproses melalui tahap pra-pemrosesan, yang meliputi penyeragaman ukuran citra, normalisasi nilai piksel, serta penerapan teknik augmentasi data guna meningkatkan mutu dan variasi dataset (Rangga Gelar Guntara, 2023).

Tahap selanjutnya adalah pelabelan data dengan mengklasifikasikan citra rumah ke dalam dua kategori, yakni rumah layak huni dan rumah tidak layak huni. Proses pelabelan ini mengacu pada indikator kondisi fisik bangunan yang sesuai

dengan konsep rumah layak huni sebagaimana dibahas dalam kajian perumahan dan permukiman (Atikah, 2022).

Citra yang telah diberi label selanjutnya dimanfaatkan dalam proses pelatihan model *deep learning* menggunakan arsitektur *EfficientNet-B0* melalui pendekatan transfer learning. Pemilihan arsitektur tersebut didasarkan pada kemampuannya dalam mengoptimalkan performa klasifikasi dengan jumlah parameter yang relatif efisien, sebagaimana ditunjukkan dalam penelitian sebelumnya (Burhanuddin et al., 2025).

Setelah proses pelatihan selesai, dilakukan evaluasi kinerja model menggunakan confusion matrix untuk menilai tingkat akurasi serta kesalahan klasifikasi. Pendekatan evaluasi ini umum diterapkan dalam penelitian klasifikasi citra berbasis *deep learning* karena mampu menyajikan hasil pengukuran performa model secara kuantitatif (Akbari et al., 2023). Hasil klasifikasi yang telah tervalidasi selanjutnya diintegrasikan ke dalam Sistem Informasi Geografis (SIG) guna menghasilkan peta sebaran rumah layak huni dan tidak layak huni secara spasial (Meileni et al., 2022).

3.2 Jenis Penelitian

Penelitian ini menerapkan pendekatan kuantitatif sebagai dasar metodologinya. Pendekatan kuantitatif merupakan metode penelitian yang berlandaskan pada pengolahan data dalam bentuk angka serta penggunaan analisis statistik untuk mengkaji keterkaitan antarvariabel dan menguji hipotesis penelitian secara sistematis dan objektif (Sugiyono, 2019).

Pendekatan tersebut dipilih karena relevan untuk mengukur dampak penerapan model *Deep learning EfficientNet-B0* terhadap tingkat ketepatan pemetaan rumah layak huni berbasis Sistem Informasi Geografis (SIG). Dalam kajian klasifikasi citra dan pemetaan spasial, metode kuantitatif banyak digunakan karena mampu menyajikan evaluasi kinerja model secara terukur, seperti nilai akurasi dan kesalahan klasifikasi (Munawwarah et al., 2025).

Dalam penelitian ini, pendekatan kuantitatif diimplementasikan dengan mengolah dataset sebanyak 1.196 citra rumah yang terdiri atas 598 citra rumah layak huni dan 598 citra rumah tidak layak huni. Seluruh dataset diproses

menggunakan model *EfficientNet-B0*, kemudian dilakukan evaluasi berdasarkan metrik akurasi, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Hasil evaluasi tersebut menjadi dasar dalam menilai performa model untuk mengklasifikasikan kondisi rumah serta mendukung penyusunan pemetaan berbasis Sistem Informasi Geografis (SIG).

3.3 Data dan Sumber Data

Data yang dimanfaatkan dalam penelitian ini dikelompokkan ke dalam dua jenis, yaitu data primer dan data sekunder. Pengelompokan ini dilakukan untuk membedakan antara data yang diperoleh serta diolah secara langsung oleh peneliti dan data pelengkap yang bersumber dari instansi atau lembaga resmi.

3.3.1 Data Primer

Data primer merupakan sumber data utama yang digunakan dalam penelitian ini dan diperoleh melalui proses pengumpulan serta pengolahan yang dilakukan langsung oleh peneliti. Data tersebut berupa citra tampak atas (*top view*) rumah di wilayah Kota Banda Aceh yang diambil melalui *Google Earth* diakses pada tahun 2024-2025 dengan mengacu pada koordinat GPS yang diperoleh dari kegiatan survei lapangan. Pemanfaatan koordinat GPS bertujuan untuk memastikan bahwa citra yang digunakan benar-benar merepresentasikan lokasi rumah yang menjadi objek penelitian.

Dataset yang digunakan pada penelitian ini terdiri atas sebanyak 1.196 citra rumah, yang meliputi 598 citra rumah layak huni dan 598 citra rumah tidak layak huni. Seluruh data tersebut berasal dari 9 kecamatan di Kota Banda Aceh, yaitu Kecamatan Baiturrahman, Banda Raya, Jaya Baru, Kuta Alam, Kuta Raja, Lueng Bata, Meuraxa, Syiah Kuala, dan Ulee Kareng. Contoh citra tampak atas yang digunakan sebagai data penelitian dapat dilihat pada Gambar 3.2.



Gambar 3. 2 Contoh Citra Tampak Atas Rumah Layak Huni dan Rumah Tidak Layak Huni

Pada Gambar 3.2 menunjukkan citra tampak atas tersebut digunakan sebagai data masukan (*input*) dalam proses klasifikasi menggunakan metode *Deep Learning*. Penggunaan citra dari *Google Earth* memungkinkan identifikasi berbagai karakteristik visual bangunan, seperti bentuk dan kondisi atap, serta lingkungan di sekitar rumah yang dapat mendukung proses penentuan kategori kelayakan hunian.

Selain citra, data primer juga meliputi proses pelabelan (*labeling*) yang dilakukan oleh peneliti berdasarkan hasil pengamatan terhadap karakteristik fisik pada setiap rumah. Selanjutnya, seluruh citra dikelompokkan ke dalam dua kelas, yaitu rumah layak huni dan rumah tidak layak huni. Label tersebut digunakan sebagai *ground truth* pada tahap pelatihan dan evaluasi model sehingga seluruh data primer yang dimanfaatkan dalam penelitian ini berasal dari proses pengumpulan, pelabelan, dan pengolahan yang dilakukan secara langsung oleh peneliti.

3.3.2 Data Sekunder

Data sekunder merupakan data pendukung yang diperoleh dari Kantor Dinas Perumahan Rakyat dan Kawasan Permukiman Kota Banda Aceh yang akan digunakan untuk melengkapi analisis spasial dalam penelitian ini. Data sekunder yang digunakan mencakup peta administrasi Kota Banda Aceh yang berisi informasi batas wilayah kecamatan dan kelurahan. Peta administrasi ini berfungsi sebagai acuan dasar dalam proses pemetaan dan penentuan lokasi sebaran rumah layak huni dan tidak layak huni.

Selain peta administrasi, penelitian ini juga memanfaatkan data shapefile batas wilayah yang digunakan dalam proses pengolahan serta visualisasi data pada

Sistem Informasi Geografis (SIG). Apabila tersedia, data bantuan Rumah Tidak Layak Huni (RTLH) dari instansi terkait turut digunakan sebagai data pendukung untuk memberikan gambaran kebijakan serta memperkuat interpretasi hasil pemetaan. Seluruh data sekunder tersebut digunakan untuk mendukung integrasi hasil klasifikasi citra ke dalam peta tematik berbasis SIG.

3.4 Teknik Pengumpulan Data

Pengumpulan data dalam penelitian ini dilaksanakan melalui beberapa langkah yang disesuaikan dengan jenis data yang digunakan, yaitu data primer dan data sekunder. Proses pengumpulan data bertujuan untuk menghasilkan data yang valid, relevan, dan siap diolah dalam analisis klasifikasi citra serta pemetaan spasial berbasis Sistem Informasi Geografis (SIG).


Data primer dikumpulkan dengan cara memperoleh citra satelit atau citra udara yang menggambarkan kondisi fisik bangunan rumah di wilayah penelitian. Citra tersebut diperoleh dari data terbuka seperti Google Earth atau Sentinel, kemudian diseleksi berdasarkan kualitas visual, luas cakupan wilayah, serta kesesuaian waktu perekaman dengan periode penelitian. Setelah citra terkumpul, dilakukan pengamatan visual terhadap setiap citra rumah untuk keperluan pelabelan data. Pelabelan dilakukan dengan mengelompokkan citra ke dalam kategori rumah layak huni dan rumah tidak layak huni berdasarkan indikator kondisi fisik bangunan yang telah ditentukan. Data hasil pelabelan ini selanjutnya digunakan sebagai data latih (*ground truth*) dalam proses pelatihan model deep learning.

Di sisi lain, data sekunder diperoleh dengan mengumpulkan data pendukung yang bersumber Kantor Dinas Perumahan Rakyat dan Kawasan Permukiman Kota Banda Aceh. Data sekunder yang digunakan meliputi peta administrasi Kota Banda Aceh, data shapefile batas wilayah administrasi, serta data bantuan Rumah Tidak Layak Huni (RTLH) apabila tersedia. Data tersebut dimanfaatkan untuk mendukung integrasi hasil klasifikasi citra ke dalam Sistem Informasi Geografis (SIG), sekaligus sebagai bahan analisis dan visualisasi sebaran spasial rumah layak huni dan tidak layak huni.

3.5 Pra-pemrosesan Data Citra

Tahap pra-pemrosesan citra merupakan bagian yang sangat penting sebelum data digunakan dalam pelatihan model *deep learning*. Tahapan ini bertujuan untuk memperbaiki kualitas citra, menyeragamkan karakteristik data masukan, serta mengurangi gangguan visual yang berpotensi memengaruhi akurasi model klasifikasi. Dalam penelitian klasifikasi citra bangunan berbasis *deep learning*, pra-pemrosesan umumnya diterapkan untuk memastikan bahwa data yang digunakan berada pada kondisi yang optimal (Agri Kristal, 2022).

Pemrosesan data citra dapat dilihat dan dijelaskan dengan diagram alir pada Gambar 3.3.



Gambar 3. 3 Diagram Alir Pra-pemrosesan Data Citra

Pada Gambar 3.3 menunjukkan proses awal pra-pemrosesan dilakukan dengan resizing yaitu penyesuaian ukuran citra menjadi 224×224 piksel agar seluruh data memiliki dimensi yang seragam serta sesuai dengan spesifikasi input model *EfficientNet-B0*. Penyeragaman dimensi citra diperlukan untuk menjaga konsistensi data masukan serta meningkatkan efisiensi dan stabilitas selama proses pelatihan model. Pendekatan ini juga banyak diterapkan dalam penelitian

klasifikasi citra bangunan dan objek menggunakan arsitektur CNN yang bersifat ringan dan efisien (Burhanuddin et al., 2025). Setelah itu, dilakukan normalisasi nilai piksel dengan tujuan mengubah rentang nilai piksel ke skala tertentu, sehingga proses konvergensi model dapat berlangsung lebih cepat dan stabil (Taufiqurrahman, Indah Clara Sari, 2024)

Tahapan selanjutnya adalah augmentasi data citra yang bertujuan untuk memperkaya variasi dataset sekaligus menekan risiko terjadinya *overfitting*. Teknik augmentasi yang digunakan meliputi rotasi, pembalikan citra (*flip*), pergeseran posisi, serta penyesuaian tingkat kecerahan. Penerapan teknik ini umum digunakan dalam penelitian citra bangunan dan rumah untuk menggambarkan perbedaan kondisi pengambilan citra, seperti variasi sudut pandang dan pencahayaan lingkungan (Rangga Gelar Guntara, 2023).

Selain itu, dilakukan proses evaluasi kualitas citra untuk memastikan bahwa data yang digunakan tidak mengalami gangguan visual yang signifikan, seperti citra buram, terpotong, atau tertutup oleh objek lain. Citra yang tidak memenuhi kriteria kualitas dikeluarkan dari dataset agar tidak berdampak negatif terhadap kinerja model pada tahap pelatihan maupun evaluasi. Proses seleksi kualitas citra ini sejalan dengan pendekatan yang diterapkan dalam penelitian klasifikasi citra rumah berbasis *deep learning* (Akbari et al., 2023). Melalui rangkaian tahapan pra-pemrosesan tersebut, data citra yang digunakan diharapkan siap dan layak untuk mendukung proses pelatihan serta evaluasi model *deep learning* dalam klasifikasi kondisi rumah.

