

Klasifikasi COVID-19 menggunakan *Filter Gabor* dan CNN dengan *Hyperparameter Tuning*

AGUS EKO MINARNO, MOCHAMMAD HAZMI COKRO MANDIRI,
MUHAMMAD RIFAL ALFARIZY

Universitas Muhammadiyah Malang, Indonesia
Email: aguseko@umm.ac.id

Received 25 Januari 2021 | *Revised* 8 Februari 2021 | *Accepted* 18 Februari 2021

ABSTRAK

Penyakit COVID-19 dapat timbul karena berbagai faktor sebab dan akibat, sehingga penyakit ini memiliki efek buruk bagi penderita. Pencitraan CT-Scan memiliki keunggulan dalam memproyeksikan kondisi paru-paru pasien penderita, sehingga dapat membantu dalam mendeteksi tingkat keparahan penyakit. Dalam studi ini, penelitian dilakukan untuk mendeteksi penyakit COVID-19 melalui citra CT-Scan menggunakan metode Filter Gabor dan Convolutional Neural Networks (CNN) dengan Hyperparameter Tuning. Data yang digunakan yaitu citra CT-Scan SARS-CoV-2 berjumlah 2481 gambar. Sebelum melatih model, dilakukan preprocessing data, seperti pelabelan, pengubahan ukuran, dan augmentasi gambar. Pengujian Model dilakukan dengan beberapa skenario uji. Hasil terbaik diperoleh pada skenario untuk model Filter Gabor dan CNN dengan Hyperparameter Tuning mendapatkan akurasi sebesar 97,9% dan AUC sebesar 99% dibandingkan dengan model tanpa Hyperparameter Tuning dan Filter Gabor.

Kata kunci: COVID-19, CNN, Filter Gabor, Hyperparameter Tuning, COVID-19 Classification

ABSTRACT

COVID-19 disease can arise due to various causal and causal factors, so it has an adverse effect on patients. CT-Scan imaging has an advantage in projecting the lung condition of patients with the patient, so it can help in detecting the severity of the disease. In this study, research was conducted to detect COVID-19 disease through CT-Scan imagery using Gabor Filter method and Convolutional Neural Networks (CNN) with Hyperparameter Tuning. The data used is CT-Scan SARS-CoV-2 imagery amounting to 2481 images. Before training the model, preprocessing data is performed, such as labeling, resizing, and augmentation of images. Model testing is performed with multiple test scenarios. The best results were obtained in scenarios for The Gabor Filter model and CNN with Hyperparameter Tuning getting 97.9% accuracy and AUC by 99% compared to models without Hyperparameter Tuning and Gabor Filter.

Keywords: COVID-19, CNN, Filter Gabor, Hyperparameter Tuning, COVID-19 Classification

1. PENDAHULUAN

Severe Acute Respiratory Syndrome CoronaVirus 2 (SARS-CoV2) adalah penyakit yang menyebabkan infeksi saluran pernafasan akibat virus corona. Penyakit SARS-CoV2 ditandai dengan gejala demam, batuk, sakit tenggorokan, sesak napas, kelelahan, dan malaise **(Singhal, 2020)**. Pada Maret 2020, *World Health Organization* (WHO) menyatakan bahwa Virus Corona sebagai pandemi penyakit di seluruh dunia **(Freni, dkk, 2020)**. Virus Corona atau COVID-19 menyebar dengan cepat diseluruh penjuru dunia. Hal tersebut terbukti berdasarkan perhitungan yang dilakukan *Center for Systems Science and Engineering* (CSSE) di Johns Hopkins University, pada 1 Mei 2020 tercatat 3,257,660 kasus COVID-19 dengan 233.416 kasus kematian dan berdampak pada lebih dari 187 Negara **(Fan, dkk, 2020)**. Deteksi dini dan diagnosis merupakan hal yang sangat dibutuhkan untuk menekan penyebaran COVID-19. Pada umumnya deteksi COVID-19 dilakukan dengan pengujian *Reverse-Transcription Polymerase Chain Reaction* (RT-PCR), namun metode tersebut kurang efisien dan memiliki sensitivitas yang rendah **(Silva, dkk, 2020)**.

