

Peningkatan Citra Untuk Klasifikasi Gangguan Paru-Paru Menggunakan Deep Learning

1st Agustinus Aldian Adiwijaya
Fakultas Ilmu Terapan
Universitas Telkom
Bandung, Indonesia

aldianadiwijaya@student.telkomuniversity.ac.id

2nd Yuli Sun Hariyani
Fakultas Ilmu Terapan
Universitas Telkom
Bandung, Indonesia

yulisun@telkomuniversity.ac.id

3rd Sugondo Hadiyoso
Fakultas Ilmu Terapan
Universitas Telkom
Bandung, Indonesia

sugondo@telkomuniversity.ac.id

Abstrak — Gangguan pada paru-paru seperti pneumonia, tuberculosis, dan Covid-19 merupakan gangguan yang cukup serius dimana dapat menyerang sistem pernapasan manusia dan bisa berakibat fatal jika tidak ditangani dengan serius. Gejala yang muncul yaitu sakit tenggorokan, batuk, demam, dan kesulitan dalam bernapas. Pengamatan kondisi paru-paru pasien dilakukan paramedis melalui foto rontgen (Chest X-rays). Namun, kualitas citra rontgen terkadang kurang optimal, sehingga dikembangkan sistem otomatisasi berbasis CAD. Oleh karena itu, pada proyek akhir ini merancang sistem untuk meningkatkan citra pada kinerja deep learning. Terutama pada perbandingan performansi sistem sebelum preprocessing dan setelah preprocessing. Penelitian ini bertujuan mengembangkan sistem otomatisasi untuk mendeteksi dan mengklasifikasi penyakit paru-paru pada citra rontgen menggunakan Convolutional Neural Network (CNN) dengan arsitektur Inception V3. Sebuah dataset multi-kelas yang mencakup Normal, Pneumonia, Tuberkulosis (TB), dan Covid-19 digunakan untuk melatih dan menguji model. Evaluasi performa sistem dilakukan sebelum dan setelah preprocessing citra dengan metode Unsharp Masking (UM) dan High-Frequency Emphasis Filtering (HEF). Hasil penelitian Pada data latih tanpa preprocessing, model mencapai akurasi sekitar 86.11%, dengan tingkat presisi, recall, dan F1-Score yang cukup seimbang. Sedangkan data latih sesudah preprocessing model mencapai akurasi sekitar 99.31%, dan presisi, recall, serta F1-Score mendekati 99.32%.

Kata kunci— Chest X-Ray, Convolutional Neural Network (CNN), Inception V3, Tuberculosis, Pneumonia, COVID-19.

I. PENDAHULUAN

Paru-Paru adalah organ pernapasan atau respirasi dalam tubuh. Paru-paru berhubungan dengan sistem pernapasan serta sirkulasi atau peredaran darah. Permasalahan yang sering terjadi pada sistem pernapasan adalah kualitas udara yang telah tercemar, sehingga udara yang dihirup mengandung banyak bakteri yang dapat menyerang sistem pernapasan terutama paru-paru [1]. Gangguan paru-paru seperti pneumonia, dan tuberculosis kedua jenis penyakit ini menyerang organ penting paru-paru dan menjadi penyebab kematian ke dua di dunia. Kemudian, beberapa tahun belakangan ini muncul virus varian baru COVID-19 dimana virus ini dapat menyebar tidak hanya melalui kontak langsung dengan pasien COVID-19, tetapi juga melalui

udara. Penularan virus ini lebih berbahaya menyebabkan gejala yang sebanding dengan Pneumonia dan Tuberculosis, sedangkan gejala yang muncul antara lain sakit tenggorokan, batuk, demam, dan kesulitan bernapas [2]. Dalam beberapa tahun terakhir, teknik Deep Learning (DL) telah berhasil diterapkan di berbagai bidang, antara lain sistem pengenalan wajah, pengawasan, klasifikasi kendaraan, dan banyak lainnya. Salah satu metode yang paling terkenal adalah model Convolutional Neural Network (CNN). Adanya kecerdasan buatan atau AI yang perkembangannya pesat, memungkinkan membantu paramedis dalam melakukan pengamatan visual yang dapat mengurangi terjadinya kesalahan dalam melakukan proses deteksi gangguan paru-paru. Pada saat klasifikasi gambar sering menggunakan teknologi Computer Aided Diagnosis (CAD) yang berguna bagi paramedis dalam mendiagnosis penyakit dengan akurat.