3.6 Metode Klasifikasi (*EfficientNet-B0*)

Metode klasifikasi yang diterapkan dalam penelitian ini menggunakan pendekatan deep learning berbasis *Convolutional Neural Network (CNN)* dengan arsitektur *EfficientNet-B0*. Arsitektur tersebut dipilih karena mampu menghasilkan performa klasifikasi yang tinggi dengan jumlah parameter yang relatif sedikit, sehingga lebih efisien dalam proses pelatihan dan sesuai untuk pengolahan citra bangunan atau rumah pada kondisi keterbatasan sumber daya komputasi. *EfficientNet* dikembangkan dengan konsep compound scaling, yaitu strategi

penskalaan jaringan yang secara seimbang mengatur kedalaman, lebar, dan resolusi input guna meningkatkan kinerja model secara optimal (Sitorus et al., 2025).

Dalam penerapannya, *EfficientNet-B0* digunakan sebagai base model melalui pendekatan transfer learning. Model yang telah dilatih sebelumnya menggunakan dataset *ImageNet* dimanfaatkan untuk mengekstraksi fitur visual penting dari citra rumah, seperti tekstur atap, bentuk bangunan, serta karakteristik lingkungan sekitarnya. Pendekatan ini dipilih karena mampu mempercepat proses pelatihan sekaligus meningkatkan akurasi klasifikasi, terutama ketika jumlah data latih terbatas. Penggunaan *EfficientNet* dengan transfer learning telah banyak diterapkan dalam penelitian klasifikasi citra bangunan berbasis CNN ringan dan menunjukkan hasil yang optimal (Burhanuddin et al., 2025).

Selanjutnya, fitur yang dihasilkan oleh *EfficientNet-B0* diteruskan ke lapisan klasifikasi (*fully connected layer*) untuk mengelompokkan citra rumah ke dalam dua kelas, yaitu rumah layak huni dan rumah tidak layak huni. Proses pelatihan dilakukan dengan menyesuaikan bobot model menggunakan algoritma optimasi serta fungsi kerugian yang sesuai untuk klasifikasi biner. Pendekatan ini sejalan dengan penelitian sebelumnya yang memanfaatkan CNN dalam mengenali kondisi fisik hunian berdasarkan karakteristik visual citra (Agri Kristal, 2022).

Proses pelatihan model *EfficientNet-B0* dilakukan dengan menetapkan beberapa hyperparameter sebagai pengaturan utama dalam proses pembelajaran. Konfigurasi *hyperparameter* tersebut disusun berdasarkan karakteristik dataset penelitian dan mengacu pada pendekatan yang umum digunakan dalam implementasi transfer learning untuk klasifikasi citra. Adapun rincian hyperparameter yang digunakan pada penelitian ini dapat dilihat pada Tabel 3.1.

Tabel 3. 1 Konfigurasi Hyperparameter Model EfficientNet-B0

Parameter	Nilai	Keterangan
Arsitektur Model	EfficientNet-B0	Transfer Learning
Ukuran Citra	224 x 224 piksel	Input model
Batch Size	32	Jumlah citra tiap iterasi
Optimizer	Adam	Optimasi bobot model
Learning Rate (Warm-up)	0,001	Tahap awal pelatihan

Learning Rate (Fine-tuning)	0,00005	Tahap penyesuaian bobot
Epoch Warm-up	5	Base model dibekukan
Epoch Fine-tuning	Maksimal 15	Dengan Early Stopping
Loss Function	Binary Crossentropy	Klasifikasi biner
Activation Function	Sigmoid	Output probabilitas dua kelas
Early Stopping	Patience = 4	Menghentikan pelatihan saat validasi tidak membaik
Restore Best Weights	True	Menggunakan bobot terbaik selama pelatihan

Evaluasi kinerja model dilakukan menggunakan *confusion matrix* untuk mengukur tingkat akurasi dan kesalahan klasifikasi antar kelas. Metode evaluasi ini memberikan gambaran kuantitatif mengenai kemampuan model dalam membedakan kondisi rumah secara tepat. Penggunaan *confusion matrix* umum diterapkan dalam penelitian klasifikasi citra berbasis *deep learning* karena mampu menyajikan informasi performa model secara komprehensif (Akbari et al., 2023).

3.7 Evaluasi Model

Evaluasi model dilakukan untuk menilai kemampuan model klasifikasi dalam membedakan citra rumah layak huni dan tidak layak huni secara akurat. Proses evaluasi dilakukan setelah tahap pelatihan selesai dengan menggunakan data uji yang tidak terlibat dalam pembelajaran model, sehingga dapat menggambarkan kemampuan generalisasi model terhadap data baru dan meminimalkan bias akibat penggunaan data latih yang sama (Akbari et al., 2023).

Metode evaluasi yang digunakan adalah *confusion matrix*, yang membandingkan hasil prediksi model dengan label sebenarnya. Berdasarkan *confusion matrix* tersebut dihitung metrik akurasi, *precision*, *recall*, dan *F1-score* untuk menilai kinerja model secara menyeluruh dan per kelas. Hasil evaluasi ini digunakan sebagai dasar untuk menentukan kelayakan model *EfficientNet-B0*

sebelum diintegrasikan ke dalam Sistem Informasi Geografis (SIG) guna menghasilkan peta sebaran rumah layak huni dan tidak layak huni secara spasial (Burhanuddin et al., 2025).

Rumus confusion matrix digunakan untuk mengukur berbagai kinerja, seperti akurasi, presisi, perolehan, spesifikasi, dan skor F1, untuk melihat seberapa baik pembelajaran mesin bekerja seperti yang diharapkan (N. A. Salsabila, 2022). Secara konseptual, *Confusion Matrix* terdiri atas empat komponen utama yang menjadi dasar penilaian performa model, yaitu:

1. *True Positive (TP)* – Rumah layak huni yang diprediksi sebagai layak huni.
2. *True Negative (TN)* – Rumah tidak layak huni yang diprediksi sebagai tidak layak huni.
3. *False Positive (FP)* – Rumah tidak layak huni yang diprediksi sebagai layak huni.
4. *False Negative (FN)* – Rumah layak huni yang diprediksi sebagai tidak layak huni.

Dari keempat elemen ini, diperoleh beberapa indikator evaluasi penting, yaitu:

1. *Recall / Sensitivity*, yang menunjukkan kemampuan model dalam menangkap seluruh sampel yang termasuk dalam kelas positif.

$$\text{Recal} = \frac{TP}{TP + FN}$$

2. *Precision*, yang mengukur tingkat ketepatan model dalam memberikan prediksi positif.

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

3. *F1-Score*, yaitu rata-rata harmonis antara precision dan recall, digunakan untuk menilai model ketika diperlukan keseimbangan antara kedua metrik tersebut.

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

4. *Accuracy*, yang menggambarkan tingkat keseluruhan ketepatan prediksi model terhadap seluruh data.

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

3.8 Integrasi Hasil Klasifikasi dengan SIG

Integrasi hasil klasifikasi citra rumah ke dalam Sistem Informasi Geografis (SIG) dilakukan untuk menampilkan kondisi rumah layak huni dan tidak layak huni dalam bentuk informasi spasial. Integrasi ini bertujuan mengaitkan keluaran model *deep learning* dengan data lokasi geografis sehingga informasi yang dihasilkan tidak hanya berupa nilai atau label klasifikasi, tetapi juga dilengkapi dengan konteks keruangan yang jelas. Pendekatan penggabungan antara *deep learning* dan SIG dikenal sebagai GeoAI dan telah banyak digunakan dalam penelitian pemetaan berbasis citra serta analisis wilayah (Meileni et al., 2022).

Keluaran model *EfficientNet-B0* berupa hasil klasifikasi kondisi rumah kemudian dihubungkan dengan koordinat geografis masing-masing objek bangunan. Data klasifikasi tersebut selanjutnya diubah ke dalam format data spasial, seperti shapefile atau geodatabase, agar dapat diproses lebih lanjut menggunakan perangkat lunak SIG. Tahapan ini memungkinkan setiap prediksi model direpresentasikan sebagai objek spasial yang memiliki informasi atribut klasifikasi sekaligus posisi geografisnya (Akmal, 2023).

Selanjutnya, data spasial yang telah terbentuk diolah dan divisualisasikan dalam lingkungan SIG dengan memanfaatkan peta administrasi dan batas wilayah sebagai peta dasar. Hasil klasifikasi disajikan dalam bentuk peta tematik yang menggambarkan sebaran rumah layak huni dan tidak layak huni pada wilayah penelitian. Penyajian peta tematik ini mempermudah analisis pola sebaran spasial serta identifikasi wilayah yang memiliki tingkat kerentanan hunian lebih tinggi,

sebagaimana diterapkan dalam penelitian pemetaan rumah tidak layak huni berbasis SIG (Wicaksono et al., 2023).

Tabel 3. 2 Alur Teknis Integrasi Hasil Klasifikasi dengan SIG

No	Tahapan Integrasi	Deskripsi Teknis	Output
1	Hasil Klasifikasi Model	Model <i>EfficientNet-B0</i> menghasilkan label kelas rumah (layak huni / tidak layak huni) untuk setiap citra rumah	Data klasifikasi (label + ID citra)
2	Penautan Data Spasial	Hasil klasifikasi dikaitkan dengan informasi koordinat geografis masing-masing rumah	Data atribut berkoordinat
3	Konversi ke Format Spasial	Data klasifikasi dikonversi ke format spasial seperti shapefile atau geodatabase	File shapefile / geodatabase
4	Integrasi ke Perangkat SIG	Data spasial dimasukkan ke dalam perangkat lunak SIG (QGIS/ArcGIS)	Layer spasial RTLH
5	Overlay dengan Peta Administrasi	Layer hasil klasifikasi dioverlay dengan peta batas kecamatan/kelurahan	Layer tematik terintegrasi
6	Visualisasi Peta Tematik	Penyajian peta sebaran rumah layak huni dan tidak layak huni	Peta sebaran RTLH
7	Analisis Spasial	Analisis pola sebaran dan identifikasi wilayah prioritas	Informasi pendukung kebijakan

Alur teknis integrasi pada Tabel 3.2 menunjukkan hasil klasifikasi dengan Sistem Informasi Geografis dimulai dari keluaran model *EfficientNet-B0* berupa label kelas rumah, yang kemudian dikaitkan dengan koordinat geografis masing-masing objek. Data tersebut dikonversi ke format spasial dan diolah dalam perangkat lunak SIG untuk menghasilkan peta tematik sebaran rumah layak huni dan tidak layak huni, sebagaimana pendekatan integrasi *deep learning* dan SIG yang dijelaskan oleh (Meileni et al., 2022; Wicaksono et al., 2023).

Melalui proses integrasi tersebut, hasil klasifikasi citra tidak hanya berperan sebagai keluaran model, tetapi juga menjadi informasi spasial yang dapat dimanfaatkan dalam mendukung pengambilan keputusan, perencanaan wilayah, serta evaluasi kebijakan bantuan perumahan. Dengan demikian, integrasi *deep learning* dan SIG memberikan pendekatan yang lebih menyeluruh dalam pemetaan dan analisis kondisi rumah layak huni berdasarkan aspek lokasi (Chaniago & Taki, 2022).


3.9 Teknis Analisis Data

Teknik analisis data pada penelitian ini diterapkan secara sistematis dan saling terhubung untuk mencapai tujuan penelitian, yaitu mengklasifikasikan kondisi rumah layak huni dan tidak layak huni berdasarkan citra serta menyajikan distribusinya secara spasial. Proses analisis meliputi analisis citra digital, evaluasi kinerja model *deep learning*, dan analisis spasial berbasis Sistem Informasi Geografis (SIG). Pendekatan analisis terintegrasi ini banyak digunakan dalam penelitian yang menggabungkan metode *deep learning* dengan SIG untuk pemetaan objek berbasis citra (Meileni et al., 2022).

