

**KLASIFIKASI CITRA MEDIS TUMOR OVARIUM MENGGUNAKAN
DEEP LEARNING DENGAN ARSITEKTUR EFFICIENTNET**

(Skripsi)

Oleh

TASYA AZZAHRA PUTRI

NPM 2117051043



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

KLASIFIKASI CITRA MEDIS TUMOR OVARIUM MENGGUNAKAN *DEEP LEARNING* DENGAN ARSITEKTUR EFFICIENTNET

Oleh

TASYA AZZAHRA PUTRI

Tumor ovarium merupakan masalah medis serius yang cukup sulit dideteksi dini karena terdapat beberapa kemiripan karakteristik antara tumor jinak dan ganas, sehingga klasifikasi yang akurat sangat penting untuk menentukan prognosis dan jenis pengobatan pasien. Penelitian ini mengembangkan model *deep learning* berbasis model arsitektur EfficientNet-B3 untuk mengklasifikasikan citra CT scan tumor ovarium menjadi *Benign* dan *Malignant*. Model dibangun dengan *transfer learning* menggunakan bobot ImageNet dan diproses melalui tahap *preprocessing*, segmentasi, serta augmentasi. Metode pembobotan kelas juga digunakan untuk mengatasi ketidakseimbangan kelas pada *dataset*. Evaluasi dilakukan pada dua skenario pembagian data (70%, 15%, 15% dan 80%, 10%, 10%) dengan metrik akurasi dan F1-score. Model mencapai akurasi 90% dan F1-score 0,90 pada skenario pertama, serta akurasi 86% dan F1-score 0,86 pada skenario kedua. Beberapa kesalahan klasifikasi masih ditemukan dan menjadi perhatian untuk pengembangan selanjutnya.

Kata Kunci : Pembelajaran Mendalam, Tumor Ovarium, Klasifikasi Citra Medis, EfficientNet-B3.

ABSTRACT

OVARIAN TUMOR MEDICAL IMAGE CLASSIFICATION USING DEEP LEARNING WITH EFFICIENTNET ARCHITECTURE

By

TASYA AZZAHRA PUTRI

Ovarian tumors are a serious medical issue that are difficult to detect early due to the similarity in characteristics between benign and malignant tumors. Therefore, accurate classification is crucial for determining patient prognosis and treatment strategies. This study develops a deep learning model based on the EfficientNet-B3 architecture to classify ovarian tumor CT scan images into benign and malignant categories. The model is built using transfer learning with ImageNet weights and involves preprocessing, segmentation, and data augmentation stages. A class weighting technique is also applied to address class imbalance in the dataset. Evaluation is conducted under two data split scenarios (70%, 15%, 15% and 80%, 10%, 10%) using accuracy and F1-score as performance metrics. The model achieved 90% accuracy and an F1-score of 0.90 in the first scenario, and 86% accuracy with an F1-score of 0.86 in the second. Some misclassifications were still observed and are noted as considerations for future development.

Keyword : Deep Learning, Ovarian Tumor, Medical Images Classification, EfficientNet-B3.

**KLASIFIKASI CITRA MEDIS TUMOR OVARIUM MENGGUNAKAN
DEEP LEARNING DENGAN ARSITEKTUR EFFICIENTNET**

Oleh

TASYA AZZAHRA PUTRI

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA KOMPUTER**

Pada

Jurusan Ilmu Komputer

Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2025

**Judul Skripsi : KLASIFIKASI CITRA MEDIS TUMOR
OVARIUM MENGGUNAKAN DEEP
LEARNING DENGAN ARSITEKTUR
EFFICIENTNET**

Nama Mahasiswa : Tasya Azzahra Putri

Nomor Pokok Mahasiswa : 2117051043

Program Studi : S1 Ilmu Komputer

Jurusan : Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

A black ink signature of Dr. rer. nat. Akmal Junaidi, M.Sc.

Dr. rer. nat. Akmal Junaidi, M.Sc.

NIP. 197101291997021001

2. Ketua Jurusan Ilmu Komputer

A blue ink signature of Dwi Sakethi, S.Si., M. Kom.

Dwi Sakethi, S.Si., M. Kom.


NIP. 196806111998021001

MENGESAHKAN


1. Tim Penguji

Ketua


: Dr. rer. nat. Akmal Junaidi, M.Sc.



Penguji Pembahas I : M. Iqbal Parabi, S.SI., M.T.



Penguji Pembahas II : Dewi Asiah Shofiana, S.Komp., M.Kom.




2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 197110012005011002



Tanggal Lulus Ujian Skripsi: 20 Juni 2025

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Tasya Azzahra Putri

NPM : 2117051043

Menyatakan bahwa skripsi saya yang berjudul "**KLASIFIKASI CITRA MEDIS TUMOR OVARIUM MENGGUNAKAN *DEEP LEARNING* DENGAN ARSITEKTUR EFFICIENTNET**" merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil penjiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang telah saya terima.

Bandar Lampung, 26 Juni 2025



The image shows a handwritten signature in black ink over a pink revenue stamp. The stamp is rectangular and contains the text 'METERAI TEMPEL' and a unique identifier '03G02X527211174'. There is also a small circular emblem on the stamp.

Tasya Azzahra Putri
NPM. 2117051043

RIWAYAT HIDUP



Penulis dilahirkan di Panjang, pada tanggal 1 Juli 2002, sebagai anak pertama dari dua bersaudara, dari Bapak Irwan Nuryaddin, dan Ibu Tri Yuliana Siska Penulis menyelesaikan pendidikan formal di SDN 1 Karang Maritim dan selesai pada tahun 2014. Kemudian pendidikan menengah pertama di SMPN 30 Bandar Lampung, yang diselesaikan pada tahun 2017, lalu melanjutkan ke pendidikan menengah atas di SMAN 2 Kotabumi yang diselesaikan pada tahun 2020. Pada tahun 2021 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan antara lain:

1. Menjadi Anggota Bidang Media Informasi Himpunan Mahasiswa Jurusan Ilmu Komputer (HIMAKOM) Periode 2022/2023.
2. Menjadi Sekretaris Bidang Media Informasi Himpunan Mahasiswa Jurusan Ilmu Komputer (HIMAKOM) Periode 2023/2024.
3. Menjadi Asisten Dosen pada Mata Kuliah Sistem Operasi Semester Genap Tahun Ajaran 2022/2023.
4. Melakukan Kerja Praktik di Bidhumas Polda Lampung Periode 2023/2024.
5. Mengikuti Kuliah Kerja Nyata (KKN) pada periode II tahun 2024 di Desa Braja Asri, Kecamatan Way Jepara, Kabupaten Lampung Timur.

MOTTO

“Karena sesungguhnya sesudah kesulitan itu ada kemudahan”

(QS. Al-Insyirah : 5)

“Tidak ada yang tidak mungkin, kecuali memakan kepala sendiri”

(Ayah)

“It will pass, everything you’ve gone through it will pass”

(Rachel Vennya)

“Selama masih hidup, kesempatan itu tidak terbatas”

(Monkey D. Luffy)

“Hidup yang tidak sesuai impian itu bukanlah hidup yang gagal.

Dan hidup yang sesuai impian juga belum tentu berhasil”

(2521)

PERSEMBAHAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Alhamdulillahirobbilalamin

Alhamdulillah atas segala rahmat dan karunia dari Allah SWT yang telah memudahkan saya menyelesaikan skripsi ini. Saya juga senantiasa mengirimkan salawat dan salam kepada Nabi Muhammad SAW.

Saya persembahkan karya ini kepada:

Kedua Orang Tuaku Tercinta

Yang selalu memberikan yang terbaik dan mengiringi do'a untuk saya. Saya juga mengucapkan terima kasih yang sebesar-besarnya karena telah mendidik dan membesarkan saya dengan penuh kasih sayang, dukungan, dan pengorbanan yang belum bisa saya balas.

Seluruh Keluarga Besar Ilmu Komputer 2021

Yang selalu memberikan semangat dan dukungan.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat bernaung melahap semua ilmu untuk menjadi bekal hidup kedepannya.

SANWACANA

Puji syukur kehadiran Allah SWT atas berkah, rahmat dan hidayat-Nya, serta petunjuk dan pedoman dari Rasulullah Nabi Muhammad Sholallahu Alaihi Wasallam penulis dapat menyelesaikan skripsi yang berjudul **“KLASIFIKASI CITRA MEDIS TUMOR OVARIUM MENGGUNAKAN *DEEP LEARNING* DENGAN ARSITEKTUR EFFICIENTNET”** dengan baik dan lancar.

Terima kasih penulis ucapkan kepada semua pihak yang telah membantu dan berperan besar dalam menyusun skripsi ini, antara lain:

1. Kedua Orang Tuaku Tercinta Ayah Irwan Nuryaddin dan Bunda Tri Yuliana Siska yang telah memberikan segala bentuk cinta, doa, pengorbanan, dan dukungan tanpa henti yang telah menjadi fondasi bagi setiap langkah penulis untuk menyelesaikan skripsi ini.
2. Adikku M. Bintang Farraz. N yang telah memberikan segala bentuk dukungan dan doa untuk penulis selama proses menyelesaikan skripsi ini
3. Ibu Anie Rose Irawati, S.T. M.Cs sebagai Dosen Pembimbing Akademik yang telah memberikan arahan, ide, motivasi, dan dukungan akademik penulis.
4. Bapak Dr. rer. nat. Akmal Junaidi, S.Si., M.Sc. sebagai Dosen Pembimbing Utama yang telah memberikan arahan, ide, motivasi, kritik serta saran kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik
5. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D, Bapak M. Iqbal Parabi, S.Si., M.T. dan Ibu Ossy Dwi Endah Wulansari, S.Si., M.T sebaga Dosen Pembahas 1 yang telah memberikan masukan yang bermanfaat dalam perbaikan skripsi ini.
6. Ibu Dewi Asiah Shofiana, S.Komp., M.Kom. dan Ibu Yunda Heningtyas, M.Kom sebagai Dosen Pembahas 2 yang telah memberikan masukan yang bermanfaat dalam perbaikan skripsi ini dan mendukung peningkatan akademik penulis.

7. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
8. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan FMIPA Universitas Lampung.
9. Ibu Yunda Heningtyas, M. Kom. selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
10. Ibu Ade Nora Maela, Bang Zainuddin, Mas Nofal, dan Mas Sam yang telah membantu segala urusan administrasi penulis di Jurusan Ilmu Komputer.
11. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu dan pengalaman dalam hidup untuk menjadi lebih baik.
12. Anggota Grup Whatsapp Tebu Tubaba (Iqbal, Reza, Qolby, Rafi S, Rafi R, Bagas, Zidan, Hanif, Enjel, Muca, Wirda, Ipeh, Nisa, Nathan, Putri, Zahra) yang telah menemani masa-masa awal perkuliahan penulis.
13. Anggota Grup Whatsapp Sahabat Jannah (Nindi, Yuna, Siska, Enjel, April, Ika, Talia, Adhis, Kristi) yang selalu kebersamai, serta memberikan dukungan, dan doa kepada penulis.
14. Kak Wawan untuk segala bentuk bantuan, masukan, dan dukungan yang telah diberikan selama akhir proses penyusunan skripsi ini.
15. Seluruh kakak tingkat dan adik tingkat Ilmu Komputer yang tidak bisa disebutkan satu persatu yang telah menjadi warna selama masa perkuliahan penulis.
16. Keluarga Besar Ilmu Komputer 2021 yang tidak bisa penulis sebutkan satu persatu.

Bandar Lampung, 26 Juni 2025



Tasya Azzahra Putri
NPM. 21170510043

DAFTAR ISI

	Halaman
DAFTAR ISI.....	i
DAFTAR GAMBAR.....	iv
DAFTAR TABEL.....	v
DAFTAR KODE PROGRAM.....	vi
I. PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
II. TINJAUAN PUSTAKA.....	5
2.1 Tumor Ovarium.....	5
2.2 Penelitian Terdahulu	5
2.3 <i>Deep Learning</i>	8
2.4 <i>Convolutional Neural Network (CNN)</i>	8
2.4.1 <i>Feature Learning</i>	9
2.4.2 <i>Convolution Layer</i>	10
2.4.3 <i>Pooling Layer</i>	11
2.4.4 <i>Activation Function</i>	11
2.4.5 <i>Batch Normalization</i>	13
2.4.6 <i>Flatten</i>	14
2.4.7 <i>Fully Connected Layer</i>	15
2.5 EfficientNet.....	15

2.6 Augmentasi	19
2.7 Segmentasi Citra	20
2.8 <i>Confusion Matrix</i>	20
2.8.1 <i>Accuracy</i>	21
2.8.2 <i>Recall</i>	22
2.8.3 <i>Precision</i>	22
2.8.4 <i>F1-Score</i>	22
III. METODOLOGI PENELITIAN	23
3.1 Waktu dan Tempat Penelitian	23
3.1.1 Waktu Penelitian	23
3.1.2 Tempat Penelitian	23
3.2 Alat dan Bahan Penelitian	23
3.2.1 Alat Penelitian	24
3.2.2 Bahan Penelitian	24
3.3 Tahap Penelitian	24
3.4 Pengumpulan Data	25
3.5 Pembagian Data	26
3.6 Augmentasi Data	26
3.7 Pemilihan Arsitektur Model	27
3.8 <i>Training Model</i>	28
3.9 <i>Testing Model</i>	28
3.10 Evaluasi Model	28
IV. HASIL DAN PEMBAHASAN	30
4.1 Deskripsi Umum <i>Dataset</i>	30
4.2 <i>Preprocessing Data</i>	31
4.2.1 Penyesuaian Ukuran Citra (<i>Resize</i>)	31
4.2.2 Segmentasi Citra	33
4.2.3 Persiapan <i>Dataset</i>	33
4.2.4 Estimasi Ketebalan <i>Outline Biru</i>	34
4.2.5 Segmentasi Berdasarkan <i>Outline Biru</i>	35
4.2.6 Ekstraksi Kontur dan <i>Crop Area Tumor</i>	36

4.2.7 <i>Fallback</i> Jika Kontur Gagal	38
4.2.8 Pembersihan Sisa Warna Biru (<i>Inpainting</i>)	40
4.2.9 Otomatisasi Segmentasi dan Penyimpanan Hasil	41
4.2.10 <i>Splitting</i> Data	42
4.2.11 Augmentasi Data	44
4.2.12 Normalisasi Data	46
4.3 Pengembangan Model	47
4.3.1 Arsitektur Dasar: EfficientNet-B3	47
4.3.2 Penambahan <i>Layer</i> dan Kompilasi Model	48
4.3.3 <i>Training</i> Model	50
4.3.4 Pembobotan Data Yang Tidak Seimbang	51
4.3.5 <i>Callback Training</i> Model	53
4.3.6 Proses Pelatihan Model	54
4.3.7 <i>Testing</i> Model	56
4.3.8 Evaluasi Model	57
4.3.9 Analisis <i>Misclassification</i>	61
V. SIMPULAN & SARAN	63
5.1 Simpulan	63
5.2 Saran	64
DAFTAR PUSTAKA	66

DAFTAR GAMBAR

Gambar	Halaman
1. Ilustrasi Lapisan <i>Convolutional Neural Network</i>	9
2. Ilustrasi <i>Max Pooling & Average Pooling</i>	11
3. Ilustrasi <i>Batch Normalization</i> (https://medium.com/)	14
4. Ilustrasi <i>Flatten</i> (https://www.superdatascience.com/)	14
5. Ilustrasi <i>Fully Connected Layer</i> (https://www.gabormelli.com/)	15
6. Ilustrasi Arsitektur EfficientNet (Tan & Le, 2019)	17
7. Tahap Penelitian	25
8. Citra Sebelum & Sesudah Segmentasi	41
9. Citra Sebelum & Sesudah Augmentasi	46
10. Grafik <i>Training</i> Model Skenario 1 (70%, 15%, 15%)	55
11. Grafik <i>Training</i> Model Skenario 2 (80%, 10%, 10%)	56
12. Hasil <i>Confusion Matrix</i> Skenario 1	59
13. Hasil <i>Confusion Matrix</i> Skenario 2	60
14. Citra yang Mengalami <i>Miss Classification</i>	61
15. Contoh Citra Yang Memiliki Kemiripan Visual	62

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu	6
2. Perbedaan Resolusi <i>Input</i> pada Variasi Model EfficientNet.....	16
3. <i>Confusion Matrix</i>	20
4. <i>Splitting</i> Data	43
5. Distribusi <i>Dataset</i> Per Skenario	44
6. <i>Classification Report</i> Skenario 1	58
7. <i>Classification Report</i> Skenario 2.....	59

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. Kode Penyesuaian Ukuran Citra (<i>Resize</i>).....	32
2. Kode Persiapan <i>Dataset</i>	33
3. Kode Estimasi Ketebalan <i>Outline</i>	34
4. Kode Untuk Mengubah Format Citra.....	35
5. Kode Untuk Morfologi <i>Closing</i>	36
6. Kode Ekstraksi & <i>Crop</i> Area Tumor	37
7. Kode Untuk <i>Fallback</i>	39
8. Kode Untuk Menghitung Titik Tengah.....	39
9. Kode untuk <i>Inpainting</i>	40
10. Kode Otomatisasi Segmentasi	42
11. Kode Augmentasi Data	44
12. Kode Augmentasi Data.....	45
13. Kode Normalisasi Data.....	46
14. Kode untuk Memuat <i>Base</i> Model EfficientNet-B3	47
15. Kode untuk Penambahan <i>Layer</i> Model	49
16. Kode untuk Menggabungkan <i>Layer</i> Model.....	50
17. Kode untuk Proses Kompilasi Model.....	50
18. Kode untuk Menangani Ketidakseimbangan Data	52
19. Kode untuk <i>Callback</i>	54
20. Kode untuk <i>Training</i> Model	55

I. PENDAHULUAN

1.1 Latar Belakang

Tumor ovarium merupakan salah satu masalah kesehatan serius bagi seluruh wanita di dunia, termasuk di Indonesia. Tumor ovarium dikategorikan menjadi dua kelompok utama yaitu tumor jinak dan tumor ganas (kanker). Sebagian besar tumor ovarium (80%) merupakan tumor jinak dan mengenai wanita usia antara 20-45 tahun (Xavier et al., 2023). Menurut data dari *Global Burden of Cancer*, pada tahun 2022 terdapat 324.603 kasus baru kanker ovarium di seluruh dunia, dengan angka kematian sebesar 206.956. Untuk kasus di Indonesia, terdapat sebanyak 15.130 kasus baru kanker ovarium dengan angka kematian sebanyak 9.673.

Tantangan klinis umum yang harus diatasi oleh dunia kesehatan khususnya onkologi, salah satunya adalah dalam membedakan antara tumor ovarium jinak dan ganas. Tantangan ini terjadi karena, berbagai jenis tumor ovarium banyak diantaranya menunjukkan karakteristik yang serupa sehingga hal ini menimbulkan ketidakpastian dalam diagnosis klinis dan menyebabkan tumor terdiagnosis pada stadium yang sudah tinggi (Hsu et al., 2022). Dalam hal diagnosis, klasifikasi yang tepat antara tumor ovarium jinak dan ganas merupakan salah satu aspek yang penting dalam menentukan langkah pengobatan yang tepat untuk masing-masing jenis tumor. Klasifikasi yang akurat dapat meningkatkan efektivitas pengobatan dan prognosis pasien (Ramayuda et al., 2021).