Pada umumnya proses dalam mengidentifikasi gangguan paru-paru dengan melakukan pengujian menggunakan teknik Chest X-Ray (CXR). Pemeriksaan CXR digunakan untuk menemukan penyakit pada anatomi tubuh manusia dengan cara pengambilan foto bagian dalam tubuh manusia menggunakan radiasi elektromagnetik. CXR dalam melakukan deteksi dini pada kondisi manusia yang terkena penyakit memiliki akurasi yang cukup sekitar 80%. Namun masih adanya kekurangan dari metode penerapan yang dilakukan untuk mendeteksi gangguan paru-paru menggunakan CXR. Seperti hasil dari CXR masih ditentukan secara manual membuat terbatasnya ukuran data yang dikumpulkan sehingga membutuhkan waktu lebih lama untuk paramedis dalam mendiagnosis gangguan paru-paru pada pasien. Dengan memanfaatkan model DL, CNN serta CXR yang dapat diklasifikasikan ke dalam kategori tertentu, sehingga model DL menarik untuk diteliti dengan model arsitektur yang berbeda. Pada penelitian sebelumnya beberapa sistem deteksi TB otomatis telah menggunakan teknik DL seperti “Deep Learning Untuk Deteksi Covid-19, Pneumonia, Dan Tuberculosis Pada Citra Rontgen Dada Menggunakan CNN dengan Arsitektur Alexnet” penelitian ini memiliki dataset 2304 citra yang terbagi menjadi empat kelas diantaranya COVID-19, pneumonia, TB, dan normal dimana masing masing kelas memiliki 576 citra. Untuk klasifikasi empat kelas tersebut diperoleh akurasi sistem sebesar 95%, serta nilai performansi seperti presisi, recall, f1-score mendapatkan nilai yang sama besar yaitu 95% dan loss sebesar 0.161. Untuk pengaruh Resize, Learning Rate, Epoch, Batch Size, dan Optimizer pada sistem telah


mendapatkan nilai terbaik yaitu dengan Resize 64×64 piksel, learning rate 0,0001, epoch 25, batch size 32, dan yang terakhir dengan Optimizer Adam [3].

Pada Proyek Akhir ini mengevaluasi langkah pre-processing terhadap kinerja teknik DL secara menyeluruh. Pre-processing gambar sangat penting untuk dilakukan pada model CNN, yang secara efektif dapat meningkatkan kinerja model CNN dalam klasifikasi gambar. Serta, peningkatan gambar adalah bagian yang sangat penting dari pre-processing. Maka dari itu, penelitian yang berhubungan antara peningkatan citra dan model CNN menjadi penting. Proyek akhir ini menggunakan arsitektur Inception V3 sebagai arsitektur DL. Tujuan utama dari Proyek Akhir ini adalah untuk mengevaluasi efek dari dua pendekatan pre-processing yang berbeda dengan algoritma peningkatan citra yaitu Unsharp Masking (UM) dan High-Frequency Emphasis Filtering (HEF) pada penggunaan CNN untuk mendeteksi gangguan paru-paru.

II. KAJIAN TEORI

A. Pneumonia

Pneumonia adalah kondisi inflamasi yang terjadi saat mengalami infeksi pada kantung-kantung udara dalam paru-paru. Untuk kondisi infeksi itu sendiri dapat menyebabkan peradangan pada kantong udara yang dinamakan alveoli sehingga dapat berakibat kantung udara dipenuhi dengan cairan atau nanah sehingga sulit untuk bernafas [4]. Gangguan ini dapat menyebabkan batuk berdahak atau bernanah, demam, menggigil, hingga kesulitan bernapas. Pada gambar 2.1 merupakan ilustrasi perbandingan paru-paru pasien yang memiliki penyakit pneumonia dan pasien yang memiliki paru-paru normal.



Gambar 2. 1 Paru-Paru Pneumonia dan Normal

B. Tuberculosis

Tuberculosis (TB) adalah penyakit menular yang terjadi akibat infeksi bakteri *Mycobacterium tuberculosis*. Penularannya penyakit ini dapat melalui udara lalu masuk ke sistem pernapasan. Penyakit ini harus segera ditangani agar tidak memperburuk kondisi paru-paru dan lebih parahnya dapat menyebabkan kematian [5]. Bakteri *Mycobacterium tuberculosis* ini menular lewat semburan air liur ketika pengidap TBC batuk, bersin, bicara, tertawa atau bernyanyi. TB tidak menular semudah itu perlu adanya kontak dekat dengan pengidap TB dalam waktu lama (beberapa jam) untuk bisa tertular penyakit ini.

C. Corona Virus Disease-19 (COVID-19)

Corona Virus Disease-19 (COVID-19) adalah infeksi yang disebabkan oleh strain virus baru virus corona yang menyerang sistem pernapasan akut. Virus COVID-19 merupakan virus varian baru yang dapat menyebabkan flu biasa, Severe Acute Respiratory Syndrome (SARS), dan Middle East Respiratory Syndrome (MERS). Penularan virus Covid-19 yang begitu cepat terjadi dikarenakan tidak sengaja menghirup percikan ludah (droplet) yang keluar saat penderita COVID-19 bersin atau batuk. Lalu memegang mulut, hidung, atau mata tanpa mencuci tangan terlebih dulu, setelah menyentuh benda yang terkena droplet penderita COVID-19.