Tahapan awal analisis dilakukan melalui pengolahan citra digital yang mencakup hasil pra-pemrosesan dan proses pelabelan citra rumah. Citra yang telah melalui tahap normalisasi dan augmentasi kemudian dimanfaatkan sebagai data masukan dalam pelatihan model *EfficientNet-B0*. Pada tahap ini, analisis diarahkan pada kemampuan model dalam mengekstraksi karakteristik visual rumah, seperti bentuk bangunan, tekstur atap, serta kondisi lingkungan sekitarnya, yang menjadi dasar dalam penentuan klasifikasi kondisi rumah (Agri Kristal, 2022).

Tahap berikutnya adalah analisis kinerja model klasifikasi yang dilakukan secara kuantitatif. Hasil prediksi model dibandingkan dengan label aktual menggunakan confusion matrix untuk memperoleh nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik-metrik tersebut digunakan untuk menilai tingkat ketepatan dan reliabilitas model *EfficientNet-B0* dalam membedakan rumah layak huni dan tidak layak huni. Metode evaluasi ini umum diterapkan dalam penelitian klasifikasi citra rumah dan bangunan berbasis *deep learning* (Akbari et al., 2023; Burhanuddin et al., 2025).

Tahap akhir analisis data melibatkan analisis spasial menggunakan Sistem Informasi Geografis (SIG). Hasil klasifikasi citra yang telah melalui proses validasi diintegrasikan ke dalam data spasial dan ditampilkan dalam bentuk peta tematik. Analisis spasial ini bertujuan untuk mengidentifikasi pola persebaran rumah layak huni dan tidak layak huni berdasarkan wilayah administrasi, sehingga area dengan tingkat kerentanan hunian yang tinggi dapat dikenali. Pendekatan ini sejalan dengan penelitian pemetaan kondisi sosial dan permukiman berbasis SIG (Chaniago & Taki, 2022; Wicaksono et al., 2023).



BAB IV HASIL DAN PEMBAHASAN

4.1 Implementasi Penelitian

4.1.1 Persiapan Dataset

Tahapan awal penelitian difokuskan pada persiapan lingkungan kerja (*development environment*) serta penyediaan dataset yang akan digunakan dalam proses pelatihan model *deep learning*. Seluruh rangkaian implementasi dilakukan menggunakan *Google Colaboratory* (Google Colab) sebagai platform komputasi berbasis *cloud*, dengan memanfaatkan bahasa pemrograman *Python* dan *framework TensorFlow*. Pemilihan Google Colab didasarkan pada kemampuannya menyediakan akselerasi GPU sehingga proses pelatihan model dapat berlangsung lebih efisien dibandingkan menggunakan perangkat komputasi dengan spesifikasi standar.


Selama proses implementasi, penelitian ini memanfaatkan fasilitas komputasi yang tersedia pada Google Colaboratory. Lingkungan pengembangan menggunakan bahasa pemrograman Python serta *framework TensorFlow* untuk membangun dan melatih model EfficientNet-B0. Spesifikasi perangkat keras dan perangkat lunak yang digunakan selama penelitian disajikan pada Tabel 4.1.

Tabel 4. 1 Spesifikasi Perangkat Penelitian

Komponen	Spesifikasi
<i>Platform</i>	<i>Google Colaboratory</i>
CPU	Intel Xeon @ 2.20 GHz
RAM	±12 GB
GPU	NVIDIA Tesla T4
Bahasa Pemograman	Python 3.12.13
<i>Framework</i>	TensorFlow 2.20.0
Perangkat Lunak SIG	QGIS 4.0.3
Sumber Citra	Google Earth Pro

Dataset yang digunakan berupa kumpulan citra tampak atas (*top view*) rumah di wilayah Kota Banda Aceh yang diperoleh melalui resolusi yang tersedia pada *Google Earth* berdasarkan koordinat GPS hasil survei lapangan. Selanjutnya, setiap citra diberi label berdasarkan kondisi fisik atap bangunan sehingga terbagi ke dalam dua kategori, yaitu rumah layak huni dan rumah tidak layak huni. Proses pelabelan dilakukan untuk memberikan label acuan (*ground truth*) sehingga model dapat mempelajari karakteristik visual dari masing-masing kategori sebagai dasar dalam proses klasifikasi.

Sebelum diproses lebih lanjut, seluruh dataset dikemas dalam format *.zip* kemudian diunggah ke lingkungan Google Colab. Setelah proses unggah selesai, dilakukan ekstraksi berkas agar struktur direktori dapat dikenali oleh sistem. Hasil identifikasi menunjukkan bahwa dataset tersusun dalam dua folder utama, yaitu layak dan tidak_layak, yang masing-masing mewakili kelas yang digunakan pada penelitian ini.



Gambar 4. 1 Struktur Folder Dataset

Gambar 4.1 menunjukkan bahwa dataset telah tersusun dalam dua direktori utama sesuai dengan kelas target klasifikasi. Struktur folder tersebut memudahkan proses pembacaan dataset menggunakan fungsi *flow_from_directory()* pada *TensorFlow* sehingga label kelas dapat dikenali secara otomatis.

Berdasarkan hasil identifikasi, dataset yang digunakan berjumlah 1.196 citra, terdiri atas 598 citra rumah layak huni dan 598 citra rumah tidak layak huni. Jumlah data yang sama pada kedua kategori menunjukkan bahwa distribusi dataset berada dalam kondisi seimbang. Kondisi tersebut penting karena dapat meminimalkan terjadinya *class imbalance*, sehingga model memperoleh kesempatan yang setara untuk mempelajari karakteristik masing-masing kelas dan menghasilkan proses klasifikasi yang lebih objektif.

Tabel 4. 2 Distribusi Dataset

Kelas	Jumlah Data Citra
Rumah Layak	598
Rumah Tidak Layak	598
Total	1.196

Distribusi data yang proporsional memberikan kontribusi positif terhadap proses pelatihan model. Selain meningkatkan stabilitas pembelajaran, keseimbangan jumlah data pada setiap kelas juga berpotensi menghasilkan performa klasifikasi yang lebih optimal ketika model dievaluasi.


4.1.2 Pra-pemrosesan Dataset

Setelah proses persiapan dataset selesai dilakukan, tahapan berikutnya adalah pra-pemrosesan (*pre-processing*). Tahapan ini bertujuan untuk memastikan bahwa data yang digunakan telah memenuhi standar kualitas sehingga dapat mendukung proses pembelajaran model secara optimal.

Langkah awal pada tahap ini adalah melakukan audit dataset. Audit dilakukan dengan memeriksa jumlah citra pada setiap kelas sekaligus mengevaluasi kondisi seluruh file gambar. Pemeriksaan kualitas citra memanfaatkan pustaka *Python Imaging Library* (PIL) melalui metode *image verification*, yang berfungsi untuk memastikan bahwa setiap file dapat dibaca dengan baik oleh sistem. Berdasarkan hasil pemeriksaan, tidak ditemukan citra yang mengalami kerusakan (*corrupted image*), sehingga seluruh dataset dinyatakan layak digunakan tanpa memerlukan proses pembersihan data (*data cleaning*).

Tahapan berikutnya adalah melakukan visualisasi beberapa sampel citra yang dipilih secara acak dari dataset. Visualisasi ini bertujuan untuk memberikan gambaran mengenai karakteristik data yang akan dipelajari oleh model. Hasil pengamatan menunjukkan bahwa dataset memiliki variasi yang cukup beragam, baik dari sisi bentuk bangunan, warna dinding, jenis material atap, kondisi pencahayaan, sudut pengambilan gambar, maupun lingkungan di sekitar rumah. Keberagaman tersebut menjadi keuntungan karena dapat membantu model

mempelajari berbagai pola visual sehingga kemampuan generalisasinya meningkat ketika dihadapkan pada data baru.



Gambar 4. 2 Contoh Citra Dataset

Berdasarkan Gambar 4.2 dapat dilihat bahwa citra memiliki karakteristik yang beragam, baik dari segi bentuk bangunan, warna dinding, jenis atap, kondisi lingkungan, maupun sudut pengambilan gambar. Keberagaman tersebut diharapkan mampu meningkatkan kemampuan model dalam mempelajari pola visual sehingga model lebih baik dalam melakukan generalisasi terhadap data baru.

Tahapan selanjutnya adalah membagi dataset menggunakan metode *hold-out*, dengan komposisi 70% data pelatihan (*training*), 15% data validasi (*validation*), dan 15% data pengujian (*testing*). Pembagian ini dilakukan agar setiap tahap memiliki fungsi yang berbeda, yaitu data pelatihan digunakan untuk membangun model, data validasi dimanfaatkan untuk memantau proses pembelajaran, sedangkan data pengujian digunakan untuk mengevaluasi performa akhir model terhadap data yang belum pernah dipelajari sebelumnya.

Tabel 4. 3 Hasil Pembagian Dataset

Dataset	Persentase	Jumlah Citra
Training	70%	836
Validation	15%	178
Testing	15%	182
Total	100%	1.196

Pada data pelatihan diterapkan teknik *data augmentation* menggunakan *ImageDataGenerator*. Transformasi yang digunakan meliputi rotasi gambar hingga 20°, *horizontal flip*, serta fill mode nearest. Teknik ini menghasilkan variasi citra secara otomatis tanpa mengubah label aslinya, sehingga model memperoleh lebih banyak contoh data selama proses pembelajaran.

Sementara itu, data validasi dan data pengujian tidak diberikan perlakuan augmentasi agar proses evaluasi dilakukan menggunakan citra asli. Pendekatan tersebut bertujuan menghasilkan penilaian performa model yang lebih objektif dan mendekati kondisi implementasi sebenarnya.

Secara keseluruhan, tahapan persiapan dan pra-pemrosesan dataset telah menghasilkan data yang berkualitas, memiliki distribusi kelas yang seimbang, serta menyajikan variasi visual yang memadai. Kondisi tersebut menjadi fondasi yang kuat untuk mendukung proses pengembangan dan pelatihan model *EfficientNet-B0* pada tahap penelitian selanjutnya.

4.2 Implementasi Model *EfficientNet-B0*

Setelah seluruh tahapan persiapan serta pra-pemrosesan dataset diselesaikan, penelitian dilanjutkan pada tahap implementasi model *EfficientNet-B0* sebagai metode utama untuk mengklasifikasikan citra rumah ke dalam kategori rumah layak huni dan rumah tidak layak huni. Tahapan ini mencakup proses penyusunan arsitektur model, penambahan lapisan klasifikasi, serta pelatihan model dengan memanfaatkan pendekatan *transfer learning*. Implementasi tersebut bertujuan menghasilkan model yang mampu mengenali karakteristik visual rumah secara efektif berdasarkan citra yang diberikan sebagai masukan.

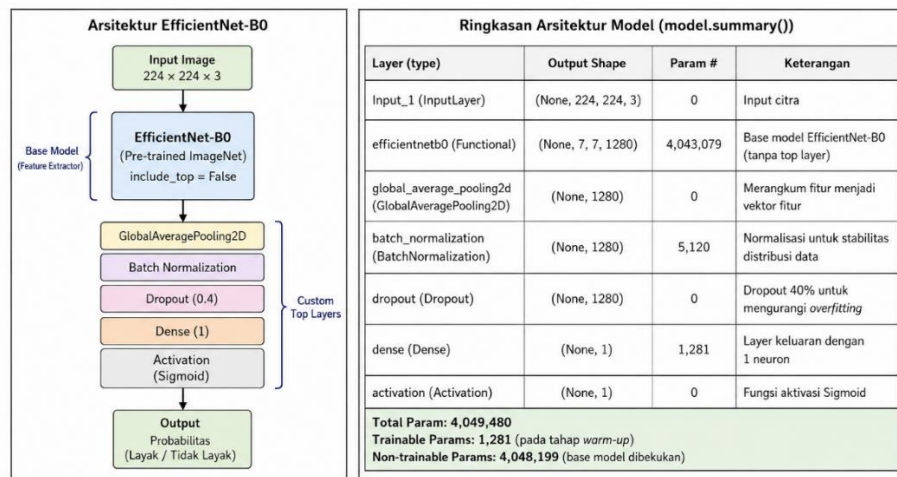
4.2.1 Arsitektur Model *EfficientNet-B0*

Penelitian ini memanfaatkan *EfficientNet-B0* sebagai model klasifikasi utama. *EfficientNet-B0* merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh Google dengan menerapkan metode *compound scaling*. Berbeda dengan pendekatan CNN konvensional yang umumnya

hanya meningkatkan kedalaman (*depth*) atau lebar (*width*) jaringan, *EfficientNet* mengoptimalkan tiga komponen secara bersamaan, yaitu kedalaman jaringan, lebar jaringan, dan resolusi citra. Pendekatan tersebut memungkinkan model memperoleh tingkat akurasi yang tinggi dengan jumlah parameter yang lebih sedikit sehingga proses komputasi menjadi lebih efisien.

