

DISERTASI

**MODEL *MULTICLASS CLASSIFICATION* UNTUK
PENYAKIT BERDASARKAN CITRA *CHEST X-RAY*
PARU-PARU DENGAN *ENSEMBLE LEARNING***

**Diajukan Untuk Memenuhi Salah Satu Syarat Memperoleh Gelar
Doktor Dalam Bidang Ilmu Teknik Informatika**



LUCKY INDRA KESUMA

03013682025015

PROGRAM STUDI ILMU TEKNIK PROGRAM DOKTOR

FAKULTAS TEKNIK

UNIVERSITAS SRIWIJAYA

2023

HALAMAN PENGESAHAN

MODEL *MULTICLASS CLASSIFICATION* UNTUK PENYAKIT BERDASARKAN CITRA *CHEST X-RAY* PARU-PARU DENGAN ENSEMBLE LEARNING

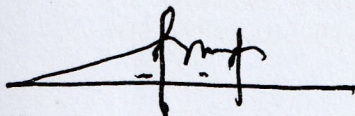
DISERTASI

Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Doktor Dalam Bidang Ilmu Teknik Informatika

Oleh:

LUCKY INDRA KESUMA
03013682025015

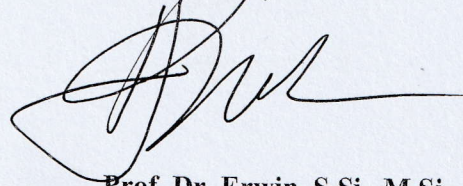
Promotor,



Dr. Ermatita, M.Kom.
NIP. 196709132006042001

Indralaya, Agustus 2023

KoPromotor,



Prof. Dr. Erwin, S.Si., M.Si.
NIP. 197101291994121001

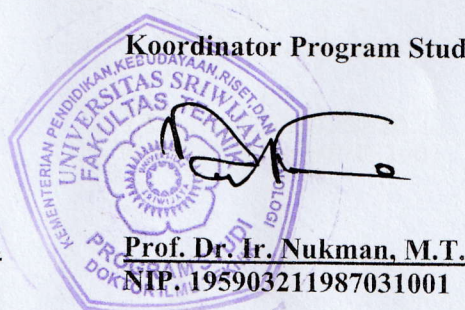
Mengetahui,

Dekan Fakultas Teknik,



Prof. Dr. Ir. H. Joni Arliansyah, M.T.
NIP. 196706151995121002

Koordinator Program Studi,



Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

HALAMAN PERSETUJUAN

Karya tulis ilmiah berupa Disertasi ini dengan judul “Model *Multiclass Classification* untuk Penyakit Berdasarkan Citra *Chest X-Ray* Paru-Paru dengan *Ensemble Learning*” telah dipertahankan dihadapan Tim Penguji Karya Tulis Ilmiah Program Studi Ilmu Teknik Program Doktor Fakultas Teknik Universitas Sriwijaya pada tanggal 10 Agustus 2023.

Palembang, 10 Agustus 2023

Tim Penguji Karya Tulis Ilmiah Berupa Disertasi

Ketua:

Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

()

Anggota:

1. Dr. Shinta Puspasari, S.Si., M.Kom.
NIP. 198204152015042002

()

2. Prof. Dr. Yusuf Hartono, M.Sc.
NIP. 196411161990031002

()

3. Dr. Abdiansah, S.Kom., M.Sc.
NIP. 198410012009121005

()

Mengetahui,

Dekan Fakultas Teknik,



Prof. Dr. Ir. H. Joni Arliansyah, M.T.
NIP. 196706151995121002

Koordinator Program Studi,



Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

RINGKASAN

Model *Multiclass Classification* untuk Penyakit Berdasarkan Citra *Chest X-Ray* Paru-Paru dengan Ensemble Learning

Citra *Chest X-ray* (CXR) dapat mendiagnosis penyakit paru-paru. Namun, diagnosis memerlukan waktu dan ketelitian yang tinggi, sehingga diperlukan sistem yang otomatis. Pada prosesnya, citra CXR terlebih dahulu ditingkatkan kualitas citranya menggunakan Morfologi *Opening* dan *Median filter*, dilanjutkan dengan augmentasi data menggunakan rotasi dan *flipping*. Segmentasi citra CXR menggunakan *U-Net Batch Normalization* dilakukan dengan memisahkan objek paru-paru dengan *background*. Hasil dari proses segmentasi tersebut dilakukan implementasi metode *ensemble learning* terhadap kinerja arsitektur *ResNet*, *EfficientNet*, dan *Inception-v3*. Hasil penelitian menunjukkan keberhasilan dalam meningkatkan kualitas citra CXR menggunakan Morfologi *Opening* dan *Median Filter* dengan rata-rata nilai PSNR sebesar 39,307, MSE sebesar 22,469, dan SSIM sebesar 0,952. Model segmentasi *U-Net Batch Normalization* mencapai akurasi di atas 93% dan nilai *loss* mendekati 1%, menunjukkan kemampuan yang sangat baik dalam mendeteksi paru-paru pada citra CXR. Penerapan *Ensemble Learning* dari *ResNet*, *EfficientNet*, dan *Inception-v3* (ELREI) pada tahap klasifikasi menghasilkan peningkatan yang signifikan dibandingkan dengan metode klasifikasi tunggal. Peningkatan nilai akurasi sebesar 11% (*ResNet*), 3% (*EfficientNet*), dan 1% (*Inception-v3*). Peningkatan nilai presisi adalah 10,5% (*ResNet*), 1% (*EfficientNet*), dan 3% (*Inception-v3*). Sedangkan peningkatan nilai *recall* adalah 10,75% (*ResNet*), 1% (*EfficientNet*), dan 3,25% (*Inception-v3*). Sementara peningkatan nilai *F1-Score* adalah 10,25% (*ResNet*), 3,25% (*EfficientNet*), dan 1% (*Inception-v3*). Rata-rata akurasi, presisi, *recall*, dan *F1-Score* yang dihasilkan oleh metode ELREI adalah 99%, 98,75%, 98,75%, dan 99%. Secara keseluruhan, metode ELREI terbukti kuat dan sangat baik untuk mengklasifikasikan penyakit paru-paru berdasarkan citra CXR, dengan mengelompokkan ke dalam empat kelas: *COVID-19*, normal, *lung opacity*, dan *pneumonia*.

Kata Kunci: Citra *Chest X-ray*, Peningkatan Kualitas Citra, Segmentasi Citra, Klasifikasi Citra, *Ensemble Learning*.

SUMMARY

Multiclass Classification Model for Lung Disease Based on Chest X-Ray Image with Ensemble Learning

Chest X-ray (CXR) images can diagnose lung diseases. However, diagnosis requires time and high accuracy, so an automated system is needed. In the process, the CXR image is first enhanced for image quality using Morphology Opening and Median filter, followed by data augmentation using rotation and flipping. CXR image segmentation using U-Net Batch Normalization is done by separating the lung object from the background. The results of the segmentation process are carried out implementation of the ensemble learning method on the performance of ResNet, EfficientNet, and Inception-v3 architectures. The results successfully improved the quality of CXR images using the morphology opening and Median filter, with an average PSNR value of 39.307, an MSE of 22.469, and an SSIM of 0.952. The U-Net Batch Normalization segmentation model achieved an accuracy of over 93% and a loss value close to 1%, indicating an excellent ability to detect lungs in CXR images. The application of Ensemble Learning from ResNet, EfficientNet, and Inception-v3 (ELREI) in the classification stage resulted in significant improvement compared to the single classification method. The increase in accuracy value is 11% (ResNet), 3% (EfficientNet), and 1% (Inception-v3). The increase in precision value is 10.5% (ResNet), 1% (EfficientNet), and 3% (Inception-v3). The increase in recall value is 10.75% (ResNet), 1% (EfficientNet), and 3.25% (Inception-v3). The increase in F1-Score value is 10.25% (ResNet), 3.25% (EfficientNet), and 1% (Inception-v3). The average accuracy, precision, recall, and F1-Score generated by the ELREI method are 99%, 98.75%, 98.75%, and 99%. Overall, the ELREI method proved to be robust and excellent for classifying lung diseases based on CXR images by categorizing them into four classes: COVID-19, normal, lung opacity, and pneumonia.

Keywords: Chest X-ray Image, Image Quality Enhancement, Image Segmentation, Image Classification, Ensemble Learning.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Puji syukur penulis panjatkan kehadiran Allah SWT, yang telah melimpahkan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan Laporan Disertasi dengan judul “**Model *Multiclass Classification* untuk Penyakit Berdasarkan Citra *Chest X-ray* Paru-Paru Dengan *Ensemble Learning*”**”.

Ucapan terima kasih penulis sampaikan pada pihak-pihak yang telah membantu penyusunan laporan ini, terkhusus kepada:

1. Kedua orang tua tercinta.
2. Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi atas Hibah Penelitian Dosen Pemula 2022 melalui Universitas Sriwijaya dengan Nomor kontrak.
3. Prof. Dr. Ir. H. Anis Saggaff, MSCE, IPU, Aseng. Eng. selaku Rektor Universitas Sriwijaya.
4. Prof. Dr. Ir. H. Joni Arliansyah, M.T. selaku Dekan Fakultas Teknik Universitas Sriwijaya.
5. Prof. Dr. Ir. Nukman, M.T., selaku Koordinator Program Studi Ilmu Teknik Program Doktor, Fakultas Teknik, Universitas Sriwijaya.
6. Dr. Ermatita, M.Kom., selaku Promotor yang telah memberikan bimbingan dan arahan dalam penyelesaian disertasi ini.
7. Prof. Dr. Erwin, S.Si., M.Si., selaku Ko-Promotor yang telah memberikan arahan dalam penyelesaian disertasi ini.
8. Prof. Dr. Ir. Nukman, M.T., Dr. Yusuf Hartono, M.Sc, dan Dr. Abdiansah, S.Kom., M.Sc. selaku Tim Penguji yang telah memberikan saran untuk peningkatan kualitas disertasi ini.
9. Rektor Universitas Sjakhyakirti Palembang, Prof. Dr. Ir. Agoes Thony Ak, M.Si. atas dukungannya.
10. Sahabat dan semua pihak bagian dari *support system* penelitian disertasi ini yang tidak dapat disebutkan satu per satu.