D. Deep Learning


Deep Learning merupakan algoritma dalam Machine Learning. Machine Learning merupakan salah satu cabang ilmu dari Artificial Intelligence atau kecerdasan buatan yang pada masa kini berperan penting dalam kehidupan kita. Semua algoritma Deep Learning menggunakan berbagai jenis jaringan syaraf untuk menyelesaikan tugas tertentu. Setiap algoritma memiliki cara kerja masing-masing yang berbeda satu sama lain. Deep Learning merupakan tiap jaringan syaraf dengan lebih dari 2 susunan. Selain itu, para ahli sedang membangun model yang lebih andal yang sebenarnya memperbarui konsep dan ide lama, seperti halnya jaringan syaraf kompleks (CNN) hingga jaringan Kapsul atau Capsnet, hingga Pembelajaran Penguatan Jaringan Dalam dan Jaringan Dalam (DRL). Banyak dari model deep learning baru ini telah terbukti sangat efektif dalam memproses kumpulan data yang sangat besar [6]. Oleh karena itu, dalam mengelola big data, deep learning merupakan solusi pembaharuan dari machine learning.

E. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu dari banyak metode pengembangan dari variasi Artificial Neural Networks (ANN) atau Jaringan Saraf Tiruan (JST) dan Multilayer Perceptrons (MLP) yang memiliki bobot dan beberapa lapisan tersembunyi yang terstruktur ke dalam arsitektur yang digunakan dalam pemrosesan data dua dimensi. CNN biasanya digunakan untuk menganalisa objek pada gambar. Teknik CNN juga dianggap sebagai model terbaik untuk menganalisa objek [7]. Teknik CNN adalah salah satu deep learning, yang menggunakan konsep machine learning untuk menemukan karakteristik visual data berdasarkan kemampuan JST dengan menerapkan algoritma untuk memproses lapisan untuk menghasilkan output yang lebih akurat. Pendekatan CNN digunakan untuk mengidentifikasi dan mengkategorikan gambar dengan mengolah gambar dua dimensi dengan tingkat kedalaman lapisan yang tinggi [8]. Arsitektur CNN terdapat beberapa lapisan pada model CNN yaitu lapisan convolution, fungsi aktivasi, pooling, flatten, dan lapisan fully connected.

Adapun arsitektur CNN secara umum dapat dilihat pada Gambar 2.2 .

Struktur CNN terdiri dari banyak lapisan, termasuk input, ekstraksi fitur, klasifikasi, dan output. Prosedur ekstraksi mencakup banyak lapisan tersembunyi, termasuk Convolution Layer, Rectified Linear Unit (ReLU), dan Pooling. Secara umum cara kerja dari CNN yaitu output dari



Gambar 2. 2 Convolutional Neural Network (CNN)

convolution layer pertama digunakan sebagai input untuk convolution layer berikutnya. Pada tahap classification layer terdiri dari full connected layer dan softmax yang outputnya berupa hasil klasifikasi [9].

F. Preprocessing


Struktur CNN Preprocessing adalah langkah pertama dalam pengolahan citra untuk memperoleh kualitas citra yang lebih baik seperti mempertajam citra, peningkatan citra, penghapusan noise, dan sebagainya. Pada tugas akhir ini digunakan dua jenis preprocessing yaitu Unsharp Masking (UM), High-Frequency Emphasis Filtering (HEF). UM bertujuan untuk meningkatkan ketajaman atau detail gambar. Pada HEF bersifat mempertahankan frekuensi tinggi dan menekan frekuensi rendah.

1. Unsharp Masking (UM)

Unsharp masking (UM) merupakan salah satu metode pemrosesan citra digital yang dapat digunakan untuk mengurangi tingkat kekaburan citra yang disebabkan oleh umur photo. Penamaan kata unsharp dikarenakan metode ini menggunakan citra yang lebih blur terhadap citra asli sebagai faktor pembuat mask [10]. Unsharp Masking nantinya akan menghasilkan gambar dengan tingkat ketajaman yang lebih baik dibandingkan dengan gambar aslinya.