Dalam menangani permasalahan tersebut, terdapat metode lain untuk mendeteksi COVID-19 salah satunya melalui citra X-Ray dan CT-Scan pada dada **(Shi et al., 2020)**. Pada kasus ini, X-Ray lebih mudah diakses karena tersedia di hampir seluruh rumah sakit di dunia dan lebih murah dibandingkan CT-Scan, namun hasil klasifikasi COVID-19 menggunakan citra CT-Scan lebih sensitif dibandingkan dengan X-Ray **(El-Kenawy, dkk, 2020)**. Maka dari itu, dibutuhkan sebuah teknologi untuk mengidentifikasi COVID-19 melalui data citra CT-Scan dengan cepat dan tepat. Identifikasi COVID-19 menggunakan citra CT-Scan dada dapat dilakukan dengan *Deep Learning*. Salah satu metode *Deep Learning* yang sering digunakan dalam mengatasi permasalahan dalam dunia medis adalah *Convolutional Neural Networks* (CNN) **(Polsinelli, dkk, 2020)**. Metode CNN sering digunakan untuk mengatasi permasalahan klasifikasi maupun segmentasi yang menggunakan data citra medis.

Penelitian sebelumnya terkait klasifikasi COVID-19 menggunakan *Deep Learning* telah banyak dilakukan, salah satunya oleh Xinggang Wang dengan judul "*A Weakly-supervised Framework for COVID-19 Classification and Lesion Localization from Chest CT*". Dataset yang digunakan berjumlah 630 citra CT-Scan yang terbagi menjadi 499 data *train* dan 131 data *test*. Metode yang digunakan adalah CNN dengan arsitektur *Detect COVID-19* (DecovNet). Hasil penelitian mendapatkan akurasi 90,1% dan AUC 95,9% **(Wang, dkk, 2020)**. Penelitian lainnya dilakukan oleh Achyut Mani T dengan judul "*Fuzzy Unique Image Transformation: Defense Against Adversarial Attacks On Deep COVID-19 Models*". Penelitian ini menggunakan dua *dataset*, *dataset* pertama adalah COVID-19 Chest X-Ray berjumlah 1125 citra terbagi menjadi 500 citra terinfeksi pneumonia, 500 citra normal (tidak terinfeksi) dan 125 citra terinfeksi COVID-19. *Dataset* kedua adalah data CT-Scan berjumlah 398 citra normal (tidak terinfeksi) dan 399 citra terinfeksi COVID-19. Metode yang digunakan adalah *Fuzzy Unique Image Transformation* (FUIT) sebagai teknik augmentasi dan model *transfer learning* dengan arsitektur Resnet-18, VGG-16, dan GoogLeNet. Hasil penelitian pada *dataset* X-Ray mendapatkan akurasi 97,2% untuk *binary classification* dan 88.21% untuk *three class classification*. Sedangkan hasil pada *dataset* CT-Scan mendapatkan akurasi 89.1% **(Tripathi & Mishra, 2020)**. Penelitian lainnya yang sejenis dilakukan oleh Zhao Wang dengan judul "*Contrastive Cross-site Learning with Redesigned Net for COVID-19 CT Classification*". Terdapat dua *dataset* yang digunakan, *dataset* pertama adalah SARS-CoV-2 dengan 1252 citra COVID-19 dan 1229 citra non-COVID-19. *Dataset* kedua adalah COVID-CT dengan 349 citra COVID-19 dan 397 citra negatif COVID-19. Metode yang digunakan adalah CNN dengan arsitektur COVID-Net. Hasil penelitian mendapatkan AUC 96,2% pada *dataset* pertama dan 85,3% pada *dataset* kedua **(Z. Wang, dkk, 2020)**. Penelitian lainnya dilakukan Pedro Silva