Pemilihan *EfficientNet-B0* didasarkan pada beberapa alasan. Pertama, ukuran model relatif ringan sehingga sesuai dijalankan pada lingkungan komputasi berbasis *cloud* seperti *Google Colaboratory*. Kedua, model ini telah melalui proses pelatihan awal menggunakan dataset *ImageNet* yang berisi jutaan citra dengan berbagai objek. Hasil pelatihan tersebut membuat *EfficientNet-B0* telah memiliki kemampuan dasar dalam mengenali pola visual, seperti bentuk, tekstur, warna, dan tepi objek. Kemampuan tersebut kemudian dimanfaatkan kembali melalui teknik *transfer learning*, sehingga proses pelatihan menjadi lebih cepat dan tetap memberikan performa yang baik meskipun menggunakan dataset penelitian dengan jumlah data yang lebih terbatas.

Pada tahap implementasi, lapisan klasifikasi bawaan (*top layer*) pada *EfficientNet-B0* tidak digunakan (*include_top=False*) karena model akan disesuaikan dengan kebutuhan penelitian. Sebagai penggantinya ditambahkan beberapa lapisan baru, yaitu *GlobalAveragePooling2D*, *Batch Normalization*, *Dropout*, dan *Dense Layer*. Lapisan *GlobalAveragePooling2D* berfungsi merangkum hasil ekstraksi fitur menjadi representasi yang lebih ringkas. Selanjutnya, *Batch Normalization* diterapkan untuk menjaga kestabilan distribusi data selama proses pelatihan, sedangkan *Dropout* dengan nilai 0,4 digunakan untuk mengurangi kemungkinan terjadinya *overfitting*. Pada lapisan keluaran digunakan *Dense Layer* dengan satu neuron yang menerapkan fungsi aktivasi *Sigmoid*, karena penelitian ini hanya mengelompokkan citra ke dalam dua kategori, yaitu rumah layak huni dan rumah tidak layak huni.



Gambar 4. 3 Arsitektur Implementasi Model *EfficientNet-B0* untuk Klasifikasi Citra Rumah


Berdasarkan Gambar 4.3, *EfficientNet-B0* berfungsi sebagai *feature extractor* yang bertugas mengekstraksi karakteristik visual dari citra rumah. Informasi fitur yang dihasilkan kemudian diproses oleh lapisan klasifikasi tambahan sehingga model mampu menghasilkan nilai probabilitas yang menunjukkan kecenderungan suatu citra termasuk ke dalam kategori rumah layak huni maupun rumah tidak layak huni.

4.2.2 Proses Pelatihan Model

Setelah proses perancangan arsitektur *EfficientNet-B0* selesai dilakukan, tahapan selanjutnya adalah melatih model menggunakan dataset citra rumah yang telah dipersiapkan sebelumnya. Pelatihan ini bertujuan untuk meningkatkan kemampuan model dalam membedakan karakteristik visual antara rumah layak huni dan rumah tidak layak huni dengan memanfaatkan pendekatan *transfer learning*. Melalui pendekatan tersebut, pengetahuan yang telah diperoleh model dari dataset ImageNet dapat dimanfaatkan kembali dan disesuaikan dengan karakteristik data pada penelitian ini.

Sebelum proses pelatihan dimulai, dataset terlebih dahulu dipisahkan ke dalam data *training*, *validation*, dan *testing*. Setiap citra hanya digunakan pada satu subset data sehingga tidak terdapat duplikasi citra maupun penggunaan titik koordinat yang sama pada proses pelatihan, validasi, dan pengujian. Dengan

demikian, setiap subset merepresentasikan data yang berbeda sehingga risiko *data leakage* dapat diminimalkan dan hasil evaluasi model menjadi lebih objektif.



Gambar 4. 4 Diagram Alur Pelatihan Model *EfficientNet-B0*

Berdasarkan Gambar 4.4, proses pelatihan dimulai dengan memuat arsitektur *EfficientNet-B0* beserta bobot awal (*pre-trained weights*) yang berasal dari *ImageNet*. Tahap pertama yang dilakukan adalah *warm-up*, yaitu dengan membekukan (*freeze*) seluruh lapisan pada *base model* sehingga hanya lapisan klasifikasi tambahan yang diperbarui selama proses pelatihan. Pada tahap ini, model dilatih selama 5 epoch menggunakan *learning rate* sebesar 0,001. Pendekatan tersebut bertujuan agar lapisan klasifikasi mampu mempelajari pola pada dataset penelitian tanpa mengubah kemampuan ekstraksi fitur yang telah dimiliki oleh model dasar.

Setelah tahap *warm-up* selesai, proses pelatihan dilanjutkan dengan *fine-tuning*. Pada tahap ini, sekitar 30 lapisan terakhir dari *EfficientNet-B0* dibuka kembali (*unfreeze*) sehingga bobotnya dapat disesuaikan dengan karakteristik citra rumah yang digunakan dalam penelitian. Nilai *learning rate* kemudian diturunkan menjadi 0,00005 untuk menghasilkan proses pembaruan bobot yang lebih stabil dan terkontrol. Selain itu, diterapkan mekanisme *Early Stopping* yang memantau nilai

validation loss selama pelatihan. Apabila tidak ditemukan peningkatan performa dalam beberapa *epoch* berturut-turut, proses pelatihan akan dihentikan secara otomatis dan model akan mengembalikan bobot terbaik melalui parameter *restore_best_weights=True*. Setelah seluruh proses selesai, model dengan performa terbaik disimpan dalam berkas *best_model_finetune.keras* untuk digunakan pada tahap evaluasi maupun pengujian data baru.

```

PHASE 1: WARM-UP (5 Epochs)...
Downloading data from https://storage.googleapis.com/keras-applications/efficientnetb0_notop.h5
16705208/16705208 ----- 0s 0us/step
Epoch 1/5
27/27 ----- 84s 2s/step - accuracy: 0.7548 - loss: 0.5256 - val_accuracy: 0.8146 - val_loss: 0.4827
Epoch 2/5
27/27 ----- 10s 387ms/step - accuracy: 0.9043 - loss: 0.2447 - val_accuracy: 0.9494 - val_loss: 0.3751
Epoch 3/5
27/27 ----- 11s 390ms/step - accuracy: 0.9342 - loss: 0.1810 - val_accuracy: 0.9438 - val_loss: 0.3166
Epoch 4/5
27/27 ----- 11s 415ms/step - accuracy: 0.9438 - loss: 0.1648 - val_accuracy: 0.9494 - val_loss: 0.2707
Epoch 5/5
27/27 ----- 11s 414ms/step - accuracy: 0.9462 - loss: 0.1270 - val_accuracy: 0.9494 - val_loss: 0.2382

PHASE 2: FINE-TUNING (15 Epochs)...
Epoch 1/15
27/27 ----- 69s 1s/step - accuracy: 0.9019 - loss: 0.2378 - val_accuracy: 0.9551 - val_loss: 0.1932
Epoch 2/15
27/27 ----- 11s 425ms/step - accuracy: 0.9498 - loss: 0.1573 - val_accuracy: 0.9607 - val_loss: 0.1616
Epoch 3/15
27/27 ----- 11s 418ms/step - accuracy: 0.9533 - loss: 0.1233 - val_accuracy: 0.9663 - val_loss: 0.1381
Epoch 4/15
27/27 ----- 11s 392ms/step - accuracy: 0.9581 - loss: 0.1169 - val_accuracy: 0.9607 - val_loss: 0.1218
Epoch 5/15
27/27 ----- 11s 409ms/step - accuracy: 0.9641 - loss: 0.0872 - val_accuracy: 0.9607 - val_loss: 0.1074
Epoch 6/15
27/27 ----- 12s 437ms/step - accuracy: 0.9749 - loss: 0.0772 - val_accuracy: 0.9607 - val_loss: 0.1069
Epoch 7/15
27/27 ----- 11s 423ms/step - accuracy: 0.9617 - loss: 0.0987 - val_accuracy: 0.9551 - val_loss: 0.1025
Epoch 8/15
27/27 ----- 11s 421ms/step - accuracy: 0.9725 - loss: 0.0794 - val_accuracy: 0.9607 - val_loss: 0.0980
Epoch 9/15
27/27 ----- 11s 425ms/step - accuracy: 0.9833 - loss: 0.0555 - val_accuracy: 0.9719 - val_loss: 0.0917
Epoch 10/15
27/27 ----- 11s 422ms/step - accuracy: 0.9725 - loss: 0.0873 - val_accuracy: 0.9607 - val_loss: 0.0880
Epoch 11/15
27/27 ----- 11s 421ms/step - accuracy: 0.9904 - loss: 0.0313 - val_accuracy: 0.9607 - val_loss: 0.0862
Epoch 12/15
27/27 ----- 11s 422ms/step - accuracy: 0.9737 - loss: 0.0573 - val_accuracy: 0.9607 - val_loss: 0.0821
Epoch 13/15
27/27 ----- 11s 398ms/step - accuracy: 0.9892 - loss: 0.0348 - val_accuracy: 0.9663 - val_loss: 0.0774
Epoch 14/15
27/27 ----- 11s 381ms/step - accuracy: 0.9880 - loss: 0.0391 - val_accuracy: 0.9719 - val_loss: 0.0735
Epoch 15/15
27/27 ----- 11s 410ms/step - accuracy: 0.9833 - loss: 0.0410 - val_accuracy: 0.9719 - val_loss: 0.0710

```

Gambar 4. 5 Output Proses *Warm-up* dan *Fine-tuning* pada Google Colaboratory

Gambar 4.5 menampilkan hasil keluaran (*output*) selama proses pelatihan yang dijalankan pada lingkungan Google Colaboratory. Pada setiap *epoch*, sistem menyajikan informasi berupa *training accuracy*, *training loss*, *validation accuracy*, dan *validation loss* sebagai indikator perkembangan proses pembelajaran model. Nilai-nilai tersebut digunakan untuk memantau peningkatan kinerja model sekaligus memastikan bahwa proses optimasi berlangsung sesuai dengan strategi pelatihan yang telah dirancang. Model dengan performa terbaik yang diperoleh dari tahapan ini selanjutnya digunakan sebagai dasar pada proses evaluasi kinerja model.


4.3 Evaluasi Kinerja Model *EfficientNet-B0*

Tahap evaluasi dilakukan untuk mengukur kemampuan model *EfficientNet-B0* dalam mengklasifikasikan citra rumah ke dalam kategori rumah layak huni dan rumah tidak layak huni. Evaluasi dilakukan menggunakan data pengujian (*testing dataset*) yang tidak pernah digunakan selama proses pelatihan maupun validasi sehingga hasil yang diperoleh dapat menggambarkan kemampuan model dalam melakukan prediksi terhadap data baru secara objektif.

Parameter evaluasi yang digunakan pada penelitian ini meliputi nilai *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix*. Selain itu, proses pelatihan model juga dianalisis melalui grafik perkembangan nilai *accuracy* dan *loss* pada data pelatihan maupun data validasi selama proses *training*.

4.3.1 Hasil Pelatihan Model

Proses pelatihan model *EfficientNet-B0* memperlihatkan perkembangan performa yang semakin baik pada setiap epoch. Hal tersebut ditunjukkan oleh peningkatan nilai *training accuracy* dan *validation accuracy* secara bertahap selama proses pembelajaran. Peningkatan tersebut mengindikasikan bahwa model mampu mempelajari pola dan karakteristik citra rumah secara efektif sehingga kinerja klasifikasi terus mengalami perbaikan.