2. High-Frequency Emphasis Filtering (HEF)

Frekuensi dalam citra terkait dengan perbedaan intensitas antar piksel bertetangga atau berdekatan. Dua buah piksel yang saling berdekatan dengan perbedaan intensitas yang besar memiliki frekuensi yang besar dibandingkan dengan dua piksel yang perbedaan intensitasnya kecil. High-Frequency Emphasis Filtering (HEF) adalah jenis pemfilteran 2-D Fourier yang membutuhkan langkah-langkah seperti pada Gambar dibawah ini




Gambar 2. 3 Langkah Filtering HEF

High pass filtering merupakan suatu metode filtering yang melewati frekuensi tinggi dengan baik, tetapi mengurangi frekuensi yang lebih rendah dari frekuensi cut-off. Pada dasarnya sharpening adalah operasi high-pass di domain frekuensi. High-pass filtering adalah langkah utama yang penting dalam meningkatkan citra. Karena high-pass mengurangi nilai rata-rata suatu gambar, gambar yang difilter akan kehilangan sebagian besar latar belakang nada suara hadir dalam aslinya. Untuk masalah ini, offset dapat ditambahkan ke high-pass filtering [11]. Ketika offset dikombinasikan dengan produk filter dikalikan dengan konstanta lebih besar dari 1, pendekatan ini disebut penyaringan penekanan frekuensi tinggi.

G. Inception V3

Arsitektur Inception v3 memanfaatkan teknik faktorisasi convolution asimetris untuk mengurangi jumlah operasi matematika. Modul Inception v3 terdiri atas tiga desain yaitu [12] :



Gambar 2. 4 Model Arsitektur Inception V3

Modul Inception A modul ini mengganti convolution 5×5 pada Inception v1 dengan dua buah convolution 3×3. Jika ditinjau dari total operasi matematika, convolution 5×5 membutuhkan 25 operasi matematika, sedangkan dua buah convolution 3×3 membutuhkan 18 operasi matematika. Modul Inception B modul ini menggunakan teknik convolution asimetris 1×7 dan 7×1 sebagai ganti convolution 7×7. Modul Inception C modul ini diajukan untuk mempromosikan representasi dimensi tinggi. Inception v3 menawarkan langkah paralel (Gambar 3 Grid Size Reduction) yang menggabungkan operasi convolution dan operasi pooling untuk mendapatkan jumlah feature map yang sama dengan operasi convolution diikuti pooling atau pun sebaliknya namun GridSize Reduction memiliki beban komputasi yang lebih ringan. Secara umum arsitektur Inception v3 dapat dibagi menjadi dua bagian besar, yaitu bagian convolution dan bagian classifier yang digambarkan pada gambar 3.7 . Bagian convolution adalah kumpulan dari lapisan convolution, pooling, aktivasi ReLU, dan Batch Normalization yang akan mengekstrak fitur dari citra input. Bagian classifier tersusun atas Neural Network yang bertugas mengklasifikasikan fitur yang sudah diekstrak oleh bagian convolution.

H. Parameter Uji

Pada Parameter yang diuji dalam penelitian ini adalah sebagai berikut :

1. Akurasi

Parameter akurasi adalah kemampuan sistem untuk menemukan input yang diberikan dan menghasilkan nilai output yang tepat [13]. Adapun untuk menghitung nilai akurasi dapat menggunakan Persamaan sebagai berikut:

$$\text{Akurasi} = \frac{TTP \text{ all} + TTN \text{ all}}{\text{total number of testing entries}}$$

2. Presisi

Parameter presisi atau biasa disebut nilai positif prediksi. Parameter ini digunakan untuk mengetahui seberapa banyak prediksi positif yang benar, dari keseluruhan data prediksi positif [10]. Adapun precision dapat dihitung dengan Persamaan sebagai berikut:

$$\text{Presisi} = \frac{TTP \text{ all}}{TTP \text{ all} + TFPi}$$

3. Recall

Parameter recall atau sensitivitas digunakan untuk menghitung nilai perkiraan rasio nilai true positive relatif terhadap semua data true positive [10]. Adapun untuk menghitung nilai recall dapat menggunakan Persamaan sebagai berikut:

$$\text{Recall} = \frac{TTP \text{ all}}{TTP \text{ all} + TFNI}$$

4. F1-Score


F1-Score merupakan proses perhitungan evaluasi dalam mengkombinasikan nilai sensitivitas dan precision. Nilai sensitivitas dan precision dari suatu keadaan dapat memiliki nilai yang berbeda [10]. Adapun nilai dari f1-Score dapat dihitung dengan menggunakan Persamaan berikut :

$$\text{F1-score} = \frac{2 \times \text{recall} \times \text{precision}}{\text{recall} + \text{precision}}$$

III. METODE

A. Blok Diagram Sistem

Pada Proyek Akhir yang dirancang sebuah sistem untuk meningkatkan citra dan mengklasifikasi gangguan paru-paru. Gambaran umum sistem diilustrasikan dengan blok diagram yang ditunjukkan pada Gambar 3.1