Semoga penelitian disertasi ini menghasilkan ilmu bermanfaat yang diberkahi Allah SWT dan menjadi amal jariah bagi kita semua. Aamiin.

Wassalamu 'alaikum warahmatullahi wabarakatuh.

Palembang, Juli 2023

Penulis

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERSETUJUAN	iii
RINGKASAN	iv
SUMMARY	v
KATA PENGANTAR	vi
DAFTAR ISI	viii
DAFTAR TABEL	xi
DAFTAR GAMBAR	xii
DAFTAR LAMPIRAN	xiv
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Perumusan Masalah	6
1.3. Tujuan	6
1.4. Manfaat	7
1.5. Batasan Masalah.....	7
1.6. Ruang Lingkup Penelitian.....	7
1.7. Sistematika Penulisan.....	9
BAB II TINJAUAN PUSTAKA	10
2.1. <i>Roadmap</i> Penelitian	10
2.2. Penyakit Menular	10
2.3. Citra Digital.....	11
2.4. Citra <i>Chest X-ray</i>	12
2.5. Perbaikan Kualitas Citra	12
2.5.1. Morfologi <i>Opening</i>	13
2.5.2. <i>Median Filter</i>	13
2.5.3. <i>Mean Square Error</i>	14
2.5.4. <i>Peak Signal-to-Noise Ratio</i>	14
2.5.5. <i>Structural Similarity Index Metrics</i>	15
2.6. Augmentasi Data	16

2.7.	Segmentasi Citra	16
2.8.	Klasifikasi Citra	16
2.9.	<i>Convolutional Neural Network (CNN)</i>	17
2.9.1.	<i>Convolution Layer</i>	17
2.9.2.	<i>Batch Normalization</i>	19
2.9.3.	Fungsi Aktivasi.....	20
2.9.4.	<i>Pooling Layer</i>	21
2.9.5.	<i>Transposed Convolution</i>	23
2.9.6.	<i>Concatenate Layer</i>	24
2.9.7.	<i>Depthwise Separable Convolution</i>	24
2.9.8.	<i>Dense Layer</i>	25
2.9.9.	<i>Dropout</i>	26
2.9.10.	<i>Loss Function</i>	26
2.10.	<i>U-Net</i>	27
2.11.	<i>Residual Network</i>	28
2.12.	<i>EfficientNet</i>	29
2.13.	<i>Inception-v3</i>	30
2.14.	<i>Ensemble Learning</i>	31
2.15.	<i>Confusion Matrix</i>	32
2.16.	<i>State of the Art</i>	34
BAB III METODOLOGI PENELITIAN		41
3.1.	Tempat Penelitian.....	41
3.2.	Waktu Penelitian	41
3.3.	Alat.....	41
3.4.	Objek Penelitian	41
3.5.	Pengumpulan Data	41
3.6.	Kerangka Kerja Penelitian	42
3.5.1.	Peningkatan Kualitas Citra	43
3.5.2.	Augmentasi Data	44
3.5.3.	Segmentasi Citra.....	45
3.5.4.	Klasifikasi Citra.....	47

3.5.4.1. <i>Training</i> Menggunakan Arsitektur <i>ResNet</i>	48
3.5.4.2. <i>Training</i> Menggunakan Arsitektur <i>EfficientNet</i>	50
3.5.4.3. <i>Training</i> Menggunakan Arsitektur <i>Inception-v3</i>	52
3.5.4.4. <i>Training</i> Menggunakan <i>Ensemble Learning</i>	54
3.5.4.5. <i>Testing</i> pada Klasifikasi Citra	55
3.5.4.6. Evaluasi Kinerja Klasifikasi Citra.....	56
BAB IV HASIL DAN PEMBAHASAN	57
4.1. Deskripsi Data	57
4.2. Peningkatan Kualitas Citra CXR	58
4.3. Augmentasi Data pada Citra CXR	62
4.4. Segmentasi Citra CXR	64
4.5. Klasifikasi Citra CXR	66
4.5.1. <i>Training</i> Klasifikasi Citra CXR Menggunakan <i>ResNet</i>	66
4.5.2. <i>Training</i> Klasifikasi Citra CXR Menggunakan <i>EfficientNet</i> .	68
4.5.3. <i>Training</i> Klasifikasi Citra CXR Menggunakan <i>Inception-v3</i>	70
4.5.4. <i>Training</i> Klasifikasi Citra CXR Menggunakan ELREI	72
4.5.5. <i>Testing</i> pada Klasifikasi Citra CXR	74
4.5.6. Evaluasi Kinerja pada Klasifikasi Citra CXR	75
4.6. Analisis dan Interpretasi Hasil	76
BAB V PENUTUP.....	78
5.1. Kesimpulan	78
5.2. Saran.....	79
DAFTAR PUSTAKA	80
LAMPIRAN.....	91

DAFTAR TABEL

Tabel 2.1. <i>Confusion matrix</i> untuk segmentasi paru-paru pada citra CXR	32
Tabel 2.2. <i>Confusion matrix</i> multikelas untuk klasifikasi penyakit <i>COVID-19</i> ...	32
Tabel 2.3. Kategori nilai kinerja arsitektur	34
Tabel 2.4. Beberapa penelitian terdahulu yang telah melakukan peningkatan kualitas citra.....	36
Tabel 2.5. Beberapa penelitian terdahulu yang telah melakukan segmentasi dan klasifikasi citra.....	37
Tabel 4.1. Perbandingan hasil peningkatan citra CXR	59
Tabel 4.2. Perbandingan Hasil Evaluasi Kinerja pada Metode <i>Median Filter</i>	61
Tabel 4.3. Perbandingan Hasil Evaluasi Penelitian ini dengan Penelitian Lain ...	61
Tabel 4.4. Perbandingan Hasil Evaluasi Kinerja Menggunakan Metode ELREI.	75
Tabel 4.5. Perbandingan Hasil Evaluasi Penelitian ini dengan Penelitian Lain ...	76

DAFTAR GAMBAR

Gambar 2.1. <i>Roadmap</i> Penelitian Tahun 2019-2023	10
Gambar 2.2. Proses operasi konvolusi	18
Gambar 2.3. Grafik fungsi aktivasi <i>ReLU</i> dan <i>sigmoid</i>	21
Gambar 2.4. Ilustrasi proses <i>max pooling</i> 2×2	22
Gambar 2.5. Ilustrasi proses <i>average pooling</i> 2×2 dan <i>stride 2</i>	22
Gambar 2.6. Ilustrasi <i>transposed convolution</i> 2×2 dan <i>stride 2</i>	23
Gambar 2.7. Proses <i>depthwise separabel convolution</i> (a) <i>depthwise convolution</i> (b) <i>pointwise convolution</i>	24
Gambar 2.8. Ilustrasi arsitektur <i>U-Net</i>	27
Gambar 2.9. Ilustrasi arsitektur <i>ResNet</i>	29
Gambar 2.10. Ilustrasi arsitektur <i>EfficientNet</i>	30
Gambar 2.11. Ilustrasi arsitektur <i>Inception-v3</i>	31
Gambar 3.1. Kerangka kerja penelitian	42
Gambar 3.2. Tahapan Peningkatan Kualitas Citra	43
Gambar 3.3. Tahapan Augmentasi Data	44
Gambar 3.4. Tahapan Segmentasi Citra	45
Gambar 3.5. Tahapan Klasifikasi Citra	48
Gambar 4.1. Contoh Citra CXR Paru-paru (a) <i>COVID-19</i> (b) Normal (c) <i>Lung</i> <i>Opacity</i> (d) <i>Pneumonia</i>	57
Gambar 4.2. Perbandingan Grafik Nilai Evaluasi Peningkatan Kualitas Citra CXR (a) <i>COVID-19</i> (b) Normal (c) <i>Lung Opacity</i> (d) <i>Pneumonia</i>	60
Gambar 4.3. Hasil Augmentasi Data Menggunakan Transformasi Rotasi	62
Gambar 4.4. Perbandingan Jumlah Data Antara Sebelum Augmentasi Data dan Sesudah Augmentasi Data	63
Gambar 4.5. Arsitektur <i>U-Net</i> pada Citra CXR	64

Gambar 4.6. Grafik <i>Training</i> Segmentasi Citra CXR (a) Akurasi (b) <i>Loss</i>	65
Gambar 4.7. Hasil Segmentasi Citra CXR Paru-paru Menggunakan <i>U-Net Batch Normalization</i>	65
Gambar 4.8. Arsitektur <i>ResNet</i> pada Klasifikasi Citra CXR	66
Gambar 4.9. Grafik <i>Training</i> Klasifikasi Citra CXR Menggunakan Arsitektur <i>ResNet</i> (a) Akurasi (b) <i>Loss</i>	67
Gambar 4.10. Arsitektur <i>EfficientNet</i> pada Klasifikasi Citra CXR	68
Gambar 4.11. Grafik <i>Training</i> Klasifikasi Citra CXR Menggunakan Arsitektur <i>EfficientNet</i> (a) Akurasi (b) <i>Loss</i>	69
Gambar 4.12. Arsitektur <i>Inception-v3</i> pada Klasifikasi Citra CXR	70
Gambar 4.13. Grafik <i>Training</i> Klasifikasi Citra CXR Menggunakan Arsitektur <i>Inception-v3</i> (a) Akurasi (b) <i>Loss</i>	71
Gambar 4.14. Proses ELREI pada Klasifikasi Citra CXR.....	72
Gambar 4.15. Grafik <i>Training</i> Klasifikasi Citra CXR Menggunakan Metode ELREI (a) Akurasi (b) <i>Loss</i>	73
Gambar 4.16. Perbandingan Evaluasi Kinerja pada Proses Klasifikasi Citra CXR Menggunakan <i>ResNet</i> , <i>EfficientNet</i> , <i>Inception-v3</i> , dan ELREI.....	74