Gambar 4. 6 Grafik Accuracy dan Validation Accuracy

Berdasarkan Gambar 4.6, kurva *training accuracy* menunjukkan tren peningkatan yang cukup signifikan sejak awal pelatihan hingga mencapai nilai mendekati 98% pada akhir tahap *fine-tuning*. Di sisi lain, *validation accuracy* juga mengalami peningkatan yang relatif stabil dan mencapai sekitar 97%, meskipun terdapat fluktuasi kecil pada beberapa epoch yang masih berada dalam batas yang wajar.

Selain menunjukkan peningkatan akurasi, kedua kurva memiliki pola yang relatif berdekatan sepanjang proses pelatihan. Perbedaan nilai yang tidak terlalu besar antara *training accuracy* dan *validation accuracy* mengindikasikan bahwa model mampu mempertahankan performa yang baik ketika dihadapkan pada data validasi. Kondisi tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang baik serta tidak memperlihatkan indikasi *overfitting* yang berarti selama proses pelatihan berlangsung.

4.3.2 Hasil Evaluasi Model


Setelah proses pelatihan selesai, model dievaluasi menggunakan data pengujian untuk mengetahui performa klasifikasi pada masing-masing kelas. Berdasarkan hasil pengujian, model memperoleh tingkat akurasi sebesar 98,35%, yang menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan sesuai dengan label sebenarnya.

Tabel 4. 4 *Classification Report*

No	Kelas	Recall	Precesion	F1-Score
1.	Rumah Layak	0.97	1.00	0.98
2.	Rumah Tidak Layak	1.00	0.97	0.98
<i>Macro Average</i>		0.98	0.98	0.98
<i>Weighted Average</i>		0.98	0.98	0.98
<i>Accuracy</i>				98 %

Berdasarkan Tabel 4.4, nilai *precision*, *recall*, dan *F1-score* pada kedua kelas berada pada kategori sangat tinggi. Nilai *precision* yang tinggi menunjukkan bahwa sebagian besar hasil prediksi model konsisten dengan label acuan (ground truth) pada data pengujian. Hal ini mengindikasikan bahwa prediksi yang dihasilkan memiliki tingkat kesesuaian yang tinggi terhadap kondisi yang telah ditetapkan pada dataset. Sementara itu, nilai *recall* yang tinggi menunjukkan bahwa model mampu mengenali hampir seluruh citra pada masing-masing kelas tanpa banyak melewatkan objek yang seharusnya terdeteksi. Nilai *F1-score* yang juga tinggi mengindikasikan bahwa keseimbangan antara *precision* dan *recall* telah tercapai dengan baik sehingga performa klasifikasi model dapat dikatakan sangat optimal.

Selain menggunakan *classification report*, evaluasi juga dilakukan melalui *confusion matrix* untuk mengetahui jumlah prediksi benar maupun prediksi yang mengalami kesalahan klasifikasi.



Gambar 4. 7 *Confusion Matrix* Model *EfficientNet-B0*

Berdasarkan Gambar 4.7, sebagian besar data pengujian berhasil diklasifikasikan dengan benar pada masing-masing kelas. Jumlah *false positive* maupun *false negative* relatif kecil dibandingkan jumlah prediksi yang benar, sehingga menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan rumah layak huni dan rumah tidak layak huni. Hasil ini juga memperkuat nilai akurasi yang diperoleh pada proses evaluasi.

Tingginya nilai akurasi yang diperoleh tidak hanya dipengaruhi oleh kemampuan model dalam mempelajari karakteristik data, tetapi juga oleh strategi pembagian dataset yang diterapkan sebelum proses pelatihan. Setiap citra rumah hanya digunakan pada satu subset data, yaitu *training*, *validation*, atau *testing*, sehingga tidak terdapat duplikasi citra maupun titik koordinat antar subset. Dengan demikian, proses evaluasi dilakukan menggunakan data yang berbeda dari data pelatihan sehingga hasil yang diperoleh dapat merepresentasikan kemampuan model dalam mengklasifikasikan data baru secara lebih objektif serta meminimalkan risiko *data leakage*.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa *model EfficientNet-B0* memiliki performa klasifikasi yang sangat baik dalam mengenali karakteristik visual rumah berdasarkan citra yang digunakan. Tingginya nilai *accuracy*, *precision*, *recall*, dan *F1-score* serta rendahnya tingkat kesalahan klasifikasi menunjukkan bahwa model telah mampu melakukan proses klasifikasi secara akurat dan konsisten.

Setelah seluruh proses evaluasi selesai, model dengan performa terbaik disimpan dalam berkas *best_model_finetune.keras* menggunakan framework TensorFlow pada lingkungan Google Colaboratory. Penyimpanan dilakukan agar model tidak perlu dilatih kembali ketika digunakan pada tahap pengujian citra baru maupun proses prediksi terhadap seluruh dataset. Berkas model tersebut selanjutnya dimanfaatkan sebagai model utama pada tahap implementasi Sistem Informasi Geografis (SIG) untuk menghasilkan data klasifikasi yang akan dipetakan secara spasial.

4.4 Pengujian Model Menggunakan Data Baru

Setelah model *EfficientNet-B0* menyelesaikan tahap pelatihan dan evaluasi menggunakan *testing dataset*, tahap berikutnya adalah melakukan pengujian menggunakan citra rumah yang berasal dari titik koordinat baru dan tidak digunakan pada proses pelatihan maupun evaluasi model. Data tersebut diperoleh dari pihak instansi terkait, kemudian diambil citra tampak atasnya melalui *Google Earth* berdasarkan koordinat GPS yang tersedia. Pengujian ini bertujuan untuk

mengetahui kemampuan model dalam mengklasifikasikan data baru pada kondisi yang lebih mendekati implementasi sebenarnya.

Proses pengujian dilakukan dengan memuat kembali model terbaik yang telah disimpan dalam berkas *best_model_finetune.keras* menggunakan framework *TensorFlow* pada lingkungan *Google Colaboratory*. Pengguna kemudian mengunggah citra rumah melalui fitur *upload file*, selanjutnya sistem secara otomatis melakukan tahap *pre-processing* dengan mengubah ukuran citra menjadi 224×224 piksel agar sesuai dengan spesifikasi masukan model *EfficientNet-B0*.

```
model = load_model('best_model_finetune (1).keras')
print("✅ Model berhasil dimuat!\n")

def audit_house(img_path):
    # 1. Load dan tampilkan gambar
    img = image.load_img(img_path, target_size=(224, 224))
    plt.figure(figsize=(4,4))
    plt.imshow(img)
    plt.axis('off')
    plt.show()

    # 2. Preprocessing
    img_array = image.img_to_array(img)
    img_array = np.expand_dims(img_array, axis=0)

    # 3. Prediksi
    prediction = model.predict(img_array, verbose=0)[0][0]

    # Berdasarkan flow_from_directory, 'layak' = 0, 'tidak_layak' = 1
    if prediction > 0.5:
        print(f"🚫 STATUS: TIDAK LAYAK (Skor Prediksi: {prediction:.4f})\n")
    else:
        print(f"✅ STATUS: LAYAK (Skor Prediksi: {prediction:.4f})\n")
    print("-" * 40)
```



Gambar 4. 8 Kode Pengujian Model Menggunakan Data Baru


Berdasarkan Gambar 4.8, proses pengujian diawali dengan memuat model menggunakan fungsi *load_model()*, kemudian pengguna mengunggah citra melalui *files.upload()*. Citra selanjutnya dibaca menggunakan *load_img()*, dikonversi menjadi array melalui *img_to_array()*, kemudian diproses oleh fungsi *model.predict()* untuk menghasilkan nilai prediksi (*prediction score*). Nilai tersebut digunakan sebagai dasar penentuan kelas dengan *threshold* sebesar 0,5, yaitu nilai di bawah 0,5 dikategorikan sebagai rumah layak huni, sedangkan nilai di atas 0,5 dikategorikan sebagai rumah tidak layak huni. Nilai ambang (*threshold*) sebesar 0,5 dipilih karena merupakan nilai standar pada model klasifikasi biner yang menggunakan fungsi aktivasi *Sigmoid*. Nilai tersebut memberikan batas keputusan

yang seimbang antara kelas positif dan kelas negatif sehingga sesuai digunakan pada penelitian ini.

Selain menghasilkan label klasifikasi, sistem juga menampilkan *AI Prediction Score* yang menunjukkan tingkat keyakinan model terhadap hasil prediksi. Nilai yang semakin mendekati 0 mengindikasikan keyakinan yang tinggi bahwa citra termasuk kategori rumah layak huni, sedangkan nilai yang mendekati 1 menunjukkan keyakinan yang tinggi bahwa citra merupakan rumah tidak layak huni.

Tabel 4. 5 Hasil Pengujian Model Menggunakan Data Baru


NO	ID_CITRA	LABEL	HASIL PREDIKSI
1	IMG01	Layak	 MENGUJI FILE: "IMG01.png" STATUS: LAYAK (Skor Prediksi: 0.0347)
2	IMG02	Layak	 MENGUJI FILE: "IMG02.png" STATUS: LAYAK (Skor Prediksi: 0.0000)

3	IMG03	Tidak Layak	 MENGUJI FILE: "IMG03.png" STATUS: TIDAK LAYAK (Skor Prediksi: 0.9999)
4	IMG04	Tidak Layak	 MENGUJI FILE: "IMG04.png" STATUS: TIDAK LAYAK (Skor Prediksi: 1.0000)
5	IMG05	Tidak Layak	 MENGUJI FILE: "IMG05.png" STATUS: TIDAK LAYAK (Skor Prediksi: 0.9997)

Berdasarkan Tabel 4.5, seluruh citra rumah yang berasal dari titik koordinat baru berhasil diklasifikasikan sesuai dengan label yang telah ditentukan. Hasil tersebut menunjukkan bahwa model *EfficientNet-B0* mampu memberikan prediksi yang konsisten terhadap data yang berada di luar dataset pelatihan dan pengujian. Untuk memperkuat hasil tersebut, dilakukan validasi dengan membandingkan citra

tampak atas yang digunakan sebagai masukan model dengan dokumentasi kondisi rumah pada saat survei lapangan.

Tabel 4. 6 Validasi Hasil Prediksi Model terhadap Kondisi Lapangan

Citra Tampak Atas (Google Earth)	Kondisi Lapangan
MENGUJI FILE: "IMG01.png"  ✓ STATUS: LAYAK (Skor Prediksi: 0.0347) IMG01 Titik Koordinat: 5.543027, 95.315530	 Kota Banda Aceh,Aceh,Indonesia Jalan Mulia I, Baiturrahman, Kota Banda Aceh, Aceh 23243, Indonesia Lat 5.543027, Long 95.315530 Rabu, 15/07/2026 12:55 PM GMT+07:00 Note : Captured by GPS Map Camera
MENGUJI FILE: "IMG02.png"  ✓ STATUS: LAYAK (Skor Prediksi: 0.0000) IMG02 Titik Koordinat: 5.539752, 95.313809	 Kota Banda Aceh,Aceh,Indonesia Jalan Sultan Alaidin Johan Syah, Baiturrahman, Kota Banda Aceh, Aceh 23243, Indonesia Lat 5.539752, Long 95.313809 Rabu, 15/07/2026 12:53 PM GMT+07:00 Note : Captured by GPS Map Camera

MENGUJI FILE: "IMG03.png"



STATUS: TIDAK LAYAK (Skor Prediksi: 0.9999)

IMG03

Titik Koordinat: 5.539350, 95.312677



MENGUJI FILE: "IMG04.png"



STATUS: TIDAK LAYAK (Skor Prediksi: 1.0000)

IMG04

Titik Koordinat: 5.524660, 95.308215



MENGUJI FILE: "IMG05.png"



STATUS: TIDAK LAYAK (Skor Prediksi: 0.9997)

IMG05

Titik Koordinat: 5.534992, 95.311498



Berdasarkan Tabel 4.6, setiap citra tampak atas yang digunakan sebagai masukan model memiliki kesesuaian dengan dokumentasi kondisi rumah pada saat survei lapangan berdasarkan titik koordinat yang sama. Perbandingan tersebut menunjukkan bahwa objek yang diprediksi oleh model merupakan rumah yang telah diverifikasi di lapangan. Pada seluruh sampel yang ditampilkan, hasil klasifikasi model sesuai dengan kondisi aktual sehingga memperkuat bahwa model mampu mengenali karakteristik visual rumah secara konsisten. Validasi ini juga menunjukkan bahwa proses klasifikasi tidak hanya didasarkan pada pola visual yang dipelajari selama pelatihan, tetapi juga mampu merepresentasikan kondisi rumah pada lokasi sebenarnya.