Gambar 3. 1 Blok Diagram sistem

Pada gambar 3.1 secara umum merupakan alur proses penelitian sistem yang dirancang dengan tujuan untuk mendapatkan hasil 4 (empat) klasifikasi citra chest x-ray Gangguan pada paru-paru. Data input sistem yang digunakan adalah citra chest x-ray dari dataset yang dapat diakses melalui kaggle secara online, berupa citra penyakit paru-paru yang akan dilakukan klasifikasi untuk mengidentifikasi menjadi 4 (empat) kelas yaitu normal, tuberculosis, pneumonia, dan COVID-19. Selanjutnya, dilakukan 2 (dua) tahap yaitu resize citra dilakukan dengan tujuan menyeragamkan ukuran citra dalam satuan pixel dan pre-processing dengan jenis pre-processing yang digunakan Unsharp Masking (UM) dan High-Frequency Emphasis Filtering (HEF) untuk meningkatkan kualitas yang lebih baik terhadap citra. Kemudian memberikan data pelatihan model sistem dengan tujuan untuk mendapatkan hasil klasifikasi yang maksimal menggunakan model Inception V3 melalui convolution, activation, dan max pooling layer, sehingga dihasilkan model terbaik kemudian dikategorikan berdasarkan kelas yang telah ditentukan. Klasifikasi merupakan hasil output dari pelatihan model dalam mengidentifikasi gangguan paru-paru pneumonia, COVID-19, tuberculosis atau normal.

B. Dataset


Pada Proyek akhir ini dataset yang digunakan berasal dari kaggle sejumlah 624 citra dengan format JPEG dan normal. Yang terdiri atas 210 citra untuk pneumonia, 90 citra untuk Covid – 19, 90 citra untuk Tuberculosis, dan 234 citra untuk Normal. Dataset tersebut digunakan untuk melatih model CNN dan Inception V3. Dataset tersebut akan dipisahkan menjadi 20% menjadi data uji dan 80% menjadi data latih. Gambar di bawah ini menunjukkan contoh dataset yang akan digunakan pada penelitian ini.



Gambar 3. 2 Dataset Chest X-Ray

C. Preprocessing

Sebelum melakukan pelatihan model, perlu dilakukan proses preprocessing. Proses ini bertujuan untuk memperbaiki kualitas citra. Proses preprocessing ini diharapkan dapat membantu mengoptimalkan dan mempermudah sistem dalam mendeteksi klasifikasi citra. Tahap pre-processing terdapat beberapa proses pada gambar 3.3




Gambar 3. 3 Diagram Blok Preprocessing

Langkah pertama pada proses preprocessing yaitu melakukan input citra X-Ray paru-paru dan citra tersebut akan diproses dengan dua jenis preprocessing yaitu Unsharp Masking (UM), High-Frequency Emphasis Filtering (HEF). UM bertujuan untuk meningkatkan ketajaman atau detail gambar. Pada HEF bersifat mempertahankan frekuensi tinggi dan menekan frekuensi rendah. Keluaran dari proses preprocessing ini didapatkan dua model gambar berbeda. Kemudian Resizing citra dilakukan dengan tujuan menyeragamkan ukuran citra dalam satuan pixel. Selain itu, ukuran citra yang terlalu besar dapat membuat pemrosesan pada sistem menjadi semakin lama, dan juga ukuran citra yang terlalu kecil dapat membuat kualitas citra yang kurang baik. Pre-processing resizing citra dilakukan pada semua model pengujian.

D. Pelatihan Model

Tahapan dari proses pelatihan model Inception V3 dimulai dengan input citra dari dataset hingga diperoleh klasifikasi. Proses pelatihan bertujuan untuk melatih model Inception V3 dalam mengenali kumpulan datanya dan mengklasifikasikannya antara tuberculosis, pneumonia, COVID-19, dan normal. Untuk diagram alur pelatihan model arsitektur Inception V3 bisa dilihat pada Gambar 3.4



Gambar 3. 4 Arsitektur Inception V3

Pelatihan model dilakukan agar model dapat mengklasifikasikan citra dengan nilai akurasi tinggi dan kesalahan yang rendah. Proses pelatihan model dilakukan dengan memasukkan beberapa citra penyakit yang sudah memiliki label dari masing-masing kelas, untuk melewati model yang sudah dibuat. Model yang digunakan adalah CNN dengan arsitektur Inception V3. Proses pelatihan dilakukan terus berulang hingga model mendapatkan

parameter terbaik, sehingga model dapat melakukan klasifikasi secara akurat.


IV. HASIL DAN PEMBAHASAN

A. Dataset


Tabel 4. 1 Dataset

Pneumonia	Covid-19	Tuberculosis	Normal
210	90	90	234

Dataset yang digunakan pada penelitian ini ialah berjumlah 210 untuk pneumonia, 90 untuk Covid – 19, 90 untuk Tuberculosis, dan 234 untuk Normal. Dataset tersebut digunakan untuk melatih model CNN dan Inception V3 pada model yang digunakan pada penelitian berikut ini. Untuk dataset yang digunakan pada penelitian ini disimpan pada google drive dan dilakukan langsung pengelompokkan pada dataset tersebut untuk 4 kelompok yaitu, Pneumonia, Tuberculosis, Covid-19, dan Normal. Ukuran dataset yang digunakan pada penelitian ini ialah seragam untuk semua kelompok dataset, yaitu 70 X 70 dilakukan resize pada semua dataset yang digunakan. Untuk hasil dataset yang digunakan dapat dilihat pada gambar berikut ini.