Di era digital yang terus berkembang seperti saat ini, kecerdasan buatan (*Artificial Intelligence*), khususnya *deep learning* telah banyak menunjukkan hasil yang signifikan dalam dunia kesehatan, termasuk dalam hal analisis citra medis. *Deep learning*, menggunakan jaringan saraf buatan multilapis untuk mengklasifikasikan citra dan suara secara langsung (Ilahiyah & Nilogiri, 2018). Pemanfaatan *deep learning* dalam analisis citra medis dapat membantu mengidentifikasi pola-pola yang sulit dideteksi oleh manusia. *Deep Learning*, khususnya arsitektur seperti EfficientNet telah terbukti efektif dalam berbagai tugas klasifikasi citra medis, termasuk deteksi tumor.

EfficientNet merupakan salah satu arsitektur *deep learning* yang dirancang untuk mengoptimalkan efisiensi dan akurasi model dengan menggunakan teknik *scaling* yang seimbang. EfficientNet memiliki keunggulan lain yaitu, penggunaan *Floating Point Operations Per Second* (FLOPS) yang lebih rendah dan mampu mencapai kinerja yang lebih baik. Hal ini dapat mempercepat waktu inferensi dan mengurangi kebutuhan daya komputasi jika dibandingkan dengan arsitektur lain seperti ResNet atau Inception (Tan & Le, 2019). Implementasi EfficientNet dalam klasifikasi citra medis tumor ovarium dapat membantu mengurangi kesalahan diagnosis yang sering terjadi pada metode konvensional.

Sejumlah penelitian telah dilakukan untuk meningkatkan akurasi diagnosis tumor ovarium melalui berbagai pendekatan *deep learning*. Pada penelitian yang dilakukan oleh Acharya et al (2018), fitur non-linear dan *ensemble fuzzy forest* digunakan untuk mengklasifikasikan tumor ovarium, dan hasilnya menunjukkan akurasi maksimum sebesar 80.60%. Penelitian oleh Guha et al (2024) yang menggunakan Enhanced ResNet50 untuk klasifikasi tumor ovarium menunjukkan peningkatan akurasi diagnosis, dengan hasil akurasi maksimum mencapai 97.5%.

Penelitian ini bertujuan mengembangkan model *deep learning* menggunakan arsitektur EfficientNet-B3 agar dapat mengklasifikasikan citra medis tumor ovarium dengan lebih akurat. Model ini dipilih karena memiliki keunggulan teknis yang membuatnya efisien dan cocok untuk tugas ini. EfficientNet-B3 mampu mengolah citra dengan resolusi yang lebih besar tanpa membutuhkan daya komputasi sebesar varian B5 sampai B7, sehingga proses pelatihan dan pengelompokkan untuk jenis tumor bisa berjalan lebih cepat dan hemat sumber daya. Desain model yang seimbang antara ukuran, kedalaman lapisan, dan ukuran citra *input* juga membantu model mengenali pola-pola rumit pada citra tumor dengan lebih baik. Dengan kata lain, penggunaan EfficientNet-B3 pada penelitian ini adalah untuk membantu membuat sistem diagnosis yang tidak hanya tepat dalam mengenali jenis tumor jinak maupun ganas, tapi juga lebih cepat dan murah digunakan.

1.2 Rumusan Masalah

Adapun rumusan masalah pada penelitian ini sebagai berikut:

1. Bagaimana merancang dan mengimplementasikan model arsitektur EfficientNet-B3 untuk klasifikasi citra medis tumor ovarium?
2. Sejauh mana akurasi dan stabilitas performa model EfficientNet-B3 dalam mengklasifikasikan tumor ovarium menjadi kelas *Benign* dan *Malignant*, terutama pada kondisi data yang terbatas?
3. Apa saja faktor-faktor teknis, seperti konfigurasi *hyperparameter*, dan pembagian data yang dapat mempengaruhi kinerja akhir pada model klasifikasi?

1.3 Batasan Masalah

Adapun batasan masalah dalam penelitian ini yaitu:

1. Penelitian ini menggunakan *dataset* citra medis tumor ovarium yang tersedia secara publik, hal ini mungkin tidak mencakup semua jenis dan subtype tumor ovarium.

2. Penelitian ini menggunakan *dataset* citra medis tumor ovarium yang jumlahnya terbatas, dan sudah dalam bentuk *cropping*.
3. Penelitian ini menggunakan segmentasi citra untuk menghilangkan anotasi lingkaran biru pada *dataset*, sehingga hanya area tumor yang digunakan untuk pelatihan dan evaluasi model klasifikasi.

1.4 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Mengembangkan model *deep learning* dengan arsitektur EfficientNet-B3 untuk klasifikasi citra medis tumor ovarium.
2. Menentukan *hyperparameter* yang optimal pada model arsitektur EfficientNet-B3, untuk mencapai pelatihan model yang stabil dan efisien.
3. Mengevaluasi performa model arsitektur EfficientNet-B3 yang dikembangkan melalui metrik seperti *accuracy*, *precision*, *recall*, *F1-score* serta analisis *confusion matrix*.
4. Mengidentifikasi faktor-faktor yang mempengaruhi kinerja model dalam klasifikasi citra medis tumor ovarium.

1.5 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah:

1. Menambah wawasan dan pengetahuan dalam bidang *deep learning* dan aplikasinya dalam klasifikasi citra medis tumor ovarium.
2. Dapat mengetahui *hyperparameter* model arsitektur EfficientNet-B3 yang optimal, dalam mengklasifikasi citra medis tumor ovarium.
3. Memberikan pemahaman lebih lanjut mengenai faktor-faktor yang mempengaruhi kinerja model arsitektur dalam klasifikasi citra medis tumor ovarium.

II. TINJAUAN PUSTAKA

2.1 Tumor Ovarium

Tumor ovarium merupakan salah satu jenis tumor yang paling mematikan dan mempengaruhi organ reproduksi wanita. Jenis tumor ini sering kali tidak terdeteksi hingga mencapai tahap lanjut, yang membuat prognosisnya lebih buruk dibandingkan dengan kanker ginekologi lainnya. Tumor ini dapat dikategorikan menjadi dua kategori utama yaitu tumor jinak (*benign*) dan tumor ganas (*malignant*). Tumor ovarium memiliki gejala yang semakin terlihat seiring dengan pertumbuhan yang terjadi. Gejala yang menjadi indikasi adanya tumor pada ovarium dapat menyebabkan perut kembung, nyeri panggul, pembengkakan pada bagian perut, serta hilangnya rasa lapar (Acharya et al., 2018).

Salah satu karakteristik yang paling menonjol dari tumor ovarium adalah deteksi dini yang sulit, sehingga salah satu tantangan penting yang dihadapi oleh dunia kedokteran adalah untuk mendiagnosis tumor ovarium sedini mungkin (Srivastava et al., 2020).

2.2 Penelitian Terdahulu

Penelitian terkait klasifikasi tumor ovarium menggunakan cita medis cukup menjadi perhatian besar dalam dunia medis dan teknologi belakangan ini. Hal ini mengingat pentingnya diagnosis dini untuk meningkatkan peluang kesembuhan pasien dan menentukan pengobatan sesuai jenis tumor. Berbagai pendekatan telah dilakukan, mulai dari metode tradisional berbasis fitur hingga teknik modern berbasis *deep learning*. Pada tingkat global,

cukup banyak studi yang menyoroti pentingnya klasifikasi otomatis tumor ovarium sebagai alat bantu diagnosis yang efisien. Sementara itu, di Indonesia penelitian terkait masih relatif terbatas. Eksplorasi penggunaan *deep learning* pada citra medis, termasuk untuk klasifikasi tumor ovarium terus meningkat, meskipun akses terhadap *dataset* besar dan berkualitas masih menjadi tantangan utama. Penelitian terdahulu yang pernah dilakukan dan berkaitan dengan klasifikasi citra medis tumor ovarium dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu

Penulis	Data	Model	Hasil
<i>Explainable AI for Interpretation of Ovarian Tumor Classification Using Enhanced ResNet50</i> (Guha et al., 2024)	Jumlah : 5725	ResNet60 (ResNet 50 yang disempurnakan)	Akurasi: 97,5%
<i>Deep learning for ovarian tumor classification with ultrasound images</i> (Wu et al., 2018)	Jumlah : 988 (Terdiri atas tiga kategori yaitu <i>Benign</i> , <i>Borderline</i> , dan <i>Malignant</i> . Jumlah citra untuk masing-masing kategori tidak dijelaskan secara rinci)	VGG16, DenseNet, GoogleNetV3, dan ResNet	Akurasi DenseNet: 87,50% Akurasi GoogleNetV3: 92,5%

Penulis	Data	Model	Hasil
<i>Automatic ovarian tumors recognition system based on ensemble convolutional neural network with ultrasound imaging</i> (Hsu et al., 2022)	Jumlah : 1896 Jinak : 948 Ganas : 948	Ensemble Convolutional Neural Network	Akurasi: 92,15%

Penelitian berjudul “*Explainable AI for Interpretation of Ovarian Tumor Classification Using Enhanced ResNet50*” yang dilakukan oleh (Guha et al., 2024) menggunakan model Enhanced ResNet50, yang merupakan modifikasi dari arsitektur ResNet50, dan *dataset* yang berjumlah 5725 citra CT yang terdiri dari kategori *Benign* dan *Malignant*. Fitur-fitur yang telah diekstrak dari citra CT diinterpretasikan menggunakan metode seperti Grad-CAM untuk memberikan transparansi terhadap hasil klasifikasi. Model yang digunakan pada penelitian ini mencapai akurasi maksimum sebesar 97,50%, spesifisitas 90,97%, dan F1-score 98,30%.