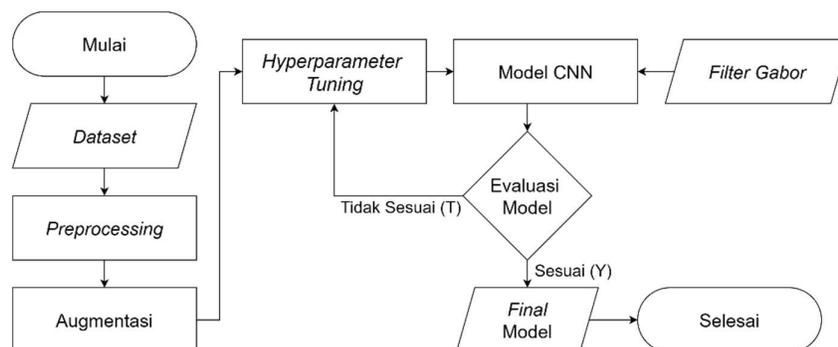
dengan judul "COVID-19 detection in CT images with deep learning: A voting-based scheme and cross-datasets analysis". Dataset yang digunakan sama dengan penelitian Zhao Wang. Namun, dataset pertama berperan sebagai data *train* dan dataset kedua sebagai data *test*. Metode yang digunakan adalah CNN dengan arsitektur *transfer learning EfficientNet*. Hasil penelitian berupa akurasi 87,6% dan AUC 90,5% (Silva, dkk, 2020). Penelitian lainnya dilakukan oleh Hariyani dengan judul "Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network". Dataset yang digunakan adalah Citra X-Ray data *cross validation* untuk data latih dengan kelas COVID-19 dan Normal berjumlah 48 data citra dan validasi berjumlah 15 data citra. Kemudian data uji menggunakan kelas COVID-19 berjumlah 42 citra dan Normal berjumlah 234 citra. Metode yang digunakan adalah *transfer learning Resnet50*. Hasil penelitian mendapatkan akurasi tertinggi 99% (Hariyani, dkk, 2020). Penelitian lainnya dilakukan oleh Jaiswal dengan judul "Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning". Dataset yang digunakan berupa CT-Scan berjumlah 2492 data citra dengan rincian 1262 positif COVID-19 dan 1230 negatif COVID-19. Metode yang digunakan adalah *deep transfer learning* dengan model DenseNet201. Hasil penelitian mendapatkan akurasi 96.25% (Jaiswal, dkk, 2020).

Berdasarkan beberapa penelitian yang telah dilakukan terdahulu, penelitian ini dilakukan untuk meningkatkan hasil dari penelitian khususnya yang dilakukan oleh Jaiswal. Penelitian Jaiswal belum menggunakan metode untuk menentukan kombinasi parameter terbaik pada model. Maka dari itu, penelitian ini dilakukan dengan mengusulkan model CNN dengan *Hyperparameter Tuning* untuk mencari kombinasi parameter terbaik untuk *optimizer*, nilai *dropout*, dan *dense* terbaik pada model yang diusulkan. Selain itu, berdasarkan data paru-paru terinfeksi COVID-19, fokus klasifikasi adalah pada bercak putih yang terdapat pada lapisan luar paru-paru. Dalam mengatasi masalah tersebut, diusulkan algoritma tekstur analisis yaitu *Filter Gabor* yang diharapkan dapat mempersingkat waktu penelitian dan meningkatkan performa model. *Filter Gabor* akan ditambahkan pada *layer convolution* pertama pada model yang telah dilakukan optimasi dengan *hyperparameter tuning*.

2. METODE PENELITIAN

2.1 Alur Penelitian

Pada penelitian ini, kami mengusulkan metode CNN untuk klasifikasi COVID-19 pada dataset SARS-CoV-2 CT-Scan. Tahap pertama dilakukan pengumpulan data, tahap kedua dilakukan *preprocessing* data, tahap ketiga dilakukan augmentasi, kemudian mengimplementasikan model usulan, melakukan evaluasi model untuk melakukan perbaikan pada model. *Filter Gabor* dan *Hyperparameter* diimplementasikan pada model untuk memberikan parameter yang optimal pada *final* model. Diagram alur penelitian ini dapat dilihat pada Gambar 1.