Gambar 4. 1 Dataset Pneumonia dan Normal




Gambar 4. 2 Dataset COVID-19 dan Tuberculosis

B. Hasil Terhadap Pengujian Preprocessing

Pada pengujian ini, fokus utama adalah mengevaluasi dampak penggunaan dua teknik preprocessing, yaitu Unsharp Masking dan High-Frequency Emphasis Filtering, dalam meningkatkan citra radiologi paru-paru untuk keperluan klasifikasi menggunakan deep learning. Sebagai langkah awal, citra radiologi paru-paru dibagi menjadi dua kelompok, yaitu kelompok yang menjalani proses Unsharp Masking dan kelompok yang mengalami High-Frequency Emphasis Filtering. Proses ini bertujuan untuk mempertajam dan meningkatkan detail pada citra radiologi sebelum citra disajikan kepada model deep learning untuk pelatihan.

Setelah proses preprocessing selesai, dilakukan pelatihan model deep learning menggunakan kedua kelompok citra yang telah diproses dan kelompok citra yang tidak mengalami preprocessing. Pengujian ini dilakukan untuk mengukur perbedaan performa klasifikasi antara citra sebelum dan sesudah preprocessing. Dengan demikian, dapat dievaluasi apakah Unsharp Masking dan High-Frequency Emphasis Filtering memberikan peningkatan yang signifikan dalam akurasi dan keandalan model klasifikasi gangguan paru-paru.

Hasil dari pengujian ini akan memberikan wawasan tentang efektivitas masing-masing teknik preprocessing, membantu pemahaman terkait dengan teknik mana yang lebih sesuai untuk meningkatkan citra radiologi paru-paru dalam konteks klasifikasi gangguan paru-paru menggunakan deep learning. Kesimpulan dari pengujian ini dapat memberikan panduan berharga dalam memilih metode preprocessing yang optimal untuk meningkatkan performa model klasifikasi paru-paru.




Gambar 4.3 Metrik Performa Data Latih

Berdasarkan hasil pengujian preprocessing pada klasifikasi gangguan paru-paru menggunakan deep learning, dapat ditarik beberapa kesimpulan yang menarik. Pada data latih tanpa preprocessing, model mencapai akurasi sekitar 86.11%, dengan tingkat presisi, recall, dan F1-Score yang cukup seimbang. Kemudian, ketika menerapkan teknik Unsharp Masking pada data latih, terjadi peningkatan signifikan dalam semua metrik performa. Akurasi mencapai 99.31%, dan presisi, recall, serta F1-Score mendekati 99.32%. Namun, ketika menggunakan High-Frequency Emphasis Filtering pada data latih, hasilnya tidak setinggi Unsharp Masking, meskipun tetap memberikan performa yang baik. Akurasi sekitar 84.03%, dengan presisi, recall, dan F1-Score yang mencapai 85.57%, 84.03%, dan 83.85%, secara berturut-turut.

C. Hasil Terhadap Pengujian Epoch

Pada pengujian terhadap epoch dalam pelatihan dan pengujian model klasifikasi gangguan paru-paru menggunakan deep learning, mengamati bagaimana kinerja model berevolusi seiring dengan jumlah epoch yang berbeda. Pada tahap pelatihan, hasil menunjukkan bahwa model mampu meningkatkan akurasi dan konsistensi prediksi seiring bertambahnya jumlah epoch. Peningkatan ini mencerminkan adaptasi model terhadap data latih, yang semakin diperdalam dan dipahami seiring berjalannya iterasi pelatihan. Namun, pada tahap pengujian, terlihat bahwa terlalu banyak epoch tidak selalu menghasilkan kinerja yang lebih baik pada dataset uji. Hal ini dapat diindikasikan oleh perbedaan performa antara data latih dan data uji. Jika model

terlalu diperkenankan untuk terus beradaptasi dengan data latih, risiko overfitting dapat meningkat, di mana model menjadi terlalu spesifik untuk data pelatihan dan kehilangan kemampuan untuk menggeneralisasi pada data baru.




Gambar 4.4 Akurasi Data Latih dan Data Uji Terhadap Epoch

Oleh karena itu, pada pengujian ini, peneliti perlu memperhatikan trade-off antara kinerja pada data latih dan data uji serta menentukan jumlah epoch yang optimal. Menemukan titik di mana peningkatan performa model pada data latih tidak diikuti oleh peningkatan pada data uji adalah kunci untuk memastikan bahwa model yang dikembangkan dapat memberikan prediksi yang baik pada data yang belum pernah dilihat sebelumnya. Kesimpulan dari pengujian terhadap epoch ini dapat memberikan panduan berharga untuk mengoptimalkan proses pelatihan model klasifikasi gangguan paru-paru menggunakan deep learning.