DAFTAR LAMPIRAN

Lampiran 1. Bukti Accepted ICIMCIS	91
Lampiran 2. Bukti Accepted Jurnal IJIES.....	92

BAB I

PENDAHULUAN

1.1. Latar Belakang

Penyakit *COVID-19* adalah salah satu penyakit menular pada saluran pernapasan yang disebabkan oleh virus bernama *Severe Acute Respiratory Syndrome Coronavirus 2 (SARS-CoV-2)*, dimana virus ini pertama kali dilaporkan di kota Wuhan, China pada bulan Desember 2019 [1]. Selama ini, untuk mendiagnosa penyakit *COVID-19* dilakukan dengan menggunakan tes *Reverse Transcription Polymerase Chain Reaction (RT-PCR)* [2]. Namun, tes tersebut memiliki kelemahan yaitu rumah sakit yang memiliki fasilitas RT-PCR terbatas, dan biaya yang dikeluarkan untuk tes tersebut cukup mahal [3]. Hal tersebut membuat para peneliti menemukan alternatif lain yang lebih baru dan mudah untuk mendiagnosa penyakit *COVID-19*, salah satunya yaitu melalui *Chest X-Ray (CXR)*. Menurut Song et al [4] gambar hasil pemeriksaan CXR dinilai cukup efektif dalam mendiagnosa penyakit *COVID-19*, karena melalui hasil pemeriksaan tersebut tenaga medis dapat melihat kelainan yang ada pada paru-paru pasien. Dalam melakukan pembacaan hasil citra CXR, diperlukan tingkat ketelitian yang tinggi, dikarenakan banyak jaringan yang bertumpuk pada citra tersebut [5]. Untuk membantu dokter dan ahli radiologi agar lebih jelas dalam membaca hasil citra CXR, maka diperlukanlah suatu peningkatan kualitas citra agar mendapatkan hasil kualitas citra yang lebih baik lagi dan lebih jelas dibaca sehingga menghasilkan diagnosis yang akurat [5].

Peningkatan kualitas citra merupakan proses mengubah citra asli menjadi citra baru sesuai dengan yang dibutuhkan untuk menghasilkan citra yang lebih jelas dan tajam [6]. Metode peningkatan kualitas citra yang berkembang saat ini ialah perbaikan kontur dan pengurangan *noise*. Salah satu metode yang dapat digunakan untuk perbaikan kontur adalah Morfologi *Opening* [7]. Morfologi *Opening* bekerja dengan menghilangkan objek tipis dan halus agar gambar menjadi lebih halus [8]. Sementara metode yang paling sering digunakan dalam meningkatkan kualitas citra

untuk mengurangi *noise* adalah metode *Filtering*. Metode *Filtering* adalah teknik *filtering* yang digunakan untuk menghilangkan atau mengurangi *noise*. Salah satu metode *filtering* yang sering digunakan saat ini adalah *Median Filter* [9]. *Median Filter* memiliki kemampuan untuk meredam *noise* dengan baik [10]. Selain peningkatan kualitas citra, umumnya citra CXR juga terkendala oleh data yang terbatas. Untuk mengatasi masalah ini, augmentasi data dapat diterapkan untuk meningkatkan jumlah dan keragaman data [11], [12]. Augmentasi data adalah suatu teknik pengolahan data citra yang mengubah citra menjadi data yang baru tanpa menghilangkan ataupun mengubah inti dari citra [13]. Augmentasi akan memperbanyak data dari kelas yang kurang terwakili sehingga membuat dataset menjadi seimbang kelasnya [11]. Augmentasi data yang sering digunakan yaitu rotasi dan *flipping*. Augmentasi rotasi dilakukan dengan memutar citra ke kanan atau ke kiri sesuai dengan derajat yang dipilih, sedangkan *flipping* dilakukan dengan membalikkan citra ke arah vertikal atau horizontal [12].

Penentuan hasil diagnosa melalui CXR membutuhkan waktu yang cukup lama dan ketelitian yang tinggi, sehingga diperlukan suatu sistem otomatis untuk mempermudah tenaga medis dalam mendiagnosa penyakit *COVID-19* secara cepat dan akurat [14]. Segmentasi merupakan salah satu sistem otomatis dalam pengolahan citra yang dilakukan dengan membagi citra menjadi beberapa wilayah atau bagian sesuai dengan karakteristiknya [15]. Proses segmentasi pada citra CXR dilakukan dengan mengambil bagian paru-parunya saja, sedangkan untuk bagian lainnya seperti tulang dada, jantung, dan yang lainnya akan dijadikan sebagai *background* [16].

Saat ini berkembang metode yang handal dalam segmentasi citra yaitu *Convolutional Neural Network* (CNN) [13]. Kemampuan utama CNN terletak pada arsitekturnya, dimana arsitektur yang sering digunakan dalam segmentasi citra adalah *U-Net* [17]. *U-Net* sangat efektif digunakan untuk segmentasi citra berbasis piksel. Kelemahan arsitektur ini selama proses pelatihan sering terjadi perubahan input untuk setiap lapisannya [18]. Input-input setiap lapisan bergantung pada jumlah parameter di lapisan sebelumnya, sehingga membuat terjadinya perubahan distribusi fitur input [19]. Hal ini menyebabkan penurunan kecepatan pelatihan dan

kinerja [18], [19]. Untuk mengatasi masalah perubahan distribusi fitur input tersebut dapat digunakan metode *Batch Normalization* (BN) [19], [20]. BN merupakan metode normalisasi yang banyak digunakan untuk segmentasi biomedis [19]. BN akan menormalkan peta fitur disemua lapisan arsitektur dengan melakukan skala ulang dan menerjemahkan ulang peta fitur yang dinormalisasi[20]. Modifikasi *U-Net* dengan menambahkan lapisan BN telah dilakukan oleh beberapa penelitian. Salah satunya Aboelenein et al [21] mengusulkan arsitektur *U-Net* dengan menambahkan lapisan *Batch Normalization* pada segmentasi tumor otak menghasilkan nilai rata-rata *F-I Score* 86%. Penelitian lainnya oleh Liu et al [22] mengusulkan arsitektur DCNN *U-Net* dengan penambahan *Batch Normalization* menghasilkan nilai *F-I Score* 83% dan 84%, Akurasi 92% dan 93%. Dari kedua penelitian diatas terlihat bahwa dengan menggabungkan arsitektur *U-Net* dan BN pada proses segmentasi citra dapat menjadi salah satu alternatif untuk medeteksi kelainan paru-paru pada CXR.

Selain segmentasi, metode CNN paling banyak dimanfaatkan untuk klasifikasi citra. Dalam CNN terdapat banyak arsitektur yang dapat diterapkan untuk pengenalan pola suatu citra. Performa kinerja arsitektur pada CNN dapat ditingkatkan dengan menambahkan lapisan [23]. Namun penambahan lapisan pada arsitektur CNN dapat mengakibatkan kompleksitas lapisan semakin meningkat dan *gradient vanishing* [24]. Untuk mengatasi tersebut dapat digunakan arsitektur *ResNet* [23], [24]. *ResNet* menggunakan *skip connection* di lapisannya untuk menangani masalah *gradient vanishing*. *Skip Connection* dapat mempercepat konvergensi jaringan di *ResNet*. Keunggulan *ResNet* adalah performanya tidak menurun walaupun arsitekturnya semakin dalam. Selain itu, *ResNet* juga memiliki kompleksitas jaringan yang lebih rendah dibandingkan dengan arsitektur CNN lainnya [25]. Beberapa penelitian telah menunjukkan keberhasilannya dalam mengklasifikasikan *COVID-19* menggunakan citra CXR [26], [27]. Penelitian oleh Keles at al. [26] menggunakan *ResNet* untuk mengklasifikasikan *COVID-19*, yang menghasilkan nilai akurasi, *recall*, dan *F1-score* di atas 90%. Sayangnya, penelitian ini tidak menghitung nilai presisinya. Penelitian oleh Karhan and Akal [27] menggunakan *ResNet-50* untuk mengklasifikasikan *COVID-19*. Hasil penelitian

menunjukkan nilai akurasi diatas 90%. Namun penelitian ini tidak menghitung *recall*, presisi, dan *F1-score*. Kelemahan arsitektur *ResNet* adalah sulitnya mendeteksi kesalahan karena lapisan yang dalam [28].

Arsitektur CNN lain yang dapat digunakan untuk klasifikasi citra adalah *EfficientNet*. Arsitektur *EfficientNet* memiliki keunggulan karena mampu menskalakan dimensi seperti kedalaman, lebar, dan resolusi dalam lapisan secara seragam. Penskalaan di *EfficientNet* dilakukan dengan menggunakan kombinasi koefisien yang sederhana dan efektif [29]. Selain itu, *EfficientNet* menghasilkan akurasi klasifikasi yang lebih tinggi daripada arsitektur CNN lainnya [30]. Penelitian oleh Ali et al. [28] menggunakan *EfficientNet-B4* untuk mencapai akurasi dan nilai *F1-Score* di atas 86% untuk klasifikasi citra kanker tetapi tidak mengukur *recall* dan presisi. Penelitian oleh Chen et al. [31] menerapkan *EfficientNet* untuk klasifikasi citra kolposkopi, mencapai skor akurasi lebih dari 90%, tetapi tidak mengukur kinerja lainnya. Kelemahan dari *EfficientNet* adalah memiliki kompleksitas jaringan yang besar, yang dapat menyebabkan hasil pelatihan arsitektur menjadi *overfitting*.