Secara keseluruhan, hasil pengujian terhadap citra rumah yang berasal dari titik koordinat baru serta validasi terhadap kondisi lapangan menunjukkan bahwa model *EfficientNet-B0* mampu menghasilkan prediksi yang konsisten. Temuan ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan layak diterapkan untuk mendukung proses identifikasi serta pemetaan sebaran rumah layak huni berbasis Sistem Informasi Geografis (SIG).

4.5 Analisis Perbandingan Kinerja Model

4.5.1 Perbandingan *EfficientNet-B0* dan Custom CNN

Sebagai upaya untuk mengevaluasi keunggulan model yang diusulkan, penelitian ini membandingkan performa *EfficientNet-B0* dengan Custom *Convolutional Neural Network* (CNN). Model Custom CNN dipilih sebagai model pembandingan (*baseline*) karena dibangun menggunakan arsitektur CNN sederhana tanpa memanfaatkan pendekatan *transfer learning*. Perbandingan ini dilakukan untuk memperoleh gambaran mengenai peningkatan performa yang dihasilkan oleh *EfficientNet-B0* dibandingkan model CNN konvensional dalam melakukan klasifikasi citra rumah.

Arsitektur Custom CNN terdiri atas tiga lapisan konvolusi (*Convolutional Layer*) yang masing-masing diikuti oleh lapisan *Max Pooling* untuk mengurangi dimensi fitur hasil ekstraksi. Selanjutnya, fitur yang diperoleh diubah menjadi bentuk vektor melalui lapisan *Flatten*, kemudian diproses oleh lapisan *Dense* dan

Dropout sebelum menghasilkan keluaran klasifikasi menggunakan fungsi aktivasi *Sigmoid*. Agar hasil perbandingan bersifat objektif, proses pelatihan Custom CNN menggunakan dataset, pembagian data, dan skenario pengujian yang sama dengan model *EfficientNet-B0*.




Gambar 4. 9 Output Proses Pelatihan dan Evaluasi Custom CNN

Berdasarkan Gambar 4.9, proses pelatihan Custom CNN berhasil diselesaikan hingga seluruh *epoch* berakhir. Hasil evaluasi menunjukkan bahwa model memperoleh tingkat akurasi sebesar 94,38% pada data pengujian. Nilai tersebut kemudian digunakan sebagai dasar untuk membandingkan performanya dengan *EfficientNet-B0*.

Tabel 4. 7 Perbandingan Akurasi Model

Model	Akurasi
Custom CNN	94,38%
<i>EfficientNet-B0</i>	98,35%

Berdasarkan Tabel 4.7, *EfficientNet-B0* memperoleh akurasi sebesar 98,35%, sedangkan Custom CNN mencapai 94,38%. Perbedaan sebesar 3,97% menunjukkan bahwa *EfficientNet-B0* memiliki kemampuan klasifikasi yang lebih baik pada dataset yang digunakan dalam penelitian ini.



Gambar 4. 10 Grafik Perbandingan Akurasi Validasi *EfficientNet-B0* dan Custom CNN

Berdasarkan Gambar 4.10, kurva *validation accuracy EfficientNet-B0* secara konsisten berada di atas kurva Custom CNN selama proses pelatihan. Selain menghasilkan akurasi yang lebih tinggi, *EfficientNet-B0* juga memperlihatkan pola pembelajaran yang lebih stabil, sedangkan Custom CNN masih mengalami fluktuasi pada beberapa *epoch*.

Perbedaan performa tersebut dipengaruhi oleh penggunaan *transfer learning* pada *EfficientNet-B0*. Melalui bobot awal (*pre-trained weights*) dari ImageNet, model telah memiliki kemampuan dasar dalam mengenali karakteristik visual, seperti bentuk, tekstur, dan pola objek, sehingga proses adaptasi terhadap dataset penelitian menjadi lebih efektif. Sebaliknya, Custom CNN mempelajari seluruh parameter dari awal (*training from scratch*), sehingga membutuhkan data yang lebih banyak untuk mencapai tingkat performa yang setara.

Selain itu, *EfficientNet-B0* menerapkan konsep *compound scaling*, yaitu metode penskalaan yang menyeimbangkan kedalaman jaringan (*depth*), lebar jaringan (*width*), dan resolusi citra (*resolution*). Pendekatan tersebut memungkinkan proses ekstraksi fitur berlangsung lebih efisien sehingga menghasilkan representasi fitur yang lebih baik dibandingkan Custom CNN.

Berdasarkan hasil analisis tersebut, *EfficientNet-B0* menunjukkan performa yang lebih unggul dibandingkan Custom CNN, baik dari aspek akurasi maupun kestabilan proses pembelajaran. Oleh karena itu, *EfficientNet-B0* dipilih sebagai model utama dalam penelitian ini karena dinilai lebih mampu mendukung proses

identifikasi dan pemetaan sebaran rumah layak huni berbasis Sistem Informasi Geografis (SIG) secara lebih akurat dan andal.

4.6 Implementasi Sistem Informasi Geografis (SIG)

Setelah model *EfficientNet-B0* berhasil melakukan proses klasifikasi terhadap citra rumah, tahapan berikutnya adalah mengintegrasikan hasil klasifikasi tersebut ke dalam Sistem Informasi Geografis (SIG). Integrasi ini bertujuan untuk menyajikan hasil prediksi tidak hanya dalam bentuk data tabular, tetapi juga dalam bentuk visualisasi spasial berupa peta. Dengan demikian, persebaran rumah layak huni dan rumah tidak layak huni dapat diamati berdasarkan lokasi geografisnya. Pada penelitian ini, proses visualisasi spasial dilakukan menggunakan perangkat lunak QGIS dengan memanfaatkan data koordinat setiap objek penelitian.

4.6.1 Ekspor Hasil Prediksi

Tahap awal dalam implementasi SIG diawali dengan penggunaan kembali model terbaik yang telah diperoleh selama proses pelatihan, yaitu *best_model_finetune.keras*. Model tersebut digunakan untuk melakukan prediksi terhadap seluruh dataset yang terdiri dari 1.196 citra rumah di wilayah Kota Banda Aceh sehingga setiap citra memperoleh hasil klasifikasi beserta nilai *AI Prediction Score* sebagai tingkat keyakinan model terhadap hasil prediksi. Seluruh hasil prediksi kemudian diekspor untuk diintegrasikan ke dalam perangkat lunak QGIS sebagai dasar penyusunan peta sebaran rumah.

Selanjutnya, hasil klasifikasi dikombinasikan dengan data atribut setiap rumah, seperti identitas objek penelitian serta informasi koordinat geografis berupa lintang (*latitude*) dan bujur (*longitude*). Koordinat tersebut diperoleh dari hasil survei lapangan pada kantor Dinas PERKIM Kota Banda Aceh dan digunakan sebagai acuan untuk memperoleh citra tampak atas rumah melalui Google Earth. Seluruh informasi tersebut kemudian disimpan ke dalam berkas berformat *Comma Separated Values* (CSV) sehingga dapat diolah lebih lanjut menggunakan perangkat lunak SIG.

Data yang diekspor ke dalam file CSV memuat beberapa atribut penting, antara lain identitas rumah, koordinat geografis, hasil klasifikasi, serta nilai *AI Prediction Score*. Format CSV dipilih karena memiliki struktur data yang sederhana, mudah diproses, dan didukung oleh berbagai perangkat lunak pemetaan, termasuk QGIS.

No	TITIK	KECAMATAN	GAMPONG	X	Y	LABEL	AI PREDICTION
1	BA_UK_L_0001	ULEE KARENG	PANGO RAYA	95.344326	5.540117	LAYAK	0,003
2	BA_UK_L_0002	ULEE KARENG	PANGO RAYA	95.343925	5.539553	LAYAK	0,0001
3	BA_UK_L_0003	ULEE KARENG	PANGO RAYA	95.346098	5.537522	LAYAK	0
4	BA_UK_L_0004	ULEE KARENG	PANGO RAYA	95.345693	5.538343	LAYAK	0,0015
5	BA_UK_L_0005	ULEE KARENG	PANGO RAYA	95.345590	5.540465	LAYAK	0
6	BA_UK_L_0006	ULEE KARENG	PANGO RAYA	95.345824	5.539111	LAYAK	0,0026
7	BA_UK_L_0007	ULEE KARENG	PANGO RAYA	95.343799	5.540243	LAYAK	0,0515
8	BA_UK_L_0008	ULEE KARENG	PANGO RAYA	95.346290	5.537445	LAYAK	0,0287
9	BA_UK_L_0009	ULEE KARENG	PANGO RAYA	95.343414	5.541530	LAYAK	0
10	BA_UK_L_0010	ULEE KARENG	PANGO RAYA	95.344372	5.542030	LAYAK	0,0011
11	BA_UK_TL_0091	ULEE KARENG	PANGO RAYA	95.346469	5.538408	TIDAK LAYAK	0,9979
12	BA_UK_TL_0092	ULEE KARENG	PANGO RAYA	95.346641	5.538466	TIDAK LAYAK	0,9682
13	BA_UK_TL_0093	ULEE KARENG	PANGO RAYA	95.345363	5.539199	TIDAK LAYAK	0,9956
14	BA_UK_TL_0094	ULEE KARENG	PANGO RAYA	95.346945	5.538550	TIDAK LAYAK	1
15	BA_UK_TL_0095	ULEE KARENG	PANGO RAYA	95.345561	5.538398	TIDAK LAYAK	0,9588
16	BA_UK_TL_0096	ULEE KARENG	PANGO RAYA	95.347130	5.536573	TIDAK LAYAK	0,9976
17	BA_UK_TL_0097	ULEE KARENG	PANGO RAYA	95.347313	5.536578	TIDAK LAYAK	0,9621
18	BA_UK_TL_0098	ULEE KARENG	PANGO RAYA	95.345129	5.539709	TIDAK LAYAK	0,9995
19	BA_UK_TL_0099	ULEE KARENG	PANGO RAYA	95.344545	5.540700	TIDAK LAYAK	1
20	BA_UK_TL_0100	ULEE KARENG	PANGO RAYA	95.344779	5.540567	TIDAK LAYAK	0,9919

Gambar 4. 11 Data Hasil Prediksi yang Diekspor ke Format CSV


Berdasarkan Gambar 4.11, setiap data rumah telah memiliki atribut spasial berupa koordinat lokasi dan atribut nonspasial berupa hasil klasifikasi beserta tingkat keyakinan model. Kombinasi kedua jenis atribut tersebut memungkinkan data divisualisasikan secara langsung pada perangkat lunak SIG tanpa memerlukan proses konversi tambahan.

4.6.2 Pemetaan Sebaran Rumah Layak Huni

Tahapan berikutnya dalam penelitian ini adalah menyajikan hasil klasifikasi ke dalam Sistem Informasi Geografis (SIG) menggunakan perangkat lunak QGIS. Data hasil prediksi yang telah disimpan dalam format CSV diimpor sebagai *Delimited Text Layer*, kemudian atribut *latitude* dan *longitude* dimanfaatkan sebagai referensi koordinat untuk membentuk titik lokasi setiap rumah pada wilayah penelitian.

Setelah seluruh data berhasil ditampilkan, dilakukan proses simbolisasi berdasarkan hasil klasifikasi model. Rumah yang dikategorikan sebagai layak huni


divisualisasikan menggunakan simbol berwarna hijau, sedangkan rumah yang diklasifikasikan sebagai tidak layak huni ditampilkan dengan simbol berwarna merah. Perbedaan warna tersebut memudahkan proses identifikasi kondisi rumah sekaligus memberikan gambaran yang lebih jelas mengenai pola persebaran pada wilayah penelitian.