Pada epoch 20, akurasi pada data latih mencapai sekitar 90%, sedangkan akurasi pada data uji mencapai sekitar 80%. Pada epoch 140, akurasi pada data latih mencapai sekitar 97%, sedangkan akurasi pada data uji mencapai sekitar 90%. Hal ini menunjukkan bahwa model pembelajaran mesin mulai overfitting pada data latih setelah epoch 140. Overfitting adalah kondisi di mana model terlalu cocok dengan data latih, sehingga tidak dapat generalisasi dengan baik ke data baru. Berdasarkan hasil analisis tersebut, dapat disimpulkan bahwa jumlah epoch yang optimal untuk model pembelajaran mesin ini adalah sekitar 140. Jumlah epoch ini menghasilkan akurasi yang cukup tinggi pada data latih dan data uji, tanpa menyebabkan overfitting. Grafik juga menunjukkan pengaruh preprocessing terhadap akurasi. Preprocessing adalah proses mempersiapkan data sebelum digunakan untuk pelatihan model pembelajaran mesin. Preprocessing dapat dilakukan untuk meningkatkan kualitas data, sehingga model dapat belajar dengan lebih baik. Pada grafik, akurasi pada data latih dan data uji dengan preprocessing lebih tinggi daripada akurasi tanpa preprocessing. Hal ini menunjukkan bahwa preprocessing dapat meningkatkan akurasi model pembelajaran mesin. Preprocessing yang digunakan dalam grafik adalah unsharp masking dan high-frequency emphasis filtering. Unsharp masking adalah proses meningkatkan kontras pada tepi objek dalam gambar. High-frequency emphasis filtering adalah proses meningkatkan frekuensi tinggi dalam gambar. Pada grafik, akurasi dengan unsharp masking lebih tinggi daripada akurasi dengan high-frequency emphasis filtering. Hal ini menunjukkan bahwa unsharp masking lebih efektif dalam meningkatkan akurasi model pembelajaran mesin.

D. Hasil Terhadap Pengujian Performasi Sistem

Tabel 4. 2 Pengujian Performasi Sistem



Dari tabel yang ditampilkan dalam gambar, dapat dilihat bahwa sistem dengan preprocessing unsharp masking dan high-frequency filtering memiliki nilai PSNR (Peak Signal to Noise Ratio) yang lebih tinggi daripada sistem tanpa preprocessing. PSNR adalah ukuran kualitas gambar yang mengukur rasio antara sinyal asli dan sinyal yang telah dikompresi atau dirusak. Nilai PSNR yang lebih tinggi menunjukkan bahwa gambar tersebut memiliki kualitas yang lebih baik. Selain itu, sistem dengan preprocessing unsharp masking dan high-frequency filtering juga memiliki nilai SSIM (Structural Similarity Index Measure) yang lebih tinggi daripada sistem tanpa preprocessing. SSIM adalah ukuran kualitas gambar yang mengukur kemiripan struktural antara sinyal asli dan sinyal yang telah dikompresi atau dirusak. Nilai SSIM yang lebih tinggi menunjukkan bahwa gambar tersebut memiliki kemiripan struktural yang lebih besar dengan sinyal asli. Berdasarkan hasil analisis tersebut, dapat disimpulkan bahwa sistem dengan preprocessing unsharp masking dan high-frequency filtering memiliki kinerja yang lebih baik daripada sistem tanpa preprocessing. Sistem ini dapat menghasilkan gambar yang lebih tajam dan memiliki kemiripan struktural yang lebih besar dengan sinyal asli.

V. KESIMPULAN

A. Kesimpulan

Dari hasil eksperimen ini, dapat disimpulkan bahwa penerapan metode preprocessing pada gambar rontgen dada secara signifikan meningkatkan akurasi model Inception V3 dalam mengklasifikasikan kasus pneumonia. Secara khusus, metode High-Frequency Emphasis Filtering memberikan peningkatan akurasi yang lebih mencolok dibandingkan dengan Unsharp Masking atau model tanpa preprocessing. Hasil ini menunjukkan bahwa peningkatan ketajaman dan penekanan frekuensi tinggi pada gambar memberikan kontribusi positif terhadap kemampuan model untuk membedakan dengan lebih baik antara kelas pneumonia dan non-pneumonia. Selain itu, observasi terhadap nilai akurasi pada setiap titik waktu (epoch 50, 100, dan 150) menunjukkan tren peningkatan yang konsisten seiring bertambahnya epoch, terutama pada model yang menggunakan metode preprocessing. Hal ini mengindikasikan bahwa model Inception V3 memiliki potensi untuk terus meningkatkan performa dengan pelatihan lebih lanjut, terutama ketika didukung dengan metode preprocessing yang sesuai. Keseluruhan, hasil akurasi yang lebih tinggi dengan penerapan metode preprocessing, terutama High-Frequency Emphasis Filtering, menunjukkan bahwa pendekatan ini dapat menjadi strategi yang efektif

dalam meningkatkan kemampuan model untuk mengenali pneumonia pada gambar rontgen dada.