Penelitian lain dilakukan oleh (Wu et al., 2018) yang berjudul “*Deep learning for ovarian tumor classification with ultrasound images*” menggunakan salah satu metode *deep learning* yaitu *Convolutional Neural Network* (CNN) dengan membandingkan empat arsitektur CNN yang berbeda, yaitu VGG16, DenseNet, GoogleNet (V3), dan ResNet untuk klasifikasi tumor ovarium berdasarkan citra ultrasonografi. Penelitian ini menggunakan *dataset* berjumlah 988 citra medis tumor ovarium yang terdiri atas tiga kategori yaitu (*Benign, Borderline, and Malignant*), untuk jumlah data pada setiap kategorinya tidak dispesifikasikan secara detail. Penelitian ini juga menerapkan teknik augmentasi data dan *fine-tuning* untuk mengoptimalkan performa model yang dilatih. Dari keempat model yang dievaluasi dalam penelitian ini, DenseNet dan GoogleNet (V3) secara umum menghasilkan akurasi yang cukup tinggi, yaitu 87,50% dan 92,50%.

Penelitian lain yang membahas terkait klasifikasi tumor ovarium dilakukan oleh (Hsu et al., 2022) dengan judul “*Automatic ovarian tumors recognition system based on ensemble convolutional neural network with ultrasound imaging*”. Penelitian ini mengusulkan sebuah sistem otomatis menggunakan metode *Ensemble Convolutional Neural Network* (CNN) pada 1896 citra ultrasonografi (948 jinak dan 948 ganas). Sistem yang dibangun dalam penelitian ini menggabungkan teknologi seperti *image preprocessing*, *data augmentation*, dan *ensemble Grad-CAM*. Penelitian ini menggabungkan tiga model arsitektur CNN yang berbeda, yaitu VGG16, ResNet50, dan InceptionV3 yang dilatih dari awal (*trained from scratch*) untuk mencapai performa yang lebih baik. Hasil penelitian mencapai rata-rata akurasi sebesar 92,15%, sensitivitas 91,37%, dan spesifitas 92,92%.

2.3 Deep Learning


Deep learning merupakan salah satu bagian dari *machine learning* yang telah banyak digunakan dalam berbagai bidang termasuk bidang medis. Konsep *deep learning* berpusat pada penggunaan jaringan saraf tiruan dengan banyak lapisan (*deep neural network*), yang terinspirasi dari struktur dan fungsi otak manusia. *Deep learning* memungkinkan model komputasi yang terdiri atas beberapa lapisan pemrosesan untuk mempelajari representasi data dengan banyak level abstraksi (LeCun et al., 2015).

Kemampuan *deep learning* ini telah menghasilkan kemajuan yang signifikan dalam berbagai bidang seperti pengenalan citra. *Deep learning* telah mencapai akurasi yang mengesankan dalam melakukan tugas-tugas seperti klasifikasi objek, deteksi objek, dan segmentasi data.

2.4 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis arsitektur *deep learning* dikembangkan dari *multilayer perceptron* (MLP), yang dirancang untuk mengelola data dalam bentuk dua dimensi dan tiga dimensi. CNN telah banyak digunakan dalam *computer vision*, seperti klasifikasi,

deteksi, dan segmentasi (Gunawan & Setiawan, 2022). Oleh karena itu, CNN dikenal cukup unggul digunakan dalam pengenalan citra atau klasifikasi citra jika dibandingkan dengan metode *deep learning* lainnya (Nengsih, 2020). Secara umum, CNN terdiri atas beberapa *layer* yaitu *input layer*, *convolution layer*, *pooling layer*, *fully connected layer*, dan *output layer*. Pada Gambar 1 dapat dilihat gambaran umum dari arsitektur CNN. Pada penelitian ini akan menggunakan salah satu arsitektur CNN yaitu EfficientNet-B3.



Gambar 1. Ilustrasi Lapisan *Convolutional Neural Network*.

Pada gambar diatas, terdapat tahapan *Feature Learning* untuk mempelajari pola-pola penting dari *input* data. Selain itu dapat dilihat juga terdapat tahap *Classification* yang bertugas menentukan kelas atau kategori dari data berdasarkan fitur yang telah dipelajari sebelumnya. Berikut ini adalah pembahasan lebih lanjut mengenai kedua tahapan tersebut:

2.4.1 *Feature Learning*

Dalam konteks *deep learning*, *feature learning* biasanya dilakukan melalui arsitektur jaringan seperti CNN. Jaringan ini belajar mengenali fitur-fitur sederhana pada lapisan awal (seperti tepi dan tekstur), kemudian menggabungkannya menjadi fitur yang lebih kompleks pada lapisan-lapisan berikutnya (LeCun et al., 2015). Pada umumnya, terdapat tiga tahapan pada *feature learning* antara lain yaitu *convolution layer*, *activation function*, dan *pooling layer*. Ketiga tahapan lapisan ini bekerja secara berurutan untuk mengekstraksi, memproses, dan mereduksi fitur dari citra *input* guna

menghasilkan representasi yang optimal untuk klasifikasi. Pembahasan lebih lanjut mengenai ketiga tahapan tersebut adalah sebagai berikut.

2.4.2 Convolution Layer

Pada tahapan *feature learning*, lapisan ini berperan sebagai komponen awal yang pertama kali memproses *input* berupa citra yang dimasukkan kedalam arsitektur jaringan. Lapisan ini bekerja dengan menerapkan *filter* atau kernel yang bergerak melintasi seluruh area citra *input* untuk melakukan operasi konvolusi. Setiap penerapan *filter* menghasilkan nilai skalar yang merepresentasikan respon dari fitur tertentu pada lokasi piksel tertentu. Hasil dari operasi konvolusi biasanya disebut dengan *Feature Map* yang digunakan untuk *input* pada *layer* selanjutnya.

Feature Map yang dihasilkan dari operasi konvolusi berupa perkalian antara matriks dua dimensi dari *filter* dengan bagian-bagian tertentu dari *input* citra secara berulang pada berbagai posisi. Proses ini dipengaruhi oleh beberapa parameter penting, seperti *stride*, yang menentukan langkah pergeseran *filter*, serta *zero padding*, yang menambahkan nilai nol di tepi *input* untuk mempertahankan ukuran *output* (Gunawan & Setiawan, 2022). Pada Persamaan 1 di bawah ini merupakan rumus perhitungan dari *convolution layer*:

$$O = \left(\frac{W - F + 2P}{S} \right) + 1 \dots \dots \dots (1)$$

Keterangan dari rumus Persamaan 1 di atas:

O : Ukuran *output* setelah konvolusi

W : Ukuran *input* citra

F : Ukuran *filter* (kernel size)


P : Nilai *padding* yang digunakan

S : *Stride* (langkah pergeseran *filter*)

2.4.3 Pooling Layer

Pooling layer merupakan salah satu komponen penting dalam arsitektur CNN, *layer* ini digunakan untuk mereduksi dimensi spasial dari *feature map* yang dihasilkan oleh *convolution layer*. Proses ini bertujuan untuk menyederhanakan representasi data, mengurangi jumlah parameter dan komputasi, serta mengurangi risiko *overfitting* tanpa kehilangan informasi penting dari citra (Albawi et al., 2017)

Terdapat beberapa jenis *pooling* yang umum digunakan, antara lain yaitu *max pooling* dan *average pooling*. Ilustrasi untuk *max pooling* dan *average pooling* dapat dilihat pada Gambar 2 berikut ini:



Gambar 2. Ilustrasi Max Pooling & Average Pooling.

2.4.4 Activation Function

Activation layer adalah komponen penting dalam arsitektur jaringan saraf karena berfungsi untuk menambahkan *non-linearitas* ke dalam model. Tanpa fungsi aktivasi, model hanya akan menjadi kombinasi *linear* dari *input*, sehingga tidak dapat mempelajari hubungan kompleks dalam data, khususnya pada citra medis seperti tumor ovarium. Terdapat beberapa jenis fungsi aktivasi antara lain, ReLU, *Tanh*, *Sigmoid*, dan *Softmax*.

Salah satu fungsi aktivasi yang paling sering digunakan adalah ReLU (Gunawan & Setiawan, 2022). Setiap jenis fungsi aktivasi memiliki karakteristik dan nilai khas yang digunakan dalam perhitungan matematisnya. Berikut ini, merupakan penjelasan lebih lanjut mengenai fungsi aktivasi yang sering digunakan antara lain adalah sebagai berikut:

1. ReLU (*Rectified Linear Unit*)

ReLU merupakan fungsi aktivasi yang paling umum digunakan pada jaringan saraf modern karena kesederhanaannya dan performa komputasinya yang efisien. Fungsi ini hanya akan mengeluarkan nilai nol jika *input* kurang dari nol, dan mengembalikan nilai *input* itu sendiri jika lebih besar dari nol. Rumus matematis dari ReLU dapat dilihat pada Persamaan 2 di bawah ini:

$$f(x) = \max(0, x) \dots \dots \dots (2)$$

ReLU tergolong cukup efisien dalam hal komputasi, karena ReLU hanya melibatkan operasi *thresholding*. Hal inilah yang membuat ReLU mudah untuk diimplementasikan dan diproses, terutama dalam proses pelatihan jaringan saraf dalam skala besar yang melibatkan jutaan parameter.