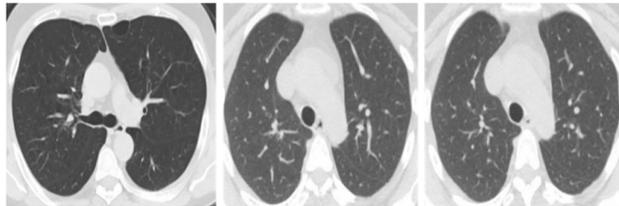
Gambar 1. Diagram Alur Penelitian

2.2 Dataset

Pada penelitian ini, *dataset* yang digunakan bersumber pada website kaggle bernama SARS-CoV-2 CT-Scan *dataset* (Soares, dkk, 2020) berjumlah 1252 CT-scan terinfeksi SARS-CoV-2 (COVID-19) dan 1229 CT-Scan tidak terinfeksi oleh SARS-CoV-2, keseluruhan data berjumlah 2481 data citra. Data dikumpulkan dari pasien di rumah sakit Sao Paulo, Brazil. Jumlah data terinfeksi COVID-19 dan normal tidak terinfeksi COVID hampir seimbang, dengan 1252 data COVID-19 dan 1229 data non-COVID-19. Data tidak memiliki standar ukuran gambar (ukuran gambar terkecil adalah 104×153 sedangkan gambar terbesar adalah 484×416). *Dataset* akan dibagi dengan rasio 80% untuk data *train* mengikuti aturan *Pareto Principle* yang menggunakan 80% dari total populasi sebagai data *train* untuk membuat model lebih efisien dan meningkatkan performa (Lovse, dkk, 2019), (Harvey & Sotardi, 2018). Perbedaan citra CT-Scan terinfeksi COVID-19 dengan citra Paru-paru Normal terletak pada bercak putih yang tersebar permukaan paru-paru. Contoh sampel data CT-Scan COVID dan non-COVID (normal) dapat dilihat pada Gambar 2 dan Gambar 3.



Gambar 2. CT-Scan Paru-paru terinfeksi COVID-19



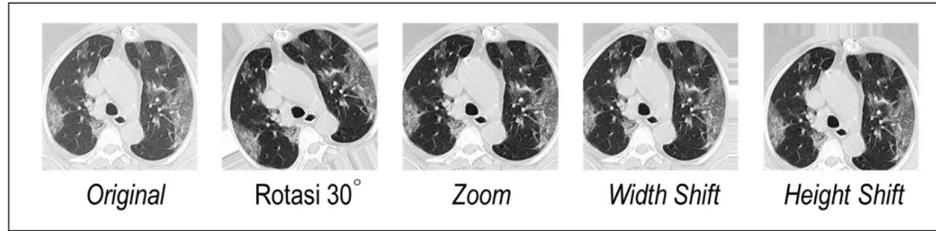
Gambar 3. CT-Scan Paru-paru Normal

2.3 Preprocessing

Pada penelitian ini, *preprocessing* yang dilakukan adalah mengubah data gambar menjadi *grayscale*, mengubah seluruh ukuran data yang beragam menjadi 128×128 pixel, memberi label pada setiap kelas, dan normalisasi data. Pada tahapan normalisasi data dilakukan penskalaan citra untuk mengubah pixel citra dari $[0, 255]$ menjadi $[0, 1]$. Proses normalisasi dilakukan menggunakan *library* Keras dengan fitur bernama *rescale*, proses tersebut dapat meningkatkan akurasi dan mengurangi *loss* saat pelatihan data (Dani, dkk, 2015).