Salah satu arsitektur CNN lainnya yang dapat mengatasi *overfitting* adalah *Inception-v3*. Arsitektur *Inception-v3* merupakan arsitektur yang sering digunakan pada proses klasifikasi citra [32]. Arsitektur *Inception-v3* menggunakan konvolusi kecil yang menumpuk, sehingga jumlah lapisan menjadi lebih kompleks tetapi tanpa menyebabkan masalah *overfitting* [33]. Beberapa penelitian telah berhasil melakukan klasifikasi menggunakan *Inception-v3* [21], [22]. Penelitian oleh Sharma [34] berhasil menerapkan *InceptionNet* pada klasifikasi *COVID-19* dengan akurasi di atas 90% tetapi tidak mengukur performa lainnya. Penelitian oleh Mujahid et al. [35] berhasil menerapkan *InceptionNet* pada klasifikasi *COVID-19* dengan nilai akurasi, presisi, dan *recall* yang masih terbilang rendah. Kelemahan dari *Inception-v3* adalah waktu komputasi yang lama karena menggunakan fitur konvolusi yang lebih mendalam [36].

Dalam klasifikasi citra, setiap arsitektur CNN pasti memiliki kelebihan dan kekurangan. Hasil kinerja dari masing-masing metode klasifikasi dapat dimaksimalkan dengan menggunakan metode *ensemble learning*. *Ensemble*

learning adalah metode yang dapat menggabungkan hasil klasifikasi dari berbagai arsitektur atau metode klasifikasi tunggal menjadi model baru yang lebih akurat [37]. Keuntungan *ensemble learning* adalah dapat mengambil informasi dari beberapa metode klasifikasi dan meminimalkan tingkat kesalahan klasifikasi tunggal. Beberapa teknik pengambilan keputusan dalam *ensemble learning* sudah tepat dan efisien, seperti *bagging*, *stacking*, *boosting*, *voting*, dan *averaging* [38]. *Voting* adalah teknik pengambilan keputusan yang populer di *Ensemble* [38], [39]. Salah satu teknik *voting* yang sering digunakan adalah *weighted voting*. *Weighted voting* memberikan bobot yang berbeda untuk pengklasifikasi berdasarkan kriteria tertentu dan memilih pengklasifikasi berdasarkan bobot ini [38].

Beberapa penelitian telah menggunakan *ensemble learning* dengan teknik *weighted voting* untuk klasifikasi *COVID-19*. Penelitian oleh Das et al [40] menggunakan teknik *weighted voting* untuk menerapkan *ensemble learning* dari *DenseNet-201*, *ResNet-50*, dan *Inception-v3*, namun akurasi yang diperoleh di bawah 95% dan tidak mengukur kinerja presisi. Penelitian lainnya oleh Siddiquie et al [41] menggunakan teknik *weighted voting* untuk menerapkan *ensemble learning* kelima arsitektur CNN: *Inception*, *ResNet-v2*, *Inception-v3*, *DenseNet121*, dan *Xception*. Sayangnya, *recall* pada penelitian ini masih di bawah 90%. Penelitian oleh Zhuo et al. [42] menerapkan *ensemble learning* dengan *weighted majority vote* dari *AlexNet*, *GoogleNet*, dan *ResNet*. Akurasi yang diperoleh dari penelitian ini sangat baik yaitu 99%, namun tidak mengukur kinerja *recall*. Penelitian oleh Kundu et al. [43] mengimplementasikan *ensemble learning* dari *GoogLeNet*, *ResNet-18*, dan *DenseNet-121* dengan *weighted voting*, tetapi hasil performa untuk akurasi, *recall*, dan *F1-score* masih di bawah 90%. Penelitian-penelitian ini hanya mengumpulkan hasil akhir pada klasifikasi tunggal mana pun untuk digunakan dalam data uji. Metode *ensemble* dari penelitian tersebut tidak berjalan dalam proses *training*, sehingga tidak dapat diketahui bagaimana kinerja metode *ensemble* pada data latih dan data validasi. Metode *ensemble* dari penelitian tersebut tidak menjamin apakah bobot yang diperoleh dari hasil *ensemble* tidak *overfitting*.

Pada penelitian ini akan melakukan peningkatan kualitas citra menggunakan Morfologi *Opening* dan *Median Filter* untuk mendapatkan kualitas citra yang lebih

baik. Selanjutnya dilakukan augmentasi data yang sesuai untuk memperbanyak jumlah data citra CXR. Pada tahap segmentasi penelitian ini akan menggabungkan arsitektur *U-Net* dan BN, sehingga dapat menjadi salah satu alternatif metode untuk segmentasi citra medis. Selain itu juga, dalam penelitian ini mengusulkan metode *ensemble learning* baru yang menggabungkan hasil *ResNet*, *EfficientNet*, dan *Inception-v3* yang disebut ELREI (*Ensemble Learning* dari *ResNet*, *EfficientNet*, dan *Inception-v3*) dengan *weighted voting* untuk klasifikasi penyakit paru-paru berdasarkan citra CXR. Berbeda dengan metode *ensemble* pada penelitian lain. Metode ELREI bekerja pada setiap *epoch* pada tahap *training*, bukan pada hasil akhir *training*, sehingga bobot hasil ELREI pada setiap *epoch* pada data *training* dan data validasi dapat dicek pada hasil performa untuk menangani *overfitting*. Untuk mengevaluasi kinerja dari metode yang diusulkan pada tahap segmentasi dan klasifikasi dilakukan dengan menghitung performa kinerja berdasarkan akurasi, presisi, *recall*, dan *F1-Score*.

1.2. Perumusan Masalah

1. Bagaimana meningkatkan kualitas citra pada dataset citra CXR yang memiliki kontras gelap dan terdapat *noise* dengan menggunakan metode *Morfologi Opening* dan *Median Filter*?
2. Bagaimana memodifikasi arsitektur *U-Net* agar dapat meningkatkan keakuratan segmentasi citra CXR paru-paru?
3. Bagaimana menerapkan metode *ensemble learning* pada arsitektur *ResNet*, *EfficientNet*, dan *Inception-v3* untuk meningkatkan hasil evaluasi pada klasifikasi penyakit *COVID-19*?

1.3. Tujuan

1. Untuk mengetahui perbandingan citra asli dan hasil peningkatan kualitas citra menggunakan metode *Morfologi Opening* dan *Median Filter* pada citra CXR.
2. Untuk mengetahui hasil segmentasi paru-paru dan evaluasi kinerja menggunakan modifikasi arsitektur *U-Net* pada citra CXR.

3. Untuk mengetahui hasil evaluasi kinerja dari penerapan metode *ensemble learning* menggunakan arsitektur *ResNet*, *EfficientNet*, dan *InceptionV3*, pada klasifikasi penyakit *COVID-19*.

1.4. Manfaat

1. Memperoleh hasil segmentasi paru-paru pada citra CXR yang lebih akurat dengan menggunakan arsitektur *U-Net*.
2. Memperoleh model klasifikasi penyakit *COVID-19* yang lebih akurat melalui penerapan *ensemble learning* menggunakan arsitektur *ResNet*, *EfficientNet* dan *Inception-v3*.
3. Membantu tenaga medis untuk mendiagnosis penyakit *COVID-19* melalui penggunaan citra CXR paru-paru yang lebih efisien dan akurat.
4. Dapat digunakan sebagai rujukan bagi pihak yang akan melakukan penelitian mengenai klasifikasi penyakit *COVID-19*.

1.5. Batasan Masalah

Penelitian ini hanya melakukan klasifikasi penyakit menular pada citra CXR kedalam empat label, yaitu *COVID-19*, normal, *lung opacity* dan *pneumonia*. Selain itu, ukuran kinerja yang digunakan pada penelitian ini berdasarkan nilai akurasi, presisi, *recall*, dan *F-1 Score*.

1.6. Ruang Lingkup Penelitian

1. Objek Penelitian

Penelitian ini berfokus pada penggunaan teknik *ensemble learning*, yaitu menggabungkan beberapa model *deep learning* dengan arsitektur yang berbeda, untuk meningkatkan kinerja pada klasifikasi penyakit paru-paru. Ketiga arsitektur *deep learning* yang digunakan, yaitu *ResNet*, *EfficientNet*, dan *Inception-v3*. Citra CXR digunakan sebagai *input* untuk model *ensemble* ini. Citra-citra ini kemudian diproses oleh masing-masing arsitektur (*ResNet*, *EfficientNet*, dan *Inception-v3*) untuk menghasilkan klasifikasi terkait penyakit paru-paru yang ada. Selanjutnya, *output* dari ketiga model ini

digabungkan melalui teknik *ensemble learning* dengan *weighted voting* untuk menghasilkan klasifikasi akhir yang lebih akurat.

2. Metode Penelitian

Langkah-langkah yang akan dilakukan pada penelitian ini sebagai berikut:

- Pengumpulan Data

Data ini terdiri dari empat kelas: 3.616 citra *COVID-19*, 10.192 citra normal, 6.012 citra *lung opacity*, dan 1.345 citra *pneumonia*.

- Peningkatan Kualitas Citra

Citra CXR dilakukan perbaikan kontur menggunakan Morfologi *Opening* dan pengurangan *noise* menggunakan *Median Filter*.

- Augmentasi Data

Citra hasil peningkatan kualitas citra selanjutnya dilakukan augmentasi data dengan metode rotasi dan *flipping* untuk meningkatkan jumlah data latih.

- Segmentasi Citra

Tahap berikutnya adalah segmentasi citra, di mana dilakukan segmentasi paru-paru pada citra CXR menggunakan modifikasi arsitektur *U-Net Batch Normalization*.

- Klasifikasi Citra

Setelah itu, dilakukan klasifikasi citra dengan menggunakan tiga metode klasifikasi: *ResNet*, *EfficientNet*, dan *Inception-v3*. Selanjutnya dilakukan klasifikasi menggunakan metode *ensemble learning* dari ketiga model tersebut (ELREI) dengan *weighted voting*. Proses *weighted voting* dilakukan pada setiap *epoch* di tahap *training*, bukan pada hasil akhir setiap arsitektur.