Gambar 4. 12 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kota Banda Aceh

Berdasarkan Gambar 4.12, hasil klasifikasi yang dihasilkan oleh model *EfficientNet-B0* berhasil diintegrasikan ke dalam QGIS dan divisualisasikan sesuai dengan posisi geografis masing-masing rumah. Peta tersebut menunjukkan bahwa proses konversi data hasil prediksi ke dalam bentuk spasial berjalan dengan baik sehingga menghasilkan informasi persebaran rumah yang dapat dimanfaatkan sebagai dasar analisis wilayah. Melalui visualisasi tersebut, distribusi rumah layak huni maupun rumah tidak layak huni di Kota Banda Aceh dapat diamati secara menyeluruh sehingga mempermudah identifikasi lokasi yang berpotensi menjadi prioritas dalam pelaksanaan program bantuan perumahan.


Untuk memberikan gambaran penerapan SIG pada wilayah dengan karakteristik yang berbeda, penelitian ini menampilkan tiga kecamatan, yaitu Baiturrahman, Ulee Kareng, dan Syiah Kuala.



Gambar 4. 13 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kecamatan Baiturrahman



Gambar 4. 14 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kecamatan Ulee Kareng



Gambar 4. 15 Peta Sebaran Rumah Layak Huni dan Rumah Tidak Layak Huni di Kecamatan Syiah Kuala

Berdasarkan Gambar 4.13 hingga Gambar 4.15, hasil klasifikasi berhasil divisualisasikan pada wilayah yang memiliki karakteristik permukiman yang berbeda. Peta yang dihasilkan menunjukkan bahwa model mampu mengidentifikasi lokasi rumah sesuai dengan koordinat geografisnya sehingga pola persebaran rumah layak huni maupun rumah tidak layak huni dapat diamati secara lebih jelas pada masing-masing kecamatan. Hasil ini menunjukkan bahwa integrasi antara model klasifikasi dan Sistem Informasi Geografis dapat diterapkan pada berbagai karakteristik wilayah dengan hasil visualisasi yang informatif dan mudah dipahami.

Secara keseluruhan, penerapan Sistem Informasi Geografis pada penelitian ini berhasil mengintegrasikan hasil klasifikasi yang dihasilkan oleh model *EfficientNet-B0* dengan data spasial sehingga menghasilkan peta persebaran rumah layak huni dan rumah tidak layak huni yang informatif. Integrasi teknologi *Deep Learning* dan SIG tidak hanya menyajikan hasil klasifikasi dalam bentuk numerik, tetapi juga memberikan visualisasi spasial yang memudahkan proses identifikasi wilayah serta mendukung pengambilan keputusan dalam penentuan prioritas penyaluran bantuan rumah layak huni di Kota Banda Aceh.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilaksanakan mengenai Pemetaan Sebaran Rumah Layak Huni Menggunakan Teknologi *Deep Learning EfficientNet-B0* dan Sistem Informasi Geografis (SIG) di Kota Banda Aceh, maka diperoleh beberapa kesimpulan sebagai berikut.

1. Penelitian ini berhasil menerapkan integrasi antara model *Deep Learning EfficientNet-B0* dan Sistem Informasi Geografis (SIG) untuk melakukan klasifikasi kondisi rumah berdasarkan citra tampak atas yang diperoleh dari *Google Earth* dengan mengacu pada titik koordinat hasil survei lapangan. Selanjutnya, hasil klasifikasi tersebut diintegrasikan ke dalam perangkat lunak QGIS sehingga menghasilkan peta persebaran rumah layak huni dan rumah tidak layak huni di wilayah Kota Banda Aceh.
2. Berdasarkan proses evaluasi menggunakan *classification report* dan *confusion matrix*, model *EfficientNet-B0* mampu mencapai tingkat akurasi sebesar 98,35%, disertai nilai *precision*, *recall*, dan *F1-score* yang tinggi pada masing-masing kelas. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali dan mengklasifikasikan kondisi rumah berdasarkan karakteristik visual citra.

5.2 Saran

Berdasarkan hasil penelitian yang telah dicapai, terdapat beberapa rekomendasi yang dapat dipertimbangkan untuk pengembangan penelitian pada masa mendatang, antara lain sebagai berikut.

1. Penelitian berikutnya disarankan menggunakan dataset dengan jumlah citra yang lebih banyak serta variasi kondisi rumah yang lebih beragam. Penambahan variasi data diharapkan mampu meningkatkan kemampuan model dalam mempelajari karakteristik objek sehingga performa generalisasi menjadi lebih baik.

2. Evaluasi model dapat dikembangkan dengan membandingkan *EfficientNet-B0* terhadap arsitektur deep learning lainnya, seperti *EfficientNet* varian yang lebih tinggi, *ResNet*, *DenseNet*, maupun *Vision Transformer* (ViT). Perbandingan tersebut diharapkan dapat memberikan gambaran mengenai model yang paling efektif untuk klasifikasi kondisi rumah.
3. Sistem dapat dikembangkan menjadi aplikasi berbasis web ataupun mobile yang terintegrasi dengan Google Maps maupun QGIS sehingga proses identifikasi kondisi rumah dan visualisasi lokasi dapat dilakukan secara real-time oleh instansi terkait.
4. Penelitian selanjutnya dapat memanfaatkan citra dengan resolusi spasial citra yang lebih tinggi sehingga perubahan kondisi rumah dapat teridentifikasi dengan lebih baik dan hasil klasifikasi menjadi lebih akurat.



DAFTAR PUSTAKA

- Agri Kristal, H. (2022). *Analisis Keandalan Ekstraksi Garis Tepi Bangunan dari Data Foto Udara Menggunakan Pendekatan Deep Learning Berbasis Mask R-CNN Pendahuluan Kebutuhan peta dasar skala besar khususnya skala 1 : 5 . 000 terus meningkat dari waktu ke waktu . Kebutuhan stereo*. 17(2), 273–285.
- Akbari, M. F. R., Rahayudi, B., & Muflikhah, L. (2023). Implementasi Deep Learning menggunakan Algoritma EfficientDet untuk Sistem Deteksi Kelayakan Penerima Bantuan Langsung Tunai berdasarkan Citra Rumah di Wilayah Kabupaten Kediri. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 7(4), 1817–1825.
- Akmal, K. (2023). The Role of Geographic Information Systems (GIS) in Location-Based Decision Making. *Journal Informatic, Education and Management (JIEM)*, 5(1), 26–30. <https://doi.org/10.61992/jiem.v5i1.73>
- Atikah, W. (2022). Pembangunan Rumah Layak Huni Dari Perspektif Hukum Perumahan Dan Permukiman. *Jurnal Kajian Konstitusi*, 2(1), 1. <https://doi.org/10.19184/jkk.v1i3.28446>
- Burhanuddin, M. I., Adam Syaifullah, Setiawan Adeka Putra Jaya, & Muhammad Gabriel Somoal. (2025). Analisis Komparatif Model MobilenetV1 Dan EfficientnetB0 Dalam Klasifikasi Citra Empat Musim Menggunakan Transfer Learning. *JEKIN - Jurnal Teknik Informatika*, 5(2), 508–521. <https://doi.org/10.58794/jekin.v5i2.1378>
- Chaniago, M. D., & Taki, H. M. (2022). Geographic Information System (GIS) as an Information Media in the Field of Environmental Health: Literature Review. *Journal of Applied Geospatial Information*, 6(2), 641–646. <https://doi.org/10.30871/jagi.v6i2.4319>
- Dianto, R. A., Anggraeny, T. F., & Maulana, H. (2025). *Analisis Efektifitas Algoritma Mobilenetv3-*. 13(3).
- Fahmi Idris, Mukhrijal, S. R. (2023). Efektifitas Program Rumah Layak Huni dalam Upaya Penanggulangan Kemiskinan di Kabupaten Aceh Barat Daya. *Sosio Konsepsia*, 12(2), 37–50. <https://doi.org/10.33007/ska.v12i2.3240>
- Hadi, A., Ryansyah, D., & Brotosaputro, G. (2025). *Penerapan Algoritma K-Nearest Neighbors (KNN) dalam Menentukan Jenis KB Menggunakan Google Colab*. 18(2), 120–128.
- Maulidiya, E., Fatichah, C., Suciati, N., & Baskoro, F. (2024). Klasifikasi Tutupan Lahan UAV Menggunakan Convolutional Neural Network Feature Map dengan Kombinasi Machine Learning. *Jurnal Ilmiah Teknologi Informasi*, 22(1), 45–55.
- Meileni, H., Jannah, M., & Novianti, L. (2022). Penerapan Deep Learning dalam Sistem Informasi Geografis. *El Sains Jurnal Elektro*, 4(1), 19–22.

<https://doi.org/10.30996/elsains.v4i1.6778>

- Munawwarah, F., Sa'diyah, H., Timamah, I., & Jannah, F. (2025). Komponen Penting Dalam Penelitian Kuantitatif: Panduan Untuk Peneliti Pemula. *INTERDISIPLIN: Journal of Qualitative and Quantitative Research*, 2(1), 53–62.
- Nurjannahtin A , Dr. Endang Indartuti, MSi, D. R. (2024). *Jurnal Ilmu Sosial dan Humaniora Submitted 16 Juni 2024 Jurnal Ilmu Sosial dan Humaniora Pada umumnya , semua manusia ingin kebutuhannya tercukupi . Kebutuhan yang diperlukan Melihat data kemiskinan diatas menurut BPS , kemudian Pemerintah Kota Surabaya m.* 2(35), 23–36.
- Rangga Gelar Guntara. (2023). Deteksi Atap Bangunan Berbasis Citra Udara Menggunakan Google Colab dan Algoritma Deep Learning YOLOv7. *Jurnal Manajemen Sistem Informasi (JMASIF)*, 2(1), 9–18. <https://doi.org/10.59431/jmasif.v2i1.156>
- Santi, E., Pravitasari, A. E., & Lubis, I. (2020). Mapping of Spatial Distribution and Spatial Autocorrelation Patterns of Poverty in All Regencies/Cities in Indonesia. *Journal of Applied Geospatial Information*, 4(1), 271–282. <https://doi.org/10.30871/jagi.v4i1.1565>
- Saragih, N. N., & Kurniawan, R. (2025). (Journal of Computer Engineering, System and Science). *Journal of Computer Engineering, System and Science*, 10(1), 299–311.
- Sitorus, Y. A., Sari, Y. A., & Adinugroho, S. (2025). Evaluasi Komparatif Arsitektur Lightweight CNN, MobileNetV2, dan EfficientNetB0 dalam Deteksi Penyakit Daun Jagung. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 9(8), 1–6. <http://j-ptiik.ub.ac.id>
- Supiyandi, S., & Mailok, R. binti. (2025). Advances in Spatial Analysis for Land Change Science: A Systematic Review of Geospatial Methodologies. *Jurnal Komputer Teknologi Informasi Sistem Informasi (JUKTISI)*, 4(2), 1085–1103. <https://doi.org/10.62712/juktisi.v4i2.604>
- Taufiqurrahman, Indah Clara Sari, M. K. M. (2024). Integrasi Model Deep Learning Efficientnet-B0 Untuk Deteksi Penyakit Daun Tomat Pada Aplikasi Seluler Berbasis Flutter. *Djtechno: Jurnal Teknologi Informasi*, 5(2), 332–346. <https://doi.org/10.46576/djtechno.v5i2.4651>
- Tilasefana, R. A., & Putra, R. E. (2023). Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG Net Untuk Pengenalan Cuaca. *Journal of Informatics and Computer Science (JINACS)*, 5(01), 48–57. <https://ejournal.unesa.ac.id/index.php/jinacs/article/view/54515>
- Wardhana, J. A., & Sibaroni, Y. (2021). Aspect Level Sentiment Analysis on Zoom Cloud Meetings App Review Using LDA. *Jurnal RESTI*, 5(4), 631–638. <https://doi.org/10.29207/resti.v5i4.3143>
- Wicaksono, R. S., Brata, A. H., & Ananta, M. T. (2023). Sistem Pemetaan dan Pelaporan Rumah Tidak Layak Huni berbasis Web (Studi Kasus: Dinas