B. Saran

Penelitian ini memerlukan pendekatan lebih lanjut dalam mengoptimalkan penggunaan teknik Unsharp Mask dan High Frequency Emphasis Filtering. Disarankan untuk melakukan eksperimen dengan variasi parameter filtering guna mencari keseimbangan yang tepat antara peningkatan visual dan pemeliharaan akurasi. Selain itu, penelitian dapat diperluas dengan menggabungkan teknik-teknik tersebut dengan metode denoising atau adaptive filtering untuk mengatasi dampak noise yang mungkin muncul. Selanjutnya, perlu mempertimbangkan karakteristik khusus dari jenis gambar yang diolah agar penggunaan teknik filtering dapat dioptimalkan. Kesimpulannya, perlu dilakukan upaya lebih lanjut untuk menyempurnakan penggunaan teknik Unsharp Mask dan High Frequency Emphasis.

REFERENSI

- [1] R. Rahmadewi and R. Kurnia, "KLASIFIKASI PENYAKIT PARU BERDASARKAN CITRA RONTGEN DENGAN METODA SEGMENTASI SOBEL," *Jurnal Nasional Teknik Elektro*, vol. 5, no. 1, pp. 2302-2949, 2016.
- [2] M. G. Manoj, M. K. S. Kumar, K. T. Valsaraj, C. Sivan and S. K. Vijayan, "Potential Link Between Compromised Air Quality and Transmission of the Novel Corona Virus (SARS-CoV-2) in Affected Areas," *Environmental Research*, vol. 190, p. 110001, 2020.
- [3] S. Septhyan, "Deep Learning Untuk Deteksi Covid-19, Pneumonia, Dan Tuberculosis Pada Citra Rontgen Dada Menggunakan CNN Dengan Arsitektur Alexnet," Universitas Telkom, S1 Teknik Telekomunikasi, Bandung, 2022.
- [4] T. P. Htun, Y. Sun, H. L. Chua and J. Pang, "Clinical features for diagnosis of pneumonia among adults in primary care setting: A systematic and meta-review," *Scientific Report*, vol. 9, no. 1, p. 7600, 2019.
- [5] O. Rochmawanti, F. Utaminigrum and F. A. Bachtar, "ANALISIS PERFORMA PRE-TRAINED MODEL CONVOLUTIONAL NEURAL NETWORK DALAM MENDETEKSI PENYAKIT TUBERCULOSIS," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 8, no. 4, p. 805, 2021.
- [6] Suryanto, N. R. Kurniawan and S. Mandala, *DEEP LEARNING MODERNISASI MACHINE LEARNING UNTUK BIG DATA*, Bandung: Informatika, 2019, pp. xiv, 250.
- [7] L. Tobias, A. Ducournau, F. Rousseau, G. Mercier and R. Fablet, "Convolutional Neural Network for Object Recognition on Mobile Devices: a Case Study," in *International Conference on Pattern Recognition(ICPR)*, Mexico, 2016.
- [8] S. H. Abdullah, "Klasifikasi Diabetic Retinopathy Berbasis Pengolahan Citra Fundus dan Deep Learning," Fakultas Teknik Elektro, Universitas Telkom Bandung, 2021.

- [9] E. Maggiori, Y. Tarabalka, G. Charpiat and P. Alliez, "Convolutional Neural Network for Large-Scale Remote-Sensing Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 2, pp. 645-657, 2017.
- [10] D. P. Sari, "Analisa Usharp Mask Filter Untuk Perbaikan Citra Pada Pas Foto," *Jurnal Riset Komputer (JURKOM)*, vol. 5, no. 6, pp. 644-647, 2018.
- [11] A. I. Zakaria, V. A. Ernawati and W. K. Z. Oktoberza, "PERBANDINGAN METODE HIGH-FREQUENCY EMPHASIS (HFE) DAN CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION(CLAHE) DALAM PERBAIKAN KUALITAS CITRA PENGINDERAAN JAUH (REMOTE SENSING)," *Jurnal Pseudocode*, vol. 6, no. 2, pp. 125-137, 2019.
- [12] J. E. Widyaya and S. Budi, "Pengaruh Preprocessing Terhadap Klasifikasi Diabetic Retinopathy dengan Pendekatan Transfer Learning Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, pp. 110-124, 2021.
- [13] D. M. W. Powers, "Evaluation: From Precision, Recall, and F-Factor to ROC Informedness, Markedness & Correlation," *J. Mach. Learn.*, vol. 2, pp. 37-63, 2007.