3. Evaluasi Kinerja

Pada tahap evaluasi, dilakukan perbandingan hasil kinerja klasifikasi metode tunggal (*ResNet*, *EfficientNet*, dan *Inception-v3*) dengan metode *ensemble learning* ELREI menggunakan metrik performa model seperti akurasi, presisi, *recall*, dan *F1-Score*.

1.7. Sistematika Penulisan

Untuk memudahkan dalam menyusun disertasi dan memperjelas isi dari setiap bab yang ada pada proposal ini, maka dibuatlah sistematika penulisan yaitu:

BAB 1 Pendahuluan

Bab ini berisi tentang latar belakang, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, ruang lingkup penelitian, dan sistematika penulisan penelitian.

BAB 2 Tinjauan Pustaka

Bab ini menjelaskan tentang landasan-landasan teori yang berkaitan dengan proses pengolahan citra CXR (peningkatan kualitas citra, augmentasi data, segmentasi citra, klasifikasi citra), serta literatur terkait yang relevan dengan topik yang diteliti.

BAB 3 Metodologi Penelitian

Bab ini menjelaskan secara rinci tentang langkah-langkah penyelesaian penelitian yang terdiri dari beberapa tahapan pengolahan citra (peningkatan kualitas citra, augmentasi data, segmentasi citra, klasifikasi citra), termasuk alat dan dataset yang digunakan.

BAB 4 Hasil dan Pembahasan

Bab ini berisi tentang hasil penelitian dan evaluasi performa peningkatan kualitas citra, segmentasi citra, dan klasifikasi citra, termasuk analisis dan interpretasi hasilnya.

BAB 5 Penutup

Bab ini menyajikan kesimpulan secara singkat dan saran untuk penelitian lanjutan.

DAFTAR PUSTAKA

- [1] N. Zhu *et al.*, “A Novel Coronavirus from Patients with Pneumonia in China, 2019,” *N. Engl. J. Med.*, vol. 382, no. 8, pp. 727–733, 2020, doi: 10.1056/nejmoa2001017.
- [2] X. Xu *et al.*, “A Deep Learning System to Screen Novel Coronavirus Disease 2019 Pneumonia,” *Engineering*, vol. 6, no. 10, pp. 1122–1129, 2020, doi: 10.1016/j.eng.2020.04.010.
- [3] H. Munusamy, J. M. Karthikeyan, G. Shriram, S. Thanga Revathi, and S. Aravindkumar, “FractalCovNet architecture for COVID-19 Chest X-ray image Classification and CT-scan image Segmentation,” *Biocybern. Biomed. Eng.*, vol. 41, no. 3, pp. 1025–1038, 2021, doi: 10.1016/j.bbe.2021.06.011.
- [4] F. Song *et al.*, “Emerging Coronavirus 2019-nCoV Pneumonia.,” *Radiology*, 2019.
- [5] T. Tinaliah and T. Elizabeth, “Peningkatan Kualitas Citra X-Ray Paru-Paru Pasien Covid-19 Menggunakan Metode Contrast Limited Adaptive Histogram Equalization,” *J. Teknol. Inf.*, vol. 4, no. 2, pp. 345–349, 2020, doi: 10.36294/jurti.v4i2.1709.
- [6] S. S. Sumijan, A. W. Purnama, and S. Arlis, “Peningkatan Kualitas Citra CT-Scan dengan Penggabungan Metode Filter Gaussian dan Filter Median,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 6, p. 591, 2019, doi: 10.25126/jtiik.201966870.
- [7] A. Desiani, D. A. Zayanti, R. Primartha, F. Efriliyanti, and N. A. C. Andriani, “Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina,” *J. Edukasi dan Penelit. Inform. JEPIN*, vol. 7, no. 2, pp. 255–262, 2021.
- [8] B. Nugroho, W. S. J. Saputra, and E. Y. Puspaningrum, “Pengenalan Multi-Wajah Menggunakan Metode Ekstraksi Fitur Viola Jones Untuk Presensi Perkuliahan,” in *Seminar Nasional informatika (SANTIKA)*, 2019, pp. 6–11.
- [9] M. R. Khilmawan and A. A. Riadi, “Implementasi Pengurangan Noise pada Citra Tulang Menggunakan Metode Median Filter dan Gaussian Filter,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 3, no. 2, pp. 116–121, 2018, doi: 10.29100/jupi.v3i2.865.
- [10] M. M. Sebatubun, “Peningkatan Kualitas Citra X-Ray Paru-Paru Menggunakan Contrast Limited Adaptive Histogram Equalization dan Gaussian Filter,” in *Seminar Riset Teknologi Informasi (SRITI)*, 2016, pp. 241–247.
- [11] P. Chlap, H. Min, N. Vandenberg, J. Dowling, L. Holloway, and A. Haworth, “A review of medical image data augmentation techniques for deep learning applications,” *J. Med. Imaging Radiat. Oncol.*, vol. 65, no. 5, pp. 545–563, 2021, doi: 10.1111/1754-9485.13261.

- [12] C. Shorten and T. M. Khoshgoftaar, “A Survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 60, 2019.
- [13] T. A. Soomro *et al.*, “Deep Learning Models for Retinal Blood Vessels Segmentation: A Review,” *IEEE Access*, vol. 7, pp. 71696–71717, 2019, doi: 10.1109/ACCESS.2019.2920616.
- [14] S. Ahuja, B. K. Panigrahi, N. Dey, V. Rajinikanth, and T. K. Gandhi, “Deep transfer learning-based automated detection of COVID-19 from lung CT scan slices,” *Appl. Intell.*, vol. 51, no. 1, pp. 571–585, 2021, doi: 10.1007/s10489-020-01826-w.
- [15] V. Kumar, T. Lal, P. Dhuliya, and D. Pant, “A study and comparison of different image segmentation algorithms,” *Proc. - 2016 Int. Conf. Adv. Comput. Commun. Autom. (Fall), ICACCA 2016*, 2016, doi: 10.1109/ICACCAF.2016.7749007.
- [16] M. Kiran, I. Ahmed, N. Khan, and A. G. Reddy, “Chest X-ray segmentation using Sauvola thresholding and Gaussian derivatives responses,” *J. Ambient Intell. Humaniz. Comput.*, vol. 10, no. 10, pp. 4179–4195, 2019, doi: 10.1007/s12652-019-01281-7.
- [17] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: convolutional networks for biomedical image segmentation,” *Springer Int. Publ.*, 2015, doi: 10.1007/978-3-319-24574-4.
- [18] S.-H. Wang *et al.*, “Multiple Sclerosis Identification by 14-Layer Convolutional Neural Network With Batch Normalization, Dropout, and Stochastic Pooling,” *Front. Neurosci.*, vol. 12, 2018, doi: 10.3389/fnins.2018.00818.
- [19] X. Y. Zhou and G. Z. Yang, “Normalization in Training U-Net for 2-D Biomedical Semantic Segmentation,” *IEEE Robot. Autom. Lett.*, vol. 4, no. 2, pp. 1792–1799, 2019, doi: 10.1109/LRA.2019.2896518.
- [20] S. Ioffe and C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” *Proc. 32nd Int. Conf. Mach. Learn. Lille, Fr. 2015*, vol. 37, pp. 1–9, 2015, doi: 10.1080/17512786.2015.1058180.
- [21] N. M. Aboelenein, P. Songhao, A. Koubaa, A. Noor, and A. Afifi, “HTTU-Net: Hybrid Two Track U-Net for Automatic Brain Tumor Segmentation,” *IEEE Access*, vol. 8, pp. 101406–101415, 2020, doi: 10.1109/ACCESS.2020.2998601.
- [22] L. Liu, L. Mou, X. X. Zhu, and M. Mandal, “Skin Lesion Segmentation Based on Improved U-net,” *2019 IEEE Can. Conf. Electr. Comput. Eng. CCECE 2019*, pp. 1–4, 2019, doi: 10.1109/CCECE.2019.8861848.
- [23] A. L. Aswathy, A. H. S., and V. C. Vinod, “COVID-19 diagnosis and severity detection from CT-images using transfer learning and back propagation neural network,” *J. Infect. Public Health*, vol. 14, no. 10, pp.

- 1435–1445, 2021, doi: 10.1016/j.jiph.2021.07.015.
- [24] D. Sarwinda, R. H. Paradisa, A. Bustamam, and P. Anggia, “Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer,” *Procedia Comput. Sci.*, vol. 179, no. 2019, pp. 423–431, 2021, doi: 10.1016/j.procs.2021.01.025.
- [25] E. Paladini, E. Vantaggiato, F. Bougourzi, C. Distanto, A. Hadid, and A. Taleb-Ahmed, “Two Ensemble-CNN Approaches for Colorectal Cancer Tissue Type Classification,” *J. Imaging*, vol. 7, no. 3, p. 51, 2021, doi: 10.3390/jimaging7030051.
- [26] A. Keles, M. B. Keles, and A. Keles, “COVID-19-CNN and COVID-19-ResNet: Diagnostic Inference Engines for Early Detection of COVID-19,” *Cognit. Comput.*, no. 0123456789, 2021, doi: 10.1007/s12559-020-09795-5.
- [27] Z. Karhan and F. Akal, “Covid-19 Classification Using Deep Learning in Chest X-Ray Images,” *TIPTEKNO 2020 - Tip Teknol. Kongresi - 2020 Med. Technol. Congr. TIPTEKNO 2020*, pp. 2021–2024, 2020, doi: 10.1109/TIPTEKNO50054.2020.9299315.
- [28] K. Ali, Z. A. Shaikh, A. A. Khan, and A. A. Laghari, “Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer,” *Neurosci. Informatics*, vol. 2, no. 4, p. 100034, 2022, doi: 10.1016/j.neuri.2021.100034.
- [29] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” in *Proceedings of the 36th International Conference on Machine Learning*, 2019, pp. 6105–6114.
- [30] S. Chaudhary, V. Jakhethiya, B. N. Subudhi, U. Baid, and S. C. Guntuku, “Detecting Covid-19 and Community Acquired Pneumonia Using Chest CT Scan Images with Deep Learning,” in *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2021, pp. 8583–8587.
- [31] X. Chen *et al.*, “Application of EfficientNet-B0 and GRU-based deep learning on classifying the colposcopy diagnosis of precancerous cervical lesions,” *Cancer Med.*, no. July 2022, pp. 1–10, 2023, doi: 10.1002/cam4.5581.
- [32] C. Wang *et al.*, “Pulmonary image classification based on inception-v3 transfer learning model,” *IEEE Access*, vol. 7, pp. 146533–146541, 2019, doi: 10.1109/ACCESS.2019.2946000.
- [33] W. Li *et al.*, “Classification of High-Spatial-Resolution Remote Sensing Scenes Method Using Transfer Learning and Deep Convolutional Neural Network,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, no. X, pp. 1986–1995, 2020, doi: 10.1109/JSTARS.2020.2988477.
- [34] S. Sharma, “COVID-19 prediction from chest X-ray images using deep convolutional neural network,” *Artif. Intell. Mach. Learn. EDGE Comput.*,