2. Tanh

Fungsi aktivasi *tanh* merupakan bentuk terpusat dari fungsi *sigmoid*, fungsi ini menghasilkan *output* dalam rentang $[-1, 1]$, sehingga sering digunakan dalam jaringan saraf karena sifatnya yang lebih seimbang terhadap nol. Fungsi ini berguna untuk menyelaraskan distribusi agar mempermudah proses pembelajaran pada lapisan-lapisan selanjutnya. Pada Persamaan 3 di bawah ini dapat dilihat rumus matematis dari *tanh*:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \dots \dots \dots (3)$$

3. Sigmoid

Sigmoid adalah fungsi aktivasi klasik yang memetakan nilai *input* ke dalam rentang antara 0 dan 1, membuatnya cocok untuk tugas klasifikasi biner. Fungsi ini juga memiliki interpretasi probabilistik yang baik. Namun, *sigmoid* juga rentan terhadap masalah *vanishing gradient*, terutama ketika nilai *input* sangat besar atau sangat kecil. Rumus matematis dari fungsi *sigmoid* dapat dilihat pada Persamaan 4 berikut:

$$f(x) = \frac{1}{1+e^{-x}} \dots \dots \dots (4)$$

Fungsi *sigmoid* akan menghasilkan *output* yang mendekati 0 untuk *input* negatif besar, dan mendekati 1 jika *input* positif besar.

4. *Softmax*


Softmax merupakan fungsi aktivasi yang umum digunakan pada lapisan *output* dalam kasus klasifikasi multi-kelas. Fungsi ini berperan mengubah sekumpulan logit (*output linear*) menjadi distribusi probabilitas, di mana total nilai seluruh kelas berjumlah satu. Dengan demikian, setiap kelas diberikan nilai probabilitas relatif terhadap kelas lainnya.

2.4.5 *Batch Normalization*

Batch normalization merupakan suatu teknik normalisasi data yang diterapkan di dalam proses pelatihan *deep neural networks*, tujuan dari teknik ini untuk mengatasi perubahan distribusi *input* antar lapisan jaringan selama proses pelatihan berlangsung. Teknik ini bekerja dengan menormalkan *output* dari lapisan sebelumnya berdasarkan nilai rata-rata dan standar deviasi dari setiap *mini batch* (Ioffe & Szegedy, 2015)

Dengan teknik ini, proses pelatihan dapat berlangsung lebih cepat dan stabil. Selain meningkatkan efisiensi pelatihan, teknik ini juga dapat memberikan efek regularisasi, sehingga dalam beberapa kasus dapat mengurangi ketergantungan terhadap metode seperti *dropout*.

Penggunaan *batch normalization* terbukti secara empiris mampu meningkatkan akurasi model, mempercepat konvergensi, serta membuat pelatihan jaringan lebih tangguh terhadap variasi inisialisasi bobot. Oleh karena itu, teknik ini telah menjadi bagian integral dari berbagai arsitektur *deep learning* modern seperti ResNet, Inception, dan EfficientNet. Pada Gambar 3 dibawah ini merupakan ilustrasi dari teknik *batch normalization*:




Gambar 3. Ilustrasi *Batch Normalization* (<https://medium.com/>).

2.4.6 Flatten

Flatten merupakan salah satu proses dalam arsitektur *deep neural network*, khususnya pada tahap transisi dari *convolution layer* ke *fully connected layer*. *Flatten* berfungsi untuk mengubah data multidimensi menjadi bentuk vektor satu dimensi.

Transformasi ini diperlukan karena lapisan *dense* hanya dapat menerima *input* dalam bentuk vektor. Tanpa proses *flatten*, data yang bersifat spasial tidak dapat diteruskan ke tahap klasifikasi. Pada Gambar 4 dapat dilihat ilustrasi dari *flatten*:




Gambar 4. Ilustrasi *Flatten* (<https://www.superdatascience.com/>).

2.4.7 Fully Connected Layer

Fully connected layer merupakan salah satu komponen penting dalam arsitektur CNN. Lapisan ini biasanya terletak di bagian akhir jaringan dan berfungsi menggabungkan semua fitur yang telah diekstrak oleh lapisan sebelumnya, seperti lapisan konvolusi dan *pooling*. Pada tahap ini, data yang sebelumnya berbentuk matriks diubah menjadi bentuk vektor satu dimensi dengan proses *flattening*. Vektor ini kemudian diproses oleh *neuron-neuron* dalam *fully connected layer* yang mirip dengan jaringan saraf tradisional.

Fungsi utama dari *fully connected layer* adalah menghubungkan dan mengkombinasikan semua informasi fitur agar model dapat mengenali pola yang kompleks dan membuat keputusan klasifikasi atau prediksi yang lebih akurat. Karena semua *neuron* pada lapisan ini terhubung secara penuh ke *neuron* di lapisan berikutnya, lapisan ini mampu mempelajari hubungan non-linear antara fitur-fitur yang diperoleh dari citra atau data *input*. Pada Gambar 5 dapat dilihat ilustrasi dari *fully connected layer*:



Gambar 5. Ilustrasi *Fully Connected Layer* (<https://www.gabormelli.com/>).

2.5 EfficientNet

EfficientNet merupakan salah satu arsitektur turunan dari *Convolutional Neural Network* (CNN) yang dikembangkan oleh Google AI Research, dan

pertama kali dikenalkan dalam sebuah makalah berjudul “EfficientNet: *Rethinking Model Scaling for Convolutional Neural Networks*” yang dipublikasikan pada tahun 2019 (Tan & Le, 2019). EfficientNet secara khusus dirancang untuk mengatasi tantangan dalam membangun model *deep learning* yang kompleks namun tetap efisien dalam hal penggunaan sumber daya komputasi.

EfficientNet terdiri atas beberapa varian yang diberi label mulai dari B0 hingga B7, yang masing-masing dirancang dengan ukuran model dan kompleksitas yang berbeda. Variasi model ini dihasilkan melalui proses *compound scaling*, yaitu metode yang digunakan untuk meningkatkan kedalaman, lebar, dan resolusi jaringan secara seimbang (Tan & Le, 2019). Pemilihan varian model arsitektur yang digunakan dapat disesuaikan dengan kebutuhan dan kapasitas perangkat keras yang tersedia. Setiap model memiliki ukuran *input* yang berbeda, seperti yang dapat dilihat pada Tabel 2 dibawah ini.


Tabel 2. Perbedaan Resolusi *Input* pada Variasi Model EfficientNet.

Variasi Model	Resolusi <i>Input</i>
EfficientNet-B0	224 x 224
EfficientNet-B1	240 x 240
EfficientNet-B2	260 x 260
EfficientNet-B3	300 x 300
EfficientNet-B4	380 x 380
EfficientNet-B5	456 x 456
EfficientNet-B6	528 x 528
EfficientNet-B7	600 x 600

Model ini memiliki keunggulan dalam mencapai akurasi yang tinggi dan juga dalam mengurangi parameter dari FLOPS (*Floating Point Operations Per Second*) yang dapat memperbaiki kemampuan suatu model (Andre et al.,

2021). Pada EfficientNet, FLOPS merupakan salah satu metrik penting dalam mengukur efisiensi model. Pengurangan FLOPS membuat model bekerja lebih cepat, membutuhkan sumber daya yang lebih rendah, dan mudah diterapkan dalam perangkat yang memiliki sumber daya terbatas.

EfficientNet dikembangkan berdasarkan arsitektur MobileNetV2 dan menggunakan teknik NAS (*Neural Architecture Search*) dengan menerapkan MBConv (*Mobile Inverted Bottleneck Convolution*) sebagai komponen utamanya. Model arsitektur ini mampu mencapai tingkat akurasi yang cukup tinggi, serta dalam hal mengurangi jumlah parameter yang diperlukan untuk pelatihan. Pada Gambar 6 dapat dilihat ilustrasi dari arsitektur EfficientNet.



Gambar 6. Ilustrasi Arsitektur EfficientNet (Tan & Le, 2019).

Gambar 6 di atas merupakan arsitektur EfficientNet-B0, yang menjadi dasar atau *baseline* dari seluruh varian EfficientNet lainnya. Meskipun setiap varian EfficientNet memiliki struktur tahapan yang serupa, perbedaannya terletak pada jumlah *layer* yang digunakan di setiap tahapannya. Semakin tinggi versinya, maka akan semakin kompleks dan dalam arsitekturnya. Adapun tahapan-tahapan dalam arsitektur EfficientNet-B0 saat melakukan klasifikasi citra akan dijelaskan sebagai berikut:

1. Tahapan pertama, *input* citra terlebih dahulu diproses menggunakan *convolutional filter* berukuran 3x3 sebanyak 32 saluran (*channel*). Tujuan dari proses ini adalah untuk mengekstraksi fitur-fitur dasar citra, seperti tepi dan tekstur. Selanjutnya, hasil dari proses konvolusi distandarkan melalui *batch normalization* untuk mempercepat proses pelatihan dan menjaga kestabilan jaringan. Setelah itu, hasil normalisasi melewati fungsi aktivasi ReLU (*Rectified Linear Unit*), yang berfungsi

untuk memperkenalkan sifat *non-linear* pada model, sehingga jaringan dapat mempelajari representasi data yang lebih kompleks.