Perkim Kabupaten Magetan). ... *Teknologi Informasi Dan Ilmu* ..., 7(2), 613–622. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/download/12261/5583>

Zaroujtaghi, A., Mansourihanis, O., Tayarani, M., Mansouri, F., Hemmati, M., & Soltani, A. (2025). A Systematic Review of GIS Evolution in Transportation Planning: Towards AI Integration. *Future Transportation*, 5(3), 1–16. <https://doi.org/10.3390/futuretransp5030097>



DAFTAR LAMPIRAN

Lampiran A. Program Pelatihan Model *EfficientNet-B0*

A.1 Audit Dataset

```
import os

layak_path = "/content/dataset/layak"
tidak_path = "/content/dataset/tidak_layak"

jumlah_layak = len(os.listdir(layak_path))
jumlah_tidak = len(os.listdir(tidak_path))

print("Layak :", jumlah_layak)
print("Tidak Layak :", jumlah_tidak)
print("Total :", jumlah_layak + jumlah_tidak)
```

```
Layak : 598
Tidak Layak : 598
Total : 1196
```

```
from PIL import Image
import os

def cek_rusak(folder):
    rusak = []

    for file in os.listdir(folder):
        try:
            img = Image.open(os.path.join(folder, file))
            img.verify()
        except:
            rusak.append(file)
    return rusak

rusak_layak = cek_rusak(layak_path)
rusak_tidak = cek_rusak(tidak_path)

print("Rusak Layak :", len(rusak_layak))
print("Rusak Tidak Layak :", len(rusak_tidak))
```

```
Rusak Layak : 0
Rusak Tidak Layak : 0
```

```

import matplotlib.pyplot as plt
from PIL import Image
import random

folder = layak_path

sample = random.sample(os.listdir(folder), 6)

plt.figure(figsize=(12,6))


for i,file in enumerate(sample):

    img = Image.open(os.path.join(folder,file))

    plt.subplot(2,3,i+1)
    plt.imshow(img)
    plt.title(file)
    plt.axis("off")

plt.show()

```



A.2 Pembagian Dataset Menjadi Data Training, Validation, dan Test

```

!pip install split-folders

import shutil
import splitfolders

# 1. Hapus folder split yang lama agar tidak ada file
duplikat/menumpuk
print("Membersihkan folder split lama...")
shutil.rmtree('/content/dataset_split', ignore_errors=True)

```

```

print("Folder bersih!")

# 2. Jalankan split ulang dari awal secara bersih
print("Memulai proses split dataset baru...")
splitfolders.ratio(
    '/content/dataset',
    output='/content/dataset_split',
    seed=1337,
    ratio=(0.7, 0.15, 0.15)
)
print("Split selesai dengan aman!")

```

A.3 Konfigurasi Data Augmentation dan Image Generator

```

from tensorflow.keras.preprocessing.image import
ImageDataGenerator

train_datagen = ImageDataGenerator(
    rotation_range=20,
    horizontal_flip=True,
    fill_mode='nearest'
)

test_datagen = ImageDataGenerator()

```

Validation Generator

```

val_generator = test_datagen.flow_from_directory(
    "/content/dataset_split/val",
    target_size=(224,224),
    batch_size=32,
    class_mode="binary"
)

```

Found 178 images belonging to 2 classes.

Test Generator

```

test_generator = test_datagen.flow_from_directory(
    "/content/dataset_split/test",
    target_size=(224,224),
    batch_size=32,
    class_mode="binary",
    shuffle=False
)

```

Found 182 images belonging to 2 classes.

Train Generator

```
train_generator = train_datagen.flow_from_directory(  
    "/content/dataset_split/train",  
    target_size=(224, 224),  
    batch_size=32,  
    class_mode="binary"  
)
```

Found 836 images belonging to 2 classes.

Verifikasi Label Kelas Dataset

```
print(train_generator.class_indices)
```

```
{'layak': 0, 'tidak_layak': 1}
```

A.4 Visualisasi Hasil Data Augmentasi

```
import matplotlib.pyplot as plt  
  
images, labels = next(train_generator)  
  
plt.figure(figsize=(12,8))  
  
for i in range(8):  
    plt.subplot(2,4,i+1)  
  
    plt.imshow(images[i].astype('uint8'))  
  
    plt.title(f"Label: {int(labels[i])}")  
  
    plt.axis("off")  
  
plt.show()
```



A.5 Pelatihan, *Fine-Tuning*, dan Evaluasi Model *EfficientNet-B0*

```
# =====
# THE REVISED NUCLEAR BYPASS CELL (NO RESCALE)
# =====

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from tensorflow.keras.applications import EfficientNetB0
from tensorflow.keras.layers import GlobalAveragePooling2D,
Dense, Dropout, BatchNormalization
from tensorflow.keras.models import Model
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping
from tensorflow.keras.preprocessing.image import
ImageDataGenerator
from sklearn.metrics import classification_report,
confusion_matrix, accuracy_score
from IPython.display import display

print("MENGATUR ULANG DATA GENERATORS (MENGHAPUS
RESCALE)...")
# FATAL FIX: Menghapus rescale=1./255 karena EfficientNetB0
sudah memilikinya secara bawaan.
train_datagen = ImageDataGenerator(rotation_range=20,
horizontal_flip=True, fill_mode='nearest')
```

```

val_test_datagen = ImageDataGenerator() # KOSONG, TANPA
RESCALE

train_generator =
train_datagen.flow_from_directory('/content/dataset_split/train', target_size=(224, 224), batch_size=32,
class_mode='binary')
val_generator =
val_test_datagen.flow_from_directory('/content/dataset_split/val', target_size=(224, 224), batch_size=32,
class_mode='binary')
test_generator =
val_test_datagen.flow_from_directory('/content/dataset_split/test', target_size=(224, 224), batch_size=32,
class_mode='binary', shuffle=False)

print("\nPHASE 1: WARM-UP (5 Epochs)...")
base_model = EfficientNetB0(weights='imagenet',
include_top=False, input_shape=(224, 224, 3))
base_model.trainable = False

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = BatchNormalization()(x) # Tambahan untuk menstabilkan
training
x = Dropout(0.4)(x)
predictions = Dense(1, activation='sigmoid')(x)

model = Model(inputs=base_model.input, outputs=predictions)
model.compile(optimizer=Adam(learning_rate=0.001),
loss='binary_crossentropy', metrics=['accuracy'])
model.fit(train_generator, validation_data=val_generator,
epochs=5)

print("\nPHASE 2: FINE-TUNING (15 Epochs)...")
base_model.trainable = True
for layer in base_model.layers[:-30]:
    layer.trainable = False

# Learning rate diperkecil
model.compile(optimizer=Adam(learning_rate=0.00005),
loss='binary_crossentropy', metrics=['accuracy'])
early_stop = EarlyStopping(monitor='val_loss', patience=4,
restore_best_weights=True)
model.fit(train_generator, validation_data=val_generator,
epochs=15, callbacks=[early_stop])

```

```

print("\nMETRIK EVALUASI\n")
y_true = test_generator.classes
pred_probs = model.predict(test_generator)
y_pred = (pred_probs > 0.5).astype(int).reshape(-1)

# --- HASIL ---
print(f"AKURASI MODEL: {accuracy_score(y_true, y_pred) *
100:.2f}%\n")

print("CLASSIFICATION REPORT:")
report_dict = classification_report(y_true, y_pred,
target_names=['Layak', 'Tidak Layak'], output_dict=True)
display(pd.DataFrame(report_dict).transpose().round(2))

cm = confusion_matrix(y_true, y_pred)
cm_perc = cm / np.sum(cm)
labels = [f"{v1}\n({v2:.1%})" for v1, v2 in zip(cm.flatten(),
cm_perc.flatten())]
labels = np.asarray(labels).reshape(2, 2)

plt.figure(figsize=(7, 5))
sns.heatmap(cm, annot=labels, fmt='', cmap='Blues',
cbar=False, annot_kws={'size': 12, 'weight': 'bold'},
linewidths=1, linecolor='gray')
plt.xticks([0.5, 1.5], ['Layak', 'Tidak Layak'], fontsize=11,
fontweight='bold')
plt.yticks([0.5, 1.5], ['Layak', 'Tidak Layak'], fontsize=11,
fontweight='bold', rotation=0)
plt.title('Confusion Matrix: EfficientNetB0', fontsize=14,
fontweight='bold')
plt.show()

```

Lampiran B. Program Perbandingan Custom CNN

B.1 Membangun Custom CNN

```

print("Membangun Custom CNN (Baseline Model)...")
cnn_model = models.Sequential([
    layers.Conv2D(32, (3, 3), activation='relu',
input_shape=(224, 224, 3)),
    layers.MaxPooling2D((2, 2)),

    layers.Conv2D(64, (3, 3), activation='relu'),
    layers.MaxPooling2D((2, 2)),

    layers.Conv2D(128, (3, 3), activation='relu'),
    layers.MaxPooling2D((2, 2)),

```

```

        layers.Flatten(),
        layers.Dense(128, activation='relu'),
        layers.Dropout(0.5),
        layers.Dense(1, activation='sigmoid')
    ])

cnn_model.compile(
    optimizer='adam',
    loss='binary_crossentropy',
    metrics=['accuracy']
)

print("Model siap! Memulai training 15 Epochs...\n")
cnn_history = cnn_model.fit(
    train_generator,
    epochs=15,
    validation_data=validation_generator,
    verbose=1
)

```

B.2 Grafik Perbandingan *EfficientNet-B0* dan Custom CNN

```

import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

# Mengatur gaya visual seaborn untuk tampilan modern
sns.set_theme(style="whitegrid", palette="muted")

print("Membaca data benchmark dan menggambar grafik
perbandingan yang lebih modern...")

# 1. Ambil data CNN yang baru saja di-training (Live Data)
cnn_val_acc = cnn_history.history['val_accuracy']
epochs_cnn = range(1, len(cnn_val_acc) + 1)

# 2. Buka dan baca file CSV EfficientNet (Historical Data)
try:
    df_eff =
pd.read_csv('/content/efficientnet_benchmark.csv')
    eff_val_acc = df_eff['EfficientNet_Val_Accuracy']
    epochs_eff = df_eff['Epoch']
except FileNotFoundError:
    print("ERROR: File 'efficientnet_benchmark.csv' belum di-
upload!")

```

```

    eff_val_acc = None

# 3. Setup Grafik
plt.figure(figsize=(10, 6))

# 4. Gambar garis (Custom CNN - Live)
plt.plot(epochs_cnn, cnn_val_acc, marker='o', linewidth=2.5,
color='#E63946', label='Custom CNN (Live)')

# 5. Gambar garis (EfficientNet - CSV Data)
if eff_val_acc is not None:
    plt.plot(epochs_eff, eff_val_acc, marker='s',
linestyle='--', linewidth=2, color='#457B9D',
label='EfficientNetB0 (Benchmark)')

# 6. Percantik Grafik
plt.title('Perbandingan Akurasi Validasi', fontsize=16,
fontweight='bold', pad=20)
plt.xlabel('Epochs', fontsize=12)
plt.ylabel('Validation Accuracy', fontsize=12)
plt.ylim(0.4, 1.02)

# Menghilangkan border atas dan kanan agar lebih clean
sns.despine()

plt.legend(frameon=True, facecolor='white',
edgecolor='lightgray', fontsize=10)
plt.tight_layout()


# 7. Tampilkan
plt.show()

```




Lampiran C. Peta Sebaran Rumah Layak Huni Tiap Kecamatan


C.1 Peta Sebaran Rumah Layak Huni Kecamatan Meuraxa




C.2 Peta Sebaran Rumah Layak Huni Kecamatan Kuta Alam




C.3 Peta Sebaran Rumah Layak Huni Kecamatan Banda Raya



C.4 Peta Sebaran Rumah Layak Huni Kecamatan Lueng Bata



C.5 Peta Sebaran Rumah Layak Huni Kecamatan Jaya Baru



C.6 Peta Sebaran Rumah Layak Huni Kecamatan Kuta Raja