- no. March 2020, pp. 315–324, 2022, doi: 10.1016/B978-0-12-824054-0.00022-8.
- [35] M. Mujahid, F. Rustam, R. Álvarez, J. Luis Vidal Mazón, I. de la T. Díez, and I. Ashraf, “Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network,” *Diagnostics*, vol. 12, no. 5, pp. 1–16, 2022, doi: 10.3390/diagnostics12051280.
- [36] J. Cao, M. Yan, Y. Jia, X. Tian, and Z. Zhang, “Application of a modified Inception-v3 model in the dynasty-based classification of ancient murals,” *EURASIP J. Adv. Signal Process.*, vol. 2021, no. 1, 2021, doi: 10.1186/s13634-021-00740-8.
- [37] J. Gao, C. Leung, and C. Miao, “Diabetic Retinopathy Classification Using an Efficient Convolutional Neural Network,” *Proc. - 2019 IEEE Int. Conf. Agents, ICA 2019*, pp. 80–85, 2019, doi: 10.1109/AGENTS.2019.8929191.
- [38] V. C. Osamor and A. F. Okezie, “Enhancing the weighted voting ensemble algorithm for tuberculosis predictive diagnosis,” *Sci. Rep.*, vol. 11, no. 1, pp. 1–12, 2021, doi: 10.1038/s41598-021-94347-6.
- [39] A. Desiani *et al.*, “Majority Voting as Ensemble Classifier for Cervical Cancer Classification,” *Sci. Technol. Indones.*, vol. 8, no. 1, pp. 84–92, 2023, doi: 10.26554/sti.2023.8.1.84-92.
- [40] A. Das, “Adaptive UNet-based Lung Segmentation and Ensemble Learning with CNN-based Deep Features for Automated COVID-19 Diagnosis,” *Multimed. Tools Appl.*, vol. 81, no. 4, pp. 5407–5441, 2022, doi: 10.1007/s11042-021-11787-y.
- [41] S. A. Siddiqui, N. Fatima, and A. Ahmad, “Chest X-ray and CT Scan Classification using Ensemble Learning through Transfer Learning,” *EAI Endorsed Trans. Scalable Inf. Syst.*, vol. 22, no. 6, pp. 1–9, 2022, doi: 10.4108/eetsis.vi.382.
- [42] T. Zhou, H. Lu, Z. Yang, S. Qiu, B. Huo, and Y. Dong, “The Ensemble Deep Learning Model for Novel COVID-19 on CT Images,” *Appl. Soft Comput.*, vol. 98, p. 106885, 2021, doi: 10.1016/j.asoc.2020.106885.
- [43] R. Kundu, R. Das, Z. W. Geem, G. T. Han, and R. Sarkar, “Pneumonia Detection in Chest X-Ray Images using an Ensemble of Deep Learning Models,” *PLoS One*, vol. 16, no. 9 September, 2021, doi: 10.1371/journal.pone.0256630.
- [44] K. Khaksari *et al.*, “Review of the efficacy of infrared thermography for screening infectious diseases with applications to COVID-19,” *J. Med. Imaging*, vol. 8, no. S1, pp. 1–15, 2021, doi: 10.1117/1.jmi.8.s1.010901.
- [45] K. Yuki, M. Fujiogi, and S. Koutsogiannaki, “COVID-19 pathophysiology: A review,” *Clin. Immunol.*, vol. 215, no. April, 2020, doi: 10.1016/j.clim.2020.108427.
- [46] S. Sehrawat and B. T. Rouse, “COVID-19: disease, or no disease? - that is

- the question. It's the dose stupid!," *Microbes Infect.*, vol. 23, no. 1, p. 104779, 2021, doi: 10.1016/j.micinf.2021.104779.
- [47] M. Rahimzadeh, A. Attar, and S. M. Sakhaei, "A fully automated deep learning-based network for detecting COVID-19 from a new and large lung CT scan dataset," *Biomed. Signal Process. Control*, vol. 68, no. December 2020, p. 102588, 2021, doi: 10.1016/j.bspc.2021.102588.
- [48] Y. Tang, J. E. Schmitz, D. H. Persing, and C. W. Stratton, "Laboratory Diagnosis of COVID-19: Current Issues and Challenges," *J. Clin. Microbiol.*, vol. 58, no. 6, pp. 1–9, 2020.
- [49] F. Song *et al.*, "Emerging 2019 Novel Coronavirus (2019-NCoV) Pneumonia," *Radiology*, vol. 295, no. 1, pp. 210–217, 2020, doi: 10.1148/radiol.2020200274.
- [50] N. Z. Munantri, H. Sofyan, and M. Y. Florestiyanto, "Aplikasi Pengolahan Citra Digital Untuk Identifikasi Umur Pohon," *Telematika*, vol. 16, no. 2, p. 97, 2020, doi: 10.31315/telematika.v16i2.3183.
- [51] I. R. S. Valente, P. C. Cortez, E. C. Neto, J. M. Soares, V. H. C. de Albuquerque, and J. M. R. S. Tavares, "Automatic 3D pulmonary nodule detection in CT images: A survey," *Comput. Methods Programs Biomed.*, vol. 124, pp. 91–107, 2016, doi: 10.1016/j.cmpb.2015.10.006.
- [52] A. Purnama, "Aplikasi matriks dalam pengolahan gambar," *Makal. IF2123 Aljabar*, no. May, p. 18650054, 2016.
- [53] A. Tahir *et al.*, "Coronavirus : Comparing COVID-19 , SARS, and MERS in The Eyes of AI," *arXiv*, pp. 1–35, 2021.
- [54] M. A. Kamel, M. Abdelshafy, M. AbdulRazek, O. Abouelkhir, A. Fawzy, and A. T. Sahlol, "Efficient Classification Approach Based on COVID-19 CT Images Analysis with Deep Features," 2021, doi: 10.1109/ICCCIS51004.2021.9397189.
- [55] Nurhidayah, B. Abdul Samad, and B. Abdullah, "Perbandingan Metode Contrast Enhancement pada Citra CT-Scan Kanker Paru-paru," *Gravitasi*, vol. 19, no. 2, pp. 24–28, 2020, doi: 10.22487/gravitasi.v19i2.15360.
- [56] M. Wulandari, "Index Quality Assesment Citra Terinterpolasi (SSIM dan FSIM)," *J. Terap. Teknol. Inf.*, vol. 1, no. 1, pp. 11–20, 2017, doi: 10.21460/jutei.2017.11.5.
- [57] A. Ramadhan, F. Mahmood, and A. Elci, "Image Denoising by Median Filter in Wavelet Domain," *Int. J. Multimed. Its Appl.*, vol. 9, no. 1, pp. 31–40, 2017, doi: 10.5121/ijma.2017.9104.
- [58] U. Sara, M. Akter, and M. S. Uddin, "Image Quality Assessment through FSIM, SSIM, MSE and PSNR—A Comparative Study," *J. Comput. Commun.*, vol. 07, no. 03, pp. 8–18, 2019, doi: 10.4236/jcc.2019.73002.
- [59] M. Elgendi *et al.*, "The Effectiveness of Image Augmentation in Deep

- Learning Networks for Detecting COVID-19 : A Geometric Transformation Perspective,” *Front. Med.*, vol. 8, no. March, pp. 1–12, 2021, doi: 10.3389/fmed.2021.629134.
- [60] M. M. A. Monshi, J. Poon, V. Chung, and F. M. Monshi, “CovidXrayNet: Optimizing Data Augmentation and CNN Hyperparameters for Improved COVID-19 Detection from CXR,” *Comput. Biol. Med.*, vol. 133, no. March, p. 104375, 2021, doi: 10.1016/j.combiomed.2021.104375.
- [61] D. Keidar, D. Yaron, E. Goldstein, Y. Shachar, A. Blass, and L. Charbinsky, “COVID-19 Classification of X-Ray Images Using Deep Neural Networks,” *Eur. Radiol.*, vol. 31, pp. 9654–9663, 2021.
- [62] I. R. I. Haque and J. Neubert, “Deep learning approaches to biomedical image segmentation,” *Informatics Med. Unlocked*, p. 100297, 2020, doi: 10.1016/j.imu.2020.100297.
- [63] A. Desiani, B. Suprihatin, S. Yahdin, A. I. Putri, and F. R. Husein, “Bi - path Architecture of CNN Segmentation and Classification Method for Cervical Cancer Disorders Based on Pap - smear Images,” *IAENG Int. J. Comput. Sci.*, vol. 48, no. 3, 2021.
- [64] Y. Jalali, M. Fateh, M. Rezvani, V. Abolghasemi, and M. H. Anisi, “ResBCDU-Net: A Deep Learning Framework for Lung CT Image Segmentation,” *Sensors*, vol. 21, no. 1, pp. 1–24, 2021, doi: 10.3390/s21010268.
- [65] X. Deng, Q. Liu, Y. Deng, and S. Mahadevan, “An Improved Method to Construct basic Probability Assignment based on The Confusion Matrix for Classification Problem,” *Inf. Sci. (Ny)*, vol. 340–341, pp. 250–261, 2016, doi: 10.1016/j.ins.2016.01.033.
- [66] J. Rasheed, A. A. Hameed, C. Djeddi, A. Jamil, and F. Al-Turjman, “A Machine Learning-based Framework for Diagnosis of COVID-19 from Chest X-ray Images,” *Interdiscip. Sci. Comput. Life Sci.*, vol. 13, no. 1, pp. 103–117, 2021, doi: 10.1007/s12539-020-00403-6.
- [67] M. A. Mohammed *et al.*, “A Comprehensive Investigation of Machine Learning Feature Extraction and Classification Methods for Automated Diagnosis of COVID-19 based on X-ray Images,” *Comput. Mater. Contin.*, vol. 66, no. 3, pp. 3289–3310, 2021, doi: 10.32604/cmc.2021.012874.
- [68] G. Marques, D. Agarwal, and I. de la Torre Díez, “Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network,” *Appl. Soft Comput. J.*, vol. 96, p. 106691, 2020, doi: 10.1016/j.asoc.2020.106691.
- [69] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, “Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition,” *Insights Imaging*, vol. 9, no. 4, pp. 21–30, 2018, doi: 10.1007/978-981-15-7078-0_3.