2. Tahap kedua, proses dimulai dengan *depthwise convolution* menggunakan *filter* berukuran 3x3 sebanyak 16 saluran untuk mengekstraksi fitur penting dari citra. Hasilnya kemudian distandarisasi melalui *batch normalization*, lalu dilewati oleh fungsi aktivasi ReLU. Selanjutnya, dilakukan *global average pooling* untuk merangkum informasi dari setiap fitur diikuti dengan proses *reshape* agar sesuai dengan dimensi berikutnya.
3. Tahap ketiga, citra diproses dengan *convolutional filter* berukuran 3x3 dengan 24 *channel* untuk menangkap fitur yang lebih kompleks. Selanjutnya, hasil distabilkan menggunakan *batch normalization* dan dilakukan *activation function* menggunakan ReLU. Setelah itu, dilanjutkan dengan pemrosesan menggunakan blok MBConv6 dengan kernel 3x3 yang dirancang untuk meningkatkan efisiensi dan akurasi fitur ekstraksi.
4. Pada tahap keempat, untuk menangkap pola yang lebih luas dari citra dilakukan proses *filtering* menggunakan kernel berukuran 5x5 dengan 40 *channel*. Hasilnya kemudian distandarisasi melalui *batch normalization* dan diberi fungsi aktivasi ReLU. Tahap ini diakhiri dengan pemrosesan menggunakan blok MBConv6 dengan *filter* 5x5, untuk memperdalam representasi fitur secara efisien.
5. Tahap kelima, citra diproses menggunakan kernel 3x3 dengan 80 *channel* untuk mengekstraksi fitur yang lebih mendetail. Proses selanjutnya, dilakukan *batch normalization* dan aktivasi ReLU untuk meningkatkan kestabilan dan kemampuan model *non-linear*. Proses ini dilanjutkan dengan penerapan MBConv6 menggunakan *filter* 3x3 untuk efisiensi dan pendalaman fitur pada citra.
6. Tahap keenam, pemrosesan dilakukan dengan kernel berukuran 5x5 dengan 112 *channel* untuk menangkap fitur yang lebih kompleks. Selanjutnya, hasil distandarisasi dengan *batch normalization* dan diberi

fungsi aktivasi ReLU. Proses pada tahap ini dilakukan untuk memperkuat representasi fitur yang telah diperoleh.

7. Pada tahap ketujuh, dilakukan proses *filtering* menggunakan kernel berukuran 5x5 dengan 192 *channel* untuk mengekstraksi fitur yang lebih dalam dan kompleks. Hasilnya kemudian distabilkan melalui *batch normalization* dan diproses menggunakan fungsi aktivasi ReLU. Tahap ini dilakukan untuk memperkuat hasil ekstraksi fitur sebelumnya.
8. Tahap kedelapan, proses *filtering* dilakukan dengan kernel berukuran 3x3 dengan 320 *channel*. Setelah itu dilakukan proses *batch normalization* dan aktivasi fungsi menggunakan ReLU. Selanjutnya, proses diakhiri dengan penerapan MBConv6 menggunakan kernel 3x3 untuk memperdalam ekstraksi fitur secara efisien.
9. *Output* dari tahapan sebelumnya kemudian diproses dengan *pooling layer* untuk merangkum informasi dari fitur yang telah diekstraksi. Setelah itu, hasilnya diubah menjadi bentuk *array* satu dimensi melalui proses *flatten* agar dapat digunakan sebagai *input* pada lapisan klasifikasi akhir.

Setelah fitur diekstraksi dan diubah ke dalam bentuk satu dimensi, data diteruskan ke tahap klasifikasi akhir. Arsitektur EfficientNet, mulai dari B0 hingga B7, memiliki struktur dasar yang serupa namun berbeda dalam hal jumlah *layer* dan tingkat kompleksitas.

2.6 Augmentasi

Augmentasi data merupakan teknik penting dalam pelatihan model *deep learning*, termasuk EfficientNet terutama ketika jumlah *dataset* yang tersedia sangat terbatas seperti halnya dalam kasus data citra medis. Teknik ini bertujuan agar data menghasilkan variasi baru dan beragam dari citra yang ada, serta untuk meningkatkan kinerja model dalam mengklasifikasikan objek (Shorten & Khoshgoftaar, 2019).

Augmentasi data merupakan salah satu solusi yang memungkinkan dalam menghindari terjadinya *overfitting* maupun *underfitting* pada model

arsitektur. Dengan cara ini, model dapat belajar dari variasi yang lebih banyak, yang memungkinkan model untuk menangkap pola yang lebih umum dan tidak terfokus pada detail atau *noise* yang mungkin ada pada data pelatihan. Dalam beberapa penelitian, augmentasi data juga digunakan bersama teknik lain, seperti regularisasi dan *dropout*, untuk lebih jauh mengurangi kemungkinan model terlalu menyesuaikan diri dengan data pelatihan (Perez & Wang, 2017).

2.7 Segmentasi Citra

Segmentasi citra merupakan proses pemisahan citra menjadi bagian-bagian yang memiliki karakteristik serupa, untuk memudahkan model melakukan proses analisis. Seiring perkembangan teknologi, pendekatan berbasis *deep learning* telah menjadi standar baru dalam segmentasi citra medis. Arsitektur seperti U-Net dan variannya telah menunjukkan kinerja yang unggul dalam berbagai tugas segmentasi, termasuk pada citra MRI, CT, dan X-ray. U-Net telah menjadi alat utama dalam tugas segmentasi citra medis karena kemampuannya untuk memberikan segmentasi yang presisi dengan jumlah data pelatihan yang terbatas (Siddique et al., 2020).

2.8 Confusion Matrix

Confusion Matrix adalah alat yang digunakan untuk mengukur kinerja model klasifikasi (Narkhede, 2018). Ada beberapa metode yang paling sering digunakan untuk mengukur skala kinerja klasifikasi. *Matrix* yang paling sering digunakan dalam proses ini yaitu *accuracy*, *precision*, *recall*, dan *F1-Score* (Yildirim & Cinar, 2020). *Confusion Matrix* berbentuk tabel yang terdiri atas informasi mengenai jumlah prediksi dari model yang digunakan. Pada Tabel 3 merupakan contoh yang menunjukkan kategori hasil prediksi *confusion matrix*.

Tabel 3. *Confusion Matrix*

	Prediksi
--	----------

Aktual	Positif	Negatif
Positif	TP	FN
Negatif	FP	TN

Keterangan dari singkatan yang ada pada Tabel 3. di atas:

TP (*True Positive*) = Prediksi positif, aktual positif.

FP (*False Positive*) = Prediksi positif, aktual negatif.

FN (*False Negative*) = Prediksi negatif, aktual positif.

TN (*True Negative*) = Prediksi positif, aktual negatif.

Kinerja suatu model *machine learning* yang direpresentasikan dalam *confusion matrix* dapat dievaluasi menggunakan metrik-metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score*.

2.8.1 Accuracy

Accuracy merupakan salah satu metrik evaluasi yang umum digunakan dalam *machine learning* untuk mengukur proporsi prediksi yang benar dari keseluruhan prediksi (Kucukkara et al., 2022). Secara sistematis, *accuracy* dapat dirumuskan seperti pada Persamaan 5 di bawah ini.

$$Accuracy = \frac{TN + TP}{TP + TN + FP + FN} \dots\dots\dots(5)$$

Meskipun *accuracy* sering digunakan sebagai metrik evaluasi model, namun pada beberapa kasus yang memiliki data yang tidak seimbang *accuracy* dapat memberikan hasil yang *misleading*. *Confusion matrix* menawarkan solusi untuk mengevaluasi kinerja model secara komprehensif dalam situasi seperti ini (Batarseh & Yang, 2020).

2.8.2 Recall

Recall merupakan metrik evaluasi yang mengukur kemampuan model untuk mengidentifikasi semua kasus positif yang sebenarnya. *Recall* dan *false negative* memiliki hubungan terbalik dalam *confusion matrix*. *Recall* yang tinggi mengindikasikan sedikitnya jumlah *false negative* (Sammut & Webb, 2010). Pada Persamaan 6 berikut ini dapat dilihat rumus dari *recall*.

$$Recall = \frac{TP}{TP + FN} \dots\dots\dots(6)$$

2.8.3 Precision

Precision merupakan metrik evaluasi yang mengukur seberapa akurat model dalam memprediksi kelas positif (Monteiro & Soares, 2021). Dalam metrik ini melibatkan *true positive* dan *false positive*. Jika nilai *precision* tinggi, maka *false positive* akan lebih sedikit. Pada Persamaan 7 di bawah ini merupakan rumus dari *precision*.

$$Precision = \frac{TP}{TP + FP} \dots\dots\dots(7)$$

2.8.4 F1-Score

F1-score adalah metrik evaluasi yang menggabungkan *precision* dan *recall* menjadi satu nilai. Hal ini berarti hasil dari *F1-score* akan cenderung rendah jika salah satu dari kedua metrik tersebut rendah. Performa model yang optimal ditunjukkan dengan nilai *F1-score* yang tinggi (Sammut & Webb, 2010). Pada Persamaan 8 di bawah ini dapat dilihat rumus dari *F1-score*.

$$F1-score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \dots\dots\dots(8)$$

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Pada penelitian ini terdapat waktu dan tempat yang telah ditentukan untuk pelaksanaannya. Adapun waktu dan tempat yang digunakan dalam penelitian ini adalah sebagai berikut:

3.1.1 Waktu Penelitian

Penelitian ini dilaksanakan mulai dari bulan Oktober semester ganjil tahun akademik 2024/2025 sampai dengan bulan Mei semester genap tahun akademik 2024/2025.

3.1.2 Tempat Penelitian

Penelitian ini dilaksanakan setiap hari di Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Yang beralamat di Jl. Prof. Dr. Ir. Soemantri Brojonegoro No.1, Gedong Meneng, Kecamatan Rajabasa, Kota Bandar Lampung, Lampung.