2.4 Augmentasi

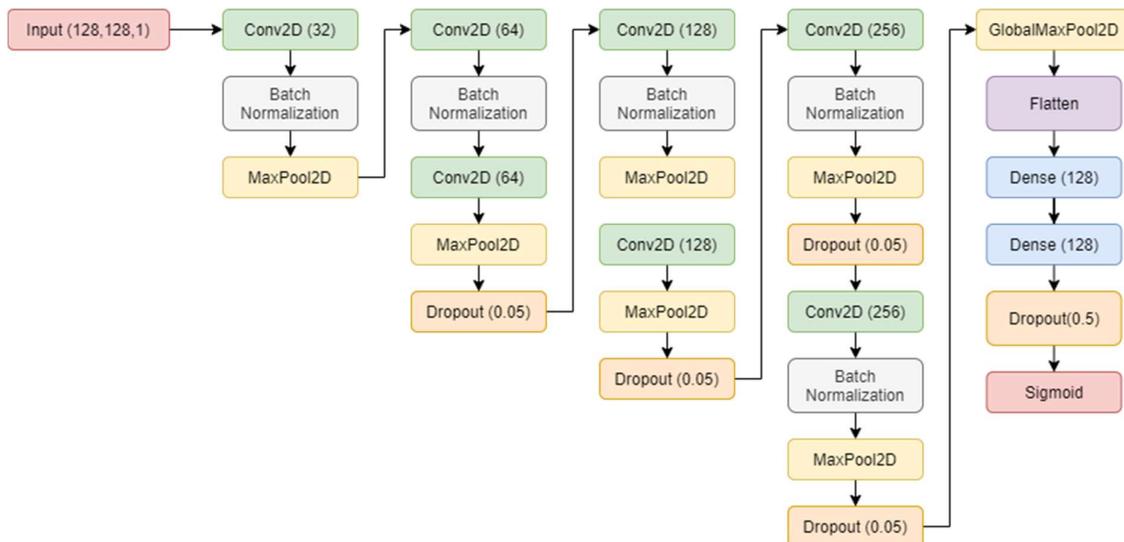
Pada tahap ini, augmentasi dilakukan untuk meningkatkan jumlah data dengan memodifikasi data sehingga program mengenali data tersebut adalah data yang berbeda. Proses ini dapat membantu penelitian dengan data berjumlah sedikit untuk mencegah *overfitting* maupun *underfitting*. Selain itu, proses augmentasi dapat meningkatkan kinerja model dalam proses klasifikasi gambar (Loey, dkk, 2020). Augmentasi data dilakukan dengan menggunakan *ImageDataGenerator* dari *library* Keras. Implementasi augmentasi data yang digunakan dalam penelitian ini adalah merotasi gambar sebesar 30 derajat, melakukan *zoom* atau perbesar gambar sebesar 10%, kemudian dilakukan *shifting* atau pergeseran gambar pada lebar dan tinggi sebesar 10%. Hasil dari augmentasi data dapat dilihat pada Gambar 4.



Gambar 4. Augmentasi Gambar

2.5 Rancangan Arsitektur Model

Arsitektur model *Convolutional Neural Network* (CNN) yang diusulkan pada penelitian ini terdiri dari *input layer*, *convolution layer*, *pooling layer*, *dropout layer*, *batch normalization*, dan *fully connected layer*. Pada *convolution layer*, filter yang digunakan bernilai (32, 64, 128, 256), *kernel size* yang akan digunakan bernilai (3, 3), *stride* bernilai 1, *padding* bernilai *same*, dan aktivasi yang digunakan adalah *Swish*. Pada *pooling layer* akan menggunakan *maxpooling* dengan *pool size* bernilai (3, 3) dan *padding* bernilai *same*. *Dropout layer* akan dibagi menjadi dua bagian berdasarkan letaknya, pada *fully connected layer* dan setelah *pooling layer*. Detail rancangan arsitektur model dapat dilihat pada Gambar 5.