- [70] S. Bharati, P. Podder, M. R. H. Mondal, and V. B. S. Prasath, "CO-ResNet: Optimized ResNet model for COVID-19 diagnosis from X-ray images," *Int. J. Hybrid Intell. Syst.*, vol. 17, no. 1–2, pp. 71–85, 2021, doi: 10.3233/his-210008.
- [71] J. Shi *et al.*, "Improvement of Damage Segmentation Based on Pixel-Level Data Balance using VGG-UNet," *Appl. Sci.*, vol. 11, no. 2, pp. 1–17, 2021, doi: 10.3390/app11020518.
- [72] W. Chen, B. Yang, J. Li, and J. Wang, "An Approach to Detecting Diabetic Retinopathy based on Integrated Shallow Convolutional Neural Networks," *IEEE Access*, vol. 8, pp. 178552–178562, 2020, doi: 10.1109/ACCESS.2020.3027794.
- [73] S. Ioffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," in *Proceedings of the 32 nd International Conference on Machine Learning*, 2015, vol. 37, pp. 448–456.
- [74] S. Wang, K. Muhammad, J. Hong, A. Kumar, S. Y. Zhang, and S. Wang, "Alcoholism Identification via Convolutional Neural Network based on Parametric ReLU , Dropout, and Batch Normalization," *Neural Comput. Appl.*, vol. 32, pp. 665–680, 2018, doi: 10.1007/s00521-018-3924-0.
- [75] Y. Tian, "Artificial Intelligence Image Recognition Method Based on Convolutional Neural Network Algorithm," *IEEE Access*, vol. 8, pp. 125731–125744, 2020, doi: 10.1109/ACCESS.2020.3006097.
- [76] L. Alzubaidi *et al.*, "Review of Deep Learning: Concepts , CNN Architectures , Challenges , Applications , Future Directions," *J. Big Data*, vol. 8, no. 53, 2021, doi: 10.1186/s40537-021-00444-8.
- [77] H. Gholamalinezhad and H. Khosravi, "Pooling Methods in Deep Neural Networks, a Review," *arXiv*, 2020.
- [78] D. Im, D. Han, S. Choi, S. Kang, and H. J. Yoo, "DT-CNN: an energy-efficient dilated and transposed convolutional neural network processor for region of interest based image segmentation," *IEEE Trans. Circuits Syst. I Regul. Pap.*, vol. 67, no. 10, pp. 3471–3483, 2020, doi: 10.1109/TCSI.2020.2991189.
- [79] J. Yang, D. Ruan, J. Huang, X. Kang, and Y. Shi, "An Embedding Cost Learning Framework Using," *IEEE Trans. Inf. Forensics Secur.*, vol. 15, pp. 839–851, 2019, doi: 10.1109/TIFS.2019.2922229.
- [80] T. A. Soomro, O. Hellwich, A. J. Afifi, M. Paul, J. Gao, and L. Zheng, "Strided U-Net Model: Retinal Vessels Segmentation using Dice Loss," *2018 Int. Conf. Digit. Image Comput. Tech. Appl. DICTA 2018*, pp. 1–8, 2018, doi: 10.1109/DICTA.2018.8615770.
- [81] Q. Li *et al.*, "Tumor Segmentation in Contrast-Enhanced Magnetic Resonance Imaging for Nasopharyngeal Carcinoma: Deep Learning with Convolutional Neural Network," *Biomed Res. Int.*, vol. 2018, 2018.

- [82] G. Brain, A. N. Gomez, and G. Brain, “Depthwise Separable Convolutions for Neural Machine Translation,” 2018.
- [83] R. Stolkin, “Dense Connection and Depthwise Separable Convolution based CNN for Polarimetric SAR Image Classification,” *Knowledge-Based Syst.*, vol. 194, 2020, doi: 10.1016/j.knosys.2020.105542.
- [84] Z. Younas and Z. Niu, “CNN with Depthwise Separable Convolutions and Combined Kernels for Rating Prediction,” *Expert Syst. Appl.*, vol. 170, p. 114528, 2021, doi: 10.1016/j.eswa.2020.114528.
- [85] D. R. Nayak, N. Padhy, P. K. Mallick, M. Zymbler, and S. Kumar, “Brain Tumor Classification Using Dense Efficient-Net,” *Axioms*, vol. 11, no. 1, 2022, doi: 10.3390/axioms11010034.
- [86] H. Salehinejad and S. Valaee, “ISING-DROPOUT : A REGULARIZATION METHOD FOR TRAINING AND COMPRESSION OF DEEP NEURAL NETWORKS,” in *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 3602–3606.
- [87] S. Lian, L. Li, G. Lian, X. Xiao, Z. Luo, and S. Li, “A Global and Local Enhanced Residual U-Net for Accurate Retinal Vessel Segmentation,” *IEEE/ACM Trans. Comput. Biol. Bioinforma.*, vol. 14, no. 8, pp. 1–10, 2019, doi: 10.1109/tcbb.2019.2917188.
- [88] H. Alaiz-moreton, J. Aveleira-mata, J. Ondicol-garcia, A. L. Muñoz-castañeda, and C. Benavides, “Multiclass Classification Procedure for Detecting Attacks on MQTT-IoT Protocol,” *Hindawi*, vol. 2019, 2019.
- [89] H. Shaziya, K. Shyamala, and R. Zaheer, “Automatic Lung Segmentation on Thoracic CT Scans using U-Net Convolutional Network,” in *2018 International Conference on Communication and Signal Processing (ICCSP)*, 2018, pp. 643–647.
- [90] Q. Ji, J. Huang, W. He, and Y. Sun, “Optimized Deep Convolutional Neural Networks for Identification of Macular Diseases from Optical Coherence Tomography Images,” *Algorithms*, vol. 12, no. 3, pp. 1–12, 2019, doi: 10.3390/a12030051.
- [91] H. Alhichri and A. S. Alswayed, “Classification of Remote Sensing Images Using EfficientNet-B3 CNN Model With Attention,” *IEEE Access*, vol. 9, pp. 14078–14094, 2021, doi: 10.1109/ACCESS.2021.3051085.
- [92] T. Ahmed, “Classification and Understanding of Cloud Structures via Satellite Images with EfficientUNet,” *SN Comput. Sci.*, vol. 3, no. 99, 2022, doi: <https://doi.org/10.1007/s42979-021-00981-2>.
- [93] C. Szegedy *et al.*, “Going Deeper with Convolutions,” in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1–9.
- [94] A. Gupta, Anjum, S. Gupta, and R. Katarya, “InstaCovNet-19: A Deep Learning Classification Model for The Detection of COVID-19 Patients

- Using Chest X-ray,” *Appl. Soft Comput.*, vol. 99, no. xxxx, p. 106859, 2021, doi: 10.1016/j.asoc.2020.106859.
- [95] C. Land, C. Mapping, U. Multispectral, and R. S. Imagery, “Very Deep Convolutional Neural Networks for Complex Land Cover Mapping Using Multispectral Remote Sensing Imagery,” *Remote Sens.*, vol. 10, no. 7, 2018, doi: 10.3390/rs10071119.
- [96] F. Ahmad, A. Farooq, and M. U. Ghani, “Deep Ensemble Model for Classification of Novel Coronavirus in Chest X-Ray Images,” *Comput. Intell. Neurosci.*, vol. 2021, 2021.
- [97] J. F. Hern, I. Researcher, J. Chardin, and S. Borja, “An Ensemble Approach for Multi-Stage Transfer Learning Models for COVID-19 Detection from Chest CT Scans,” *Intell. Med.*, vol. 5, no. 2020, 2021, doi: 10.1016/j.ibmed.2021.100027.
- [98] I. Markoulidakis, I. Rallis, I. Georgoulas, G. Kopsiaftis, A. Doulamis, and N. Doulamis, “Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem,” *Technologies*, vol. 9, no. 4, p. 81, 2021, doi: 10.3390/technologies9040081.
- [99] A. Desiani, R. Primartha, M. Arhami, and O. Orsalan, “Naive Bayes Classifier for Infant Weight Prediction of Hypertension Mother,” *J. Phys. Conf. Ser.*, vol. 1282, no. 1, 2019, doi: 10.1088/1742-6596/1282/1/012005.
- [100] D. Chicco, M. J. Warrens, and G. Jurman, “The Matthews Correlation Coefficient (MCC) is More Informative Than Cohen’s Kappa and Brier Score in Binary Classification Assessment,” *IEEE Access*, vol. 9, pp. 78368–78381, 2021, doi: 10.1109/ACCESS.2021.3084050.
- [101] F. Li and H. He, “Assessing the Accuracy of Diagnostic Tests,” *Shanghai Arch. Psychiatry*, vol. 30, no. 3, pp. 207–212, 2018, doi: 10.11919/j.issn.1002-0829.218052.
- [102] A. R. Susanto, “Analisis Perbandingan Metode Perbaikan Kontras Citra pada Citra Medis Xray,” *J. Inform.*, vol. 12, no. 1, pp. 1–9, 2018, doi: 10.26555/jifo.W.
- [103] D. Umamaheswari and S. Geetha, “Visual Quality and Illumination Enhancement Using Gamma Corrected Gaussian Filtering Framework for Covid-19 Images,” *ICTACT J. Image Video Process.*, vol. 11, no. 1, pp. 2268–2274, 2020, doi: 10.21917/ijivp.2020.0322.
- [104] A. Roy and P. Maity, “A Comparative Analysis of Various Filters to Denoise Medical X-Ray Images,” in *2020 4th International Conference on Electronics, Materials Engineering and Nano-Technology, IEMENTech 2020*, 2020, pp. 20–24, doi: 10.1109/IEMENTech51367.2020.9270073.
- [105] M. Abdel-Basset, N. N. Mostafa, K. M. Sallam, I. Elgendi, and K. Munasinghe, “Enhanced COVID-19 X-ray Image Preprocessing Schema Using Type-2 Neutrosophic Set,” *Appl. Soft Comput.*, vol. 123, p. 108948,