3.2 Alat dan Bahan Penelitian

Pada penelitian ini terdapat alat dan bahan yang digunakan. Adapun alat dan bahan yang digunakan pada penelitian ini adalah sebagai berikut.

3.2.1 Alat Penelitian

Alat yang digunakan dalam penelitian ini terbagi menjadi dua jenis yaitu perangkat lunak dan perangkat keras. Alat ini digunakan untuk menunjang setiap tahapan penelitian agar sesuai dengan prosedur penelitian.

a. Perangkat Lunak

Perangkat lunak yang digunakan dalam penelitian ini antara lain adalah sistem operasi *Windows 10 Pro* 64-bit, *Google Colab*, *Google Drive*, Python 3.11.11, *Library Tensorflow* 2.18.0, *Library Numpy* 1.26.4, *Library Matplotlib* 3.10.0, dan *Library Scikit-learn* 1.6.0.

b. Perangkat Keras

Adapun perangkat keras yang digunakan dalam mendukung penelitian ini antara lain adalah Laptop HP EliteBook Folio 9470m, CPU Intel Core i5-3437U CPU 1.90GHz, GPU Intel HD Graphics 4000, RAM 6GB, dan SSD 256GB.


3.2.2 Bahan Penelitian

Penelitian ini menggunakan *dataset* citra CT scan tumor ovarium yang berasal dari *repository* Github sebagai bahannya dengan kelas sebanyak 2 yaitu kelas jinak dan ganas serta masing-masing kelas terdiri atas 100 citra CT scan. *Dataset* yang digunakan didapatkan dari hasil kerjasama dengan SDM College of Medical Sciences and Hospitals, Dharwad, India. *Dataset* yang digunakan dalam penelitian ini merupakan *dataset* yang telah di *cropping*, sehingga penelitian ini tidak menggunakan *dataset* yang melalui proses ekstraksi dan segmentasi area tumor dari citra asli.

3.3 Tahap Penelitian

Adapun tahapan yang dilakukan penelitian ini dimulai dari pengumpulan data, *preprocessing* data, augmentasi data, pembuatan model, dan evaluasi model. Pada

Gambar 7 dapat dilihat alur dari tahap penelitian yang akan dilakukan pada penelitian ini.



Gambar 7. Tahap Penelitian.

3.4 Pengumpulan Data

Pengumpulan data merupakan tahapan pertama dari penelitian ini, *dataset* yang diambil berasal dari repositori Github milik Srirupa Guha. *Dataset* hanya terdiri atas 2 kelas yaitu kelas *Benign* (jinak) dan *Malignant* (ganas), dan masing-masing kelas terdiri atas 100 citra CT *scan* tumor ovarium yang telah di *cropping*, telah di anotasi menggunakan *outline* biru, dan memiliki format (.jpg).

3.5 Pembagian Data

Tahapan selanjutnya adalah pembagian *dataset* yang telah melalui tahapan *preprocessing* menjadi data latih, data validasi, dan data uji. Penelitian ini menggunakan dua skenario pembagian *dataset*, Skenario 1 yaitu berisi 70% data latih, 15% data validasi, dan 15% data uji, serta Skenario 2 yaitu berisi 80% data latih, 10% data validasi, dan 10% data uji. Detail pembagian dan evaluasi hasil pada masing-masing skenario akan dijelaskan lebih lanjut pada bagian hasil dan pembahasan.

a. Data Latih

Data latih merupakan data yang digunakan untuk melatih model, dimana model belajar mengenali pola atau hubungan dalam data berdasarkan *input* yang diberikan. Data ini mencakup mayoritas *dataset* agar model dapat mempelajari berbagai variasi yang ada.

b. Data Validasi

Data validasi digunakan selama proses pelatihan model berlangsung, untuk mengoptimalkan kinerja model, seperti dalam memilih *hyperparameter* yang terbaik dan mencegah *overfitting* selama proses pelatihan.

c. Data Uji

Data uji merupakan bagian dari *dataset* yang digunakan untuk mengevaluasi kinerja dan kemampuan model dalam menggeneralisasi data baru yang tidak pernah dilihat sebelumnya.

3.6 Augmentasi Data

Augmentasi data merupakan salah satu tahap penting dalam penelitian ini, mengingat jumlah *dataset* yang digunakan tergolong terbatas, yaitu hanya terdiri atas dua kelas dengan total 200 citra, yaitu kelas tumor jinak (*Benign*) dan kelas tumor ganas (*Malignant*), masing-masing kelas berjumlah 100 citra. Untuk mengatasi keterbatasan jumlah pada data latih, dilakukan teknik augmentasi data, yaitu metode yang memperbanyak data dengan cara memodifikasi citra asli menggunakan transformasi tertentu tanpa mengubah label kelasnya. Dalam penelitian ini, augmentasi dilakukan dengan pendekatan konvensional

menggunakan berbagai transformasi seperti rotasi, pergeseran posisi, *zoom*, *flipping* horizontal, dan penyesuaian kecerahan. Teknik ini diterapkan secara dinamis selama proses pelatihan model melalui pemanfaatan pustaka ImageDataGenerator dari Keras. Pendekatan ini dipilih karena cukup efektif untuk meningkatkan variasi data tanpa menambah data secara manual.

3.7 Pemilihan Arsitektur Model

Penelitian ini menggunakan arsitektur EfficientNet-B3, yang diimplementasikan melalui *framework* TensorFlow. Secara khusus, varian EfficientNet-B3 dipilih karena mempertimbangkan kapasitas model yang lebih besar dibandingkan EfficientNet-B0, dengan tujuan mengevaluasi apakah peningkatan kompleksitas arsitektur dapat memberikan kinerja klasifikasi yang lebih baik, meskipun jumlah *dataset* yang digunakan pada penelitian ini tergolong terbatas.

Pada penelitian sebelumnya oleh (Guha et al., 2024), model EfficientNet-B0 digunakan untuk klasifikasi tumor ovarium namun hanya menghasilkan akurasi sebesar 72,5% pada *dataset* uji. Berdasarkan hal tersebut, penelitian ini mencoba menggunakan EfficientNet-B3 yang memiliki jumlah parameter dan kedalaman lapisan lebih banyak, serta mendukung resolusi *input* yang lebih tinggi, yaitu 300×300 piksel. Resolusi ini disesuaikan dengan ukuran citra pada *dataset* setelah dilakukan proses *rescaling* dari ukuran aslinya yang bervariasi.

EfficientNet-B3 dirancang dengan pendekatan *compound scaling* yang memungkinkan penyesuaian kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) secara seimbang, sehingga model arsitektur ini dapat belajar mengenai fitur-fitur yang lebih kompleks tanpa memerlukan sumber daya komputasi sebesar varian B5 hingga B7. Untuk memperkuat performa pada data terbatas, pendekatan *transfer learning* digunakan dengan memanfaatkan bobot pralatih dari ImageNet, sehingga proses pelatihan dapat berjalan lebih cepat dan tetap akurat meskipun dengan jumlah data latih yang relatif kecil.

3.8 Training Model

Tahapan selanjutnya adalah *training*, pada tahap ini model akan dilatih menggunakan data latih yang telah di proses sebelumnya untuk memperbarui bobot model agar dapat menghasilkan prediksi yang lebih akurat dengan menambahkan fungsi *loss*. Kemudian gradien *loss* dihitung dan digunakan oleh algoritma optimasi Adam. Proses ini berlangsung secara iteratif selama beberapa *epoch*, dimana setiap *epoch* melibatkan seluruh *batch* data latih. Selama tahapan *training* berlangsung, performa model dipantau menggunakan data validasi untuk memastikan model tidak mengalami *overfitting*. Hasil dari proses pelatihan ini akan menghasilkan model dengan ekstensi file h.5. *Hyperparameter* yang digunakan selama tahapan ini berlangsung antara lain *input size* (sesuai dengan versi EfficientNet-B3 yang digunakan yaitu 300x300 piksel), *batch size* (32), *epoch* (25), *optimizer* (Adam).

3.9 Testing Model

Testing merupakan tahapan yang dilakukan setelah tahapan *training* selesai, tahap ini digunakan untuk mengevaluasi performa model terhadap data uji yang terdiri atas data yang tidak pernah dilihat oleh model selama proses pelatihan berlangsung. Pada proses ini data uji akan diproses melalui lapisan-lapisan model untuk menghasilkan prediksi akhir. Hasil prediksi ini kemudian dibandingkan dengan label sebenarnya menggunakan metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil dari tahapan ini digunakan untuk menyimpulkan keberhasilan model dalam menyelesaikan tugas klasifikasi.

3.10 Evaluasi Model

Tahapan ini dilakukan untuk mengukur kinerja model yang telah dilatih dalam menyelesaikan tugas klasifikasi. Pada tahap ini, model terbaik yang disimpan selama pelatihan (melalui teknik *checkpoint*) di-load, kemudian data uji diproses melalui lapisan-lapisan model untuk menghasilkan prediksi. Pada tahapan ini juga, terdapat metrik akurasi yang digunakan yaitu *Confusion Matrix*. *Confusion Matrix* digunakan untuk memberikan analisis terkait distribusi kesalahan prediksi pada setiap kelas citra medis tumor ovarium.

Hasil evaluasi ini dapat memberikan gambaran menyeluruh tentang kinerja model pada data baru. Jika performa model belum memadai, ini berarti model sering melakukan kesalahan dalam mengklasifikasikan citra, sehingga tingkat keakuratannya rendah dan hasil prediksinya kurang dapat diandalkan. Untuk mengidentifikasi masalah seperti *overfitting*, *underfitting*, atau ketidakseimbangan data, yang mungkin akan mempengaruhi hasil akhir penelitian maka perlu dilakukan perbaikan pada model atau data agar hasil klasifikasi menjadi lebih akurat dan konsisten.