Gambar 5. Rancangan Arsitektur Model

2.6 Hyperparameter Tuning

Pemilihan terhadap parameter yang tepat pada model yang diusulkan perlu dilakukan untuk meningkatkan hasil dari klasifikasi. *Hyperparameter Tuning* memiliki peran penting dalam pembelajaran mesin dan algoritma deep learning karena parameter yang dihasilkan mempengaruhi kinerja model CNN secara signifikan. Oleh karena itu *Hyperparameter Tuning* diusulkan untuk mengoptimalkan pemrosesan gambar medis pada Model CNN yang dibentuk (Ucar & Korkmaz, 2020). Pada penelitian ini, dilakukan metode *hyperparameter tuning* untuk menentukan parameter *optimizer*, *dropout* pada *fully connected layer*, *dropout* setelah *pooling layer*, dan *dense layer* yang tepat untuk model yang diusulkan. Pelatihan model pada saat *hyperparameter* dilakukan menggunakan *epoch* berjumlah 5. Detail parameter yang akan dibandingkan saat *hyperparameter tuning* dapat dilihat pada Tabel 2.

Tabel 2. Parameter Pemanding

| | Parameter |
|--------------------------------------|----------------------------|
| <i>Optimizer</i> | Adam, SGD, RMSprop, Adamax |
| <i>Dropout setelah pooling layer</i> | 0.05, 0,1 |
| <i>Dropout fully connected layer</i> | 0.25, 0,1 |
| <i>Dense layer</i> | 64, 128 |

2.7 Filter Gabor

Filter Gabor adalah alat untuk merepresentasikan tekstur gambar dengan cara melakukan ekstraksi fitur pada gambar. *Filter Gabor* memiliki keunggulan yaitu pada tingkat invariasi yang digunakan untuk melakukan skala, rotasi dan kemampuan menerjemahkan gambar. *Filter Gabor* dirancang untuk mengekstrak fitur yang disesuaikan dengan inputan gambar. *Filter Gabor* mengganti bobot *kernel* dalam konfigurasi *Convolutional Neural Network (CNN)* (Sarwar, dkk, 2017). Pada penelitian ini, *Filter Gabor* dipasang pada lapisan pertama konvolusional, bertujuan untuk mengurangi kompleksitas komputasi dan mempertahankan kemampuan representasi fitur secara bersamaan. Selain itu, *Grid Search* digunakan untuk menemukan parameter dan memilih *Filter Gabor* yang tepat. Frekuensi, yang telah diuji, adalah 0,1, 0,2, dan 0,4 Hz. Delapan orientasi ($\theta = 0, (\pi/4), (\pi/2), (3\pi/4), \pi, (5\pi/4), (3\pi/2), 2\pi$) diperiksa untuk setiap frekuensi, dan kombinasi terbaik parameter dipilih bagi parameter yang diberikan untuk menunjang peforma dari *Filter Gabor* (Chen, dkk, 2017).

3. HASIL DAN PEMBAHASAN

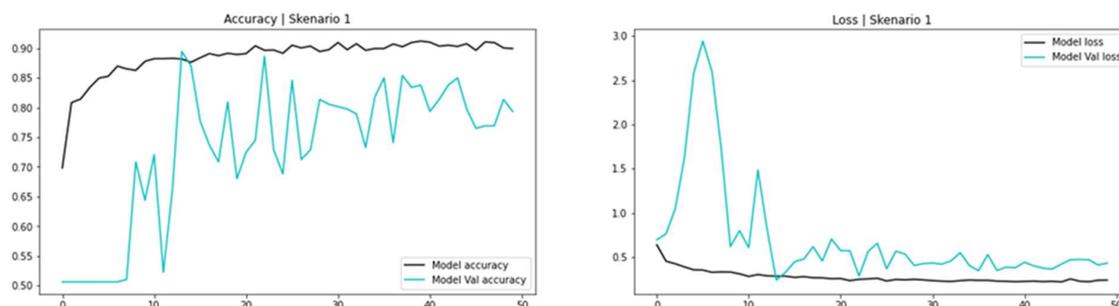
Pengujian dalam penelitian ini menggunakan 3 skenario untuk mengetahui pengaruh dari *hyperparameter tuning* dan *filter gabor* terhadap hasil klasifikasi dari model yang telah diusulkan. Detail skenario pengujian dalam penelitian ini dapat dilihat pada Tabel 3.

Tabel 3. Skenario Pengujian

| Skenario | Penjelasan |
|----------|---|
| 1 | Pengujian model yang telah diusulkan |
| 2 | Pengujian model usulan dengan <i>hyperparameter tuning</i> |
| 3 | Pengujian model dengan <i>hyperparameter tuning</i> dan <i>filter gabor</i> |

3.1 Skenario 1: Pengujian Model

Pada skenario pertama ini, dilakukan pengujian terhadap model yang telah diusulkan pada Gambar 5. Pengujian dilakukan menggunakan *optimizer* SGD dengan *learning rate* sebesar 0.00146, *binary classification*, *epoch* berjumlah 50 dan *batch size* sebesar 32. Hasil dari skenario pertama dapat dilihat pada Gambar 6.

**Gambar 6. Hasil Akurasi dan Loss dari Skenario 1**

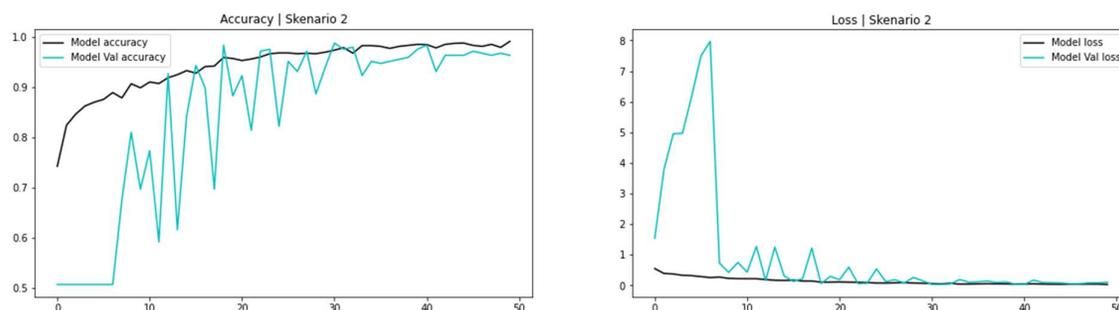
3.2 Skenario 2: Model dengan *Hyperparameter Tuning*

Pada skenario kedua, dilakukan optimasi parameter terhadap model yang diusulkan dengan menggunakan *hyperparameter tuning*. Pelatihan model menggunakan *binary classification*, *epoch* berjumlah 5 dan *batch size* sebesar 32. Parameter yang dibandingkan pada tahap ini dapat dilihat pada Tabel 2. Hasil dari *hyperparameter tuning* dapat dilihat pada Tabel 4.

Tabel 4. Hasil Parameter Terbaik dari Hyperparameter Tuning

| <i>Optimizer</i> | <i>Dense Layer</i> | <i>Dropout Setelah Pooling Layer</i> | <i>Dropout Pada Fully Connected Layer</i> | Akurasi |
|------------------|--------------------|--------------------------------------|---|----------------|
| Adam | 128 | 0.05 | 0.25 | 84.2 |
| Adam | 256 | 0.05 | 0.25 | 81.3 |
| Adam | 128 | 0.1 | 0.5 | 75.7 |
| SGD | 128 | 0.1 | 0.25 | 74.5 |
| SGD | 128 | 0.05 | 0.5 | 74.1 |

Parameter tertinggi dari *hyperparameter tuning* akan menggantikan parameter sebelumnya yang digunakan dalam model usulan di skenario pertama. Pengujian akan dilakukan menggunakan *learning rate* sebesar 0.00146, *binary classification*, *epoch* berjumlah 50 dan *batch size* sebesar 32. Hasil dari skenario kedua dapat dilihat pada Gambar 7.

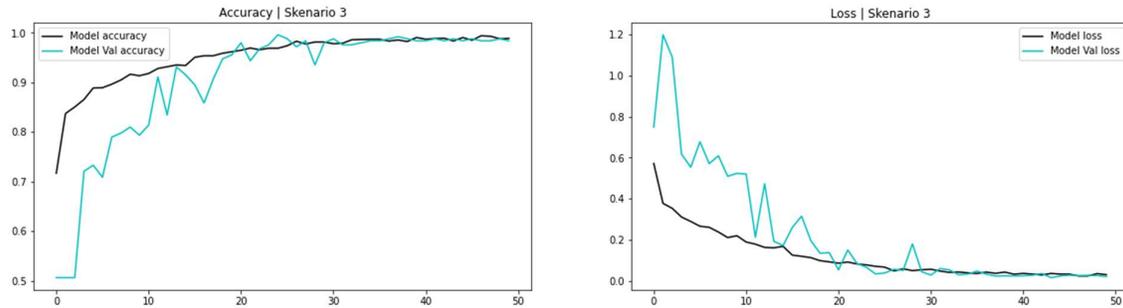


Gambar 7. Hasil Akurasi dan Loss dari Skenario 2

Berdasarkan Gambar 7, dapat dilihat bahwa model menjadi lebih stabil dalam perkembangan akurasi maupun *loss* pada setiap *epoch*. Perbedaan model pada skenario ini dengan model skenario pertama adalah pada *dropout* yang ada di *fully connected layer* dan parameter yang digunakan. Skenario pertama menggunakan nilai *dropout* 0.5 dan *optimizer* SGD berdasarkan model yang diusulkan. Sedangkan skenario ini menggunakan nilai *dropout* 0.25 dan *optimizer* Adam berdasarkan hasil dari *hyperparameter tuning* yang dilakukan sebelumnya. Hal tersebut membuktikan bahwa hasil optimasi parameter dari *hyperparameter tuning* memberikan pengaruh yang signifikan terhadap performa model.

3.3 Skenario 3: Model dengan *Hyperparameter Tuning* dan *Filter Gabor*

Pada skenario ketiga ini, percobaan dilakukan menggunakan model pada skenario kedua yang diberi tambahan *filter gabor* pada *layer* konvolusi pertama. Pengujian model menggunakan *learning rate* sebesar 0.00146, *binary classification*, *epoch* berjumlah 50 dan *batch size* berjumlah 32. Hasil dari skenario ketiga dapat dilihat pada Gambar 8.



Gambar 8. Hasil Akurasi dan Loss dari Skenario 3

Grafik akurasi dan *loss* pada skenario ini lebih stabil daripada dua skenario sebelumnya. Hal tersebut disebabkan oleh *filter gabor* pada *layer* konvolusi pertama dapat mengekstraksi fitur terhadap tekstur citra CT-Scan khususnya bercak putih pada paru-paru terinfeksi COVID-19.

3.4 Analisis Hasil

Berdasarkan hasil dari setiap skenario, terdapat beberapa perbedaan seperti hasil dari skenario pertama dengan skenario kedua dan ketiga, sedangkan skenario kedua dan ketiga mendapatkan hasil yang hampir sama dalam *loss* validasi dan nilai *Area Under Curve* (AUC). Namun, skenario ketiga lebih baik dalam akurasi, *loss*, *precision*, *recall*, *f1-score* dan AUC. Detail dari hasil klasifikasi seluruh skenario dapat dilihat pada Tabel 5.

Tabel 5. Hasil Skenario 1, 2, dan 3

| Model | Train | | Validation | | Test | | Macro Avg | | | AUC |
|------------|-------|------|------------|------|------|------|-----------|--------|----------|-----|
| | Acc | Loss | Acc | Loss | Acc | Loss | Precision | Recall | F1 Score | |
| Skenario 1 | 81.5 | 0.41 | 79.3 | 0.43 | 79.6 | 0.38 | 84 | 79 | 78 | 97 |
| Skenario 2 | 97.5 | 0.06 | 96.4 | 0.10 | 94.4 | 0.15 | 97 | 96 | 96 | 99 |
| Skenario 3 | 98.2 | 0.05 | 97.9 | 0.10 | 96.4 | 0.06 | 98 | 98 | 98 | 99 |

Hasil kombinasi parameter dari *hyperparameter tuning* yang diterapkan pada skenario kedua meningkatkan hasil akurasi dan *loss* validasi