- 2022, doi: 10.1016/j.asoc.2022.108948.
- [106] L. I. Kesuma, Ermatita, Erwin, P. Sari, and R. H. Purabaya, “Improved Chest X - Ray Image Quality Using Median and Gaussian Filter Methods,” 2022.
- [107] G. Tong, Y. Li, H. Chen, Q. Zhang, and H. Jiang, “Improved U-NET Network for Pulmonary Nodules Segmentation,” *Optik (Stuttg.)*, vol. 174, no. August, pp. 460–469, 2018, doi: 10.1016/j.ijleo.2018.08.086.
- [108] A. G. Smith, J. Petersen, R. Selvan, and C. R. Rasmussen, “Segmentation of Roots in Soil with U-Net,” *Plant Methods*, vol. 16, no. 1, pp. 1–15, 2020, doi: 10.1186/s13007-020-0563-0.
- [109] B. A. Akinuwesi *et al.*, “Application of intelligence-based computational techniques for classification and early differential diagnosis of COVID-19 disease,” *Data Sci. Manag.*, vol. 4, no. December, pp. 10–18, 2021, doi: 10.1016/j.dsm.2021.12.001.
- [110] S. Kadry, V. Rajinikanth, S. Rho, N. Sri, and M. Raja, “Development of a Machine-Learning System to Classify Scan Images into Normal / COVID-19 Class,” vol. 2, no. December, 2019.
- [111] D. N. Vinod and S. R. S. Prabakaran, “Data science and the role of Artificial Intelligence in achieving the fast diagnosis of Covid-19,” vol. 140, 2020, doi: 10.1016/j.chaos.2020.110182.
- [112] S. K. Sharma, U. K. Lilhore, S. Simaiya, and N. K. Trivedi, “An improved random forest algorithm for predicting the COVID-19 pandemic patient health,” *Ann. Rom. Soc. Cell Biol.*, vol. 25, no. 1, pp. 67–75, 2021.
- [113] X. Wu *et al.*, “Deep learning-based multi-view fusion model for screening 2019 novel coronavirus pneumonia: A multicentre study,” *Eur. J. Radiol.*, vol. 128, no. March, pp. 1–9, 2020, doi: 10.1016/j.ejrad.2020.109041.
- [114] V. Shah, R. Keniya, A. Shridharani, M. Punjabi, J. Shah, and N. Mehendale, “Diagnosis of COVID-19 using CT scan images and deep learning techniques,” *Emerg. Radiol.*, vol. 28, no. 3, pp. 497–505, 2021, doi: 10.1007/s10140-020-01886-y.
- [115] S. Albahli, N. Ayub, and M. Shiraz, “Coronavirus disease (COVID-19) detection using X-ray images and enhanced DenseNet,” *Appl. Soft Comput.*, vol. 110, p. 107645, 2021, doi: 10.1016/j.asoc.2021.107645.
- [116] S. R. D. Dimas, B. S. Negara, S. Sanjaya, and E. Satria, “COVID-19 Classification for Chest X-Ray Images using Deep Learning and Resnet-101,” in *2021 International Congress of Advanced Technology and Engineering, ICOTEN 2021*, 2021, pp. 20–23, doi: 10.1109/ICOTEN52080.2021.9493431.
- [117] T. Anwar and S. Zakir, “Deep learning based diagnosis of COVID-19 using chest CT-scan images,” *Proc. - 2020 23rd IEEE Int. Multi-Topic Conf. INMIC 2020*, pp. 6–10, 2020, doi: 10.1109/INMIC50486.2020.9318212.

- [118] R. A. Pratiwi, S. Nurmaini, D. P. Rini, M. N. Rachmatullah, and A. Darmawahyuni, "Deep Ensemble Learning for Skin Lesions Classification with Convolutional Neural Network," *IAES Int. J. Artif. Intell.*, vol. 10, no. 3, pp. 563–570, 2021, doi: 10.11591/ijai.v10.i3.pp563-570.
- [119] S. Tang *et al.*, "EDL-COVID: Ensemble Deep Learning for COVID-19 Case Detection from Chest X-Ray Images," *IEEE Trans. Ind. Informatics*, vol. 17, no. 9, pp. 6539–6549, 2021, doi: 10.1109/TII.2021.3057683.
- [120] P. Shrivastava, A. Singh, S. Agarwal, H. Tekchandani, and S. Verma, "Covid Detection in CT and X-Ray Images using Ensemble Learning," in *Proceedings - 5th International Conference on Computing Methodologies and Communication, ICCMC 2021*, 2021, no. Iccmc, pp. 1085–1090, doi: 10.1109/ICCMC51019.2021.9418308.
- [121] T. K. K. Ho and J. Gwak, "Feature-Level Ensemble Approach for COVID-19 Detection using Chest X-ray Images," *PLoS One*, vol. 17, no. 7 July, pp. 1–19, 2022, doi: 10.1371/journal.pone.0268430.
- [122] L. Visuna, D. Yang, J. Garcia-Blas, and J. Carretero, "Computer-Aided Diagnostic for Classifying Chest X-ray Images using Deep Ensemble Learning," *BMC Med. Imaging*, vol. 22, no. 1, pp. 1–16, 2022, doi: 10.1186/s12880-022-00904-4.
- [123] L. I. Kesuma, Ermatita, and Erwin, "ELREI : Ensemble Learning of ResNet , EfficientNet , and Inception-v3 for Lung Disease Classification based on Chest X-Ray Image," *Int. J. Intell. Eng. Syst.*, vol. 16, no. 5, pp. 149–161, 2023, doi: 10.22266/ijies2023.1031.14.
- [124] E. Allam Zanaty and S. Mostafa Ibrahim, "Medical Image Compression Based on Combining Region Growing and Wavelet Transform," *Int. J. Med. Imaging*, vol. 7, no. 3, pp. 57–65, 2019, doi: 10.11648/j.ijmi.20190703.11.

LAMPIRAN

Lampiran 1. Bukti Accepted ICIMCIS



November 16-17, 2022

4th International Conference Informatics, Multimedia, Cyber and Information System

AI-Powered Solutions in transformed Business and Society into Super Smart Society 5.0

No : 103/UN61/FIK/2022 Jakarta, November 8th, 2022
Subject : Letter of Acceptance as Submission
at ICIMCIS 2022

Lucky Kesuma
Universitas Sjakhyakirti Palembang, Indonesia

Dear author,
Congratulation, your final manuscript submission #1570852024 with the title **(Improved Chest X-Ray Image Quality Using Median and Gaussian Filter Methods)** has been ACCEPTED as part of the technical program for the 2022 International Conference on Informatics, Multimedia, Cyber and Information Systems (ICIMCIS). Hopefully, this paper will be presented (oral or online) at the conference as our technical program reports. The conference organizers and our attendees expect each and every accepted paper to be presented which contributes to the success of the event.

Your final submission must adhere to the IEEE PDF compliance which is checked through <https://2022.icimcis.org/final-camera-ready-guidelines/>. To confirm attendance at the conference, please complete registration through the link below:

<https://bit.ly/ICIMCIS2022-Registration-Form>

Please be noticed, only registered and presented papers will proceed to IEEE explore. Upon receipt of your registration, we appreciate taking this opportunity to thank you for your participation in the 4th ICIMCIS 2022. Please do not hesitate to contact us for further information or visit our link below :

<https://2022.icimcis.org/>

We look forward to meeting you at the 4th ICIMCIS on November 16th - 17th, 2022 at **Virtual Conference, in Horison Grand Serpong, Indonesia**. For more info please join this WhatsApp Group:

<https://chat.whatsapp.com/EiZ3X7dRHFcBbbYgNGufNE>



Lampiran 2. Bukti Accepted Jurnal IJIES

Intelligent Networks and Systems Society

Acceptance Letter

International Journal of Intelligent Engineering and Systems (IJIES)

June 27, 2023

Dear Erwin,

Manuscript Title: ELREI: Ensemble Learning of ResNet, EfficientNet, and Inception-v3 for Lung Disease Classification based on Chest X-Ray Image

Author(s): Lucky Indra Kesuma, Ermatita, Erwin

Thank you for submitting your paper to the International Journal of Intelligent Engineering and Systems (IJIES). Based on double blind review process, we are pleased to inform you that our Review Committee has accepted your paper.

The paper will be included in the IJIES, which will be published with ISSN (ISSN: 2185-3118) in online on the website (<http://www.inass.org/publications.html>). We are looking forward to your further contribution to our journal.

Kind regards

Prof. Dr. Kei EGUCHI
Editor-in-Chief, International Journal of Intelligent Engineering and Systems

Department of Information Electronics
Fukuoka Institute of Technology

A handwritten signature in black ink that reads "Kei Eguchi". The signature is written in a cursive style.

E-mail: ijies@inass.org