V. SIMPULAN & SARAN

5.1 Simpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa:

1. Model klasifikasi tumor ovarium berbasis *deep learning* yang dikembangkan dalam penelitian ini menggunakan arsitektur EfficientNet-B3 sebagai *backbone*, dengan tambahan beberapa lapisan *Dense* dan *Dropout* untuk *head classifier*. Model ini berhasil melakukan klasifikasi citra medis ke dalam dua kelas, yaitu *Benign* (jinak) dan *Malignant* (ganas), dengan performa yang baik.
2. Model menunjukkan performa yang stabil dan akurat meskipun dengan data terbatas. Pada Skenario 1 (70%, 15%, 15%), model mencapai akurasi 90% dengan F1-score 0.90. Sementara pada Skenario 2 (80%, 10%, 10%), akurasi sedikit lebih rendah yaitu 86% dengan F1-score 0.86. Hal ini mengindikasikan bahwa jumlah data validasi dan uji yang lebih besar pada Skenario 1 membantu mencapai performa yang lebih optimal.
3. Kinerja akhir model dipengaruhi oleh beberapa faktor teknis, antara lain: pemilihan arsitektur EfficientNet-B3 sebagai *feature extractor*, penggunaan bobot kelas (*class weight*) untuk mengatasi ketidakseimbangan data, konfigurasi *hyperparameter* seperti *learning rate*, *batch size*, serta implementasi *callback* seperti *Early Stopping* dan *ReduceLROnPlateau* yang menjaga stabilitas dan efisiensi proses pelatihan.
4. Model ini menghasilkan nilai *recall* yang tinggi untuk kelas *Malignant* (ganas), yaitu 0.93 pada Skenario 1 dan 0.90 pada Skenario 2. Tingginya

recall ini sangat penting dalam konteks medis karena menunjukkan kemampuan model untuk meminimalkan kasus *False Negative* (tumor ganas yang salah dideteksi sebagai jinak). Dengan demikian jika diimplementasikan, model ini dapat membantu tenaga medis untuk mengidentifikasi pasien dengan tumor ganas secara lebih andal, sehingga penanganan atau *treatment* yang diberikan dapat sesuai dengan kondisi atau stadium tumor yang diderita oleh pasien.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, dapat terdapat beberapa saran yang dapat digunakan untuk penelitian serupa kedepannya:

1. **Perluasan *Dataset*:** Disarankan untuk memperluas jumlah dan keragaman *dataset*, baik dari segi variasi citra, resolusi, maupun sumber rumah sakit, guna meningkatkan kemampuan generalisasi model terhadap data dari dunia nyata.
2. **Eksplorasi Arsitektur Lain:** Penelitian selanjutnya dapat mencoba arsitektur *deep learning* lain yang lebih kompleks atau ringan, seperti varian lain dari model yang digunakan dalam penelitian ini seperti EfficientNet-V2, guna membandingkan performa dan efisiensi komputasi.
3. **Penggunaan GAN untuk Augmentasi Data:** Ke depannya, model *Generative Adversarial Network* (GAN) dapat dijadikan alternatif untuk memperluas dan memperkaya data pelatihan. Eksplorasi jenis-jenis GAN seperti Conditional GAN, DCGAN, atau StyleGAN berpotensi menghasilkan citra sintesis yang lebih realistis, sehingga dapat membantu meningkatkan generalisasi model dalam mendeteksi berbagai karakteristik tumor ovarium.
4. **Uji Klinis dan Validasi Nyata:** Sebelum diterapkan dalam dunia medis secara luas, model perlu diuji lebih lanjut melalui uji klinis atau validasi dengan data dunia nyata dari berbagai institusi medis untuk memastikan keandalan dan akurasi sistem dalam konteks klinis.

Dengan mempertimbangkan berbagai aspek yang telah dianalisis, saran-saran di atas diharapkan dapat menjadi landasan pengembangan lebih lanjut dalam penelitian klasifikasi citra medis tumor ovarium kedepannya. Penerapan pendekatan dan teknologi yang lebih optimal di masa mendatang diharapkan mampu meningkatkan akurasi, efisiensi, serta keandalan sistem dalam konteks aplikasi nyata di bidang medis.

DAFTAR PUSTAKA

- Acharya, U. R., Akter, A., Chowriappa, P., Dua, S., Raghavendra, U., Koh, J. E. W., Tan, J. H., Leong, S. S., Vijayananthan, A., Hagiwara, Y., Ramli, M. T., & Ng, K. H. (2018). Use of Nonlinear Features for Automated Characterization of Suspicious Ovarian Tumors Using Ultrasound Images in Fuzzy Forest Framework. *International Journal of Fuzzy Systems*, 20(4), 1385–1402. <https://doi.org/10.1007/s40815-018-0456-9>
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Andre, R., Wahyu, B., & Purbaningtyas, R. (2021). Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur EfficientNet-B3 (*Vol. 11, Issue 3*). <https://jurnal.umj.ac.id/index.php/just-it/index>
- Feras A., & Batarseh Ruixin Yang (Eds.). (2020). *Data Democracy*. Elsevier. <https://doi.org/10.1016/C2018-0-04003-7>
- Guha, S., Kodipalli, A., Fernandes, S. L., & Dasar, S. (2024). Explainable AI for Interpretation of Ovarian Tumor Classification Using Enhanced ResNet50. *Diagnostics*, 14(14). <https://doi.org/10.3390/diagnostics14141567>
- Gunawan, D., & Setiawan, H. (2022). *Convolutional Neural Network dalam Analisis Citra Medis* (Vol. 2, Issue 2).

- Hsu, S.-T., Su, Y.-J., Hung, C.-H., Chen, M.-J., Lu, C.-H., & Kuo, C.-E. (2022). Automatic ovarian tumors recognition system based on ensemble convolutional neural network with ultrasound imaging. *BMC Medical Informatics and Decision Making*, 22(1), 298. <https://doi.org/10.1186/s12911-022-02047-6>
- Ilahiyah, S., & Nilogiri, A. (n.d.). *Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network*.
- Ioffe, S., & Szegedy, C. (2015). *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift*.
- Kucukkara, Z., Ozkan, I. A., & Tasdemir, S. (2022). Identification of Chicken Eimeria Species from Microscopic Images by Using Convolutional Neural Network Method. *Selcuk University Journal of Engineering Sciences*, 21(02), 69–74. <http://sujes.selcuk.edu.tr>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Monteiro, N., & Soares, A. (2021). IRON: uma abordagem inteligente para roteamento em redes ópticas elásticas. *Anais Do XXXIX Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC 2021)*, 308–321. <https://doi.org/10.5753/sbrc.2021.16729>
- Narkhede, S. (2018, May). *Understanding Confusion Matrix*. Medium. <https://medium.com/towards-data-science/understanding-confusion-matrix-a9ad42dcfd62>
- Nengsih, W. (2020). CNN Modelling Untuk Deteksi Wajah Berbasis Gender Menggunakan Python. *Jurnal Komputer Terapan*, 6(2), 190–199. <https://doi.org/10.35143/jkt.v6i2.3679>

- Perez, L., & Wang, J. (2017). *The Effectiveness of Data Augmentation in Image Classification using Deep Learning*. <http://arxiv.org/abs/1712.04621>
- Ramayuda, I. B. G., Mardiyana, L., Erawati, D., & Yuliati, I. (2021). Diagnostic value of abdominal CT scan in ovarian tumors in Dr. Soetomo General Academic Hospital, Surabaya, Indonesia, from January 2017 to December 2018. *Majalah Obstetri & Ginekologi*, 29(2), 45. <https://doi.org/10.20473/mog.v29i22021.45-52>
- Sammut, C., & Webb, G. I. (Eds.). (2010). *Encyclopedia of Machine Learning*. Springer US. <https://doi.org/10.1007/978-0-387-30164-8>
- Shams, B., Wang, Z., Roine, T., Aydogan, D. B., Vajkoczy, P., Lippert, C., Picht, T., & Fekonja, L. S. (2022). Machine learning-based prediction of motor status in glioma patients using diffusion MRI metrics along the corticospinal tract. *Brain Communications*, 4(3). <https://doi.org/10.1093/braincomms/fcac141>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Siddique, N., Sidike, P., Elkin, C., & Devabhaktuni, V. (2020). *U-Net and its variants for medical image segmentation: theory and applications*. <https://doi.org/10.1109/ACCESS.2021.3086020>
- Srivastava, S., Kumar, P., Chaudhry, V., & Singh, A. (2020). Detection of Ovarian Cyst in Ultrasound Images Using Fine-Tuned VGG-16 Deep Learning Network. *SN Computer Science*, 1(2). <https://doi.org/10.1007/s42979-020-0109-6>
- Tan, M., & Le, Q. V. (2019). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*.

- Wu, C., Wang, Y., & Wang, F. (2018). Deep learning for ovarian tumor classification with ultrasound images. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11166 LNCS, 395–406. https://doi.org/10.1007/978-3-030-00764-5_36
- Xavier Ongko, N., Maristella Nadapdap, F., Budi Tarigan, S., Arhamni, A., Sopacua, E., & Artiani, L. (2023).
- Hendrianto et al. Tinjauan pustaka mengenai tumor ovarium. *Buletin Kedokteran Dan Kesehatan Prima*, 2(1). <https://doi.org/10.34012/bkkp.v2i1.4173>
- Yildirim, M., & Cinar, A. (2020). Classification of Alzheimer’s Disease MRI Images with CNN Based Hybrid Method. *Ingénierie Des Systèmes d’Information*, 25(4), 413–418. <https://doi.org/10.18280/isi.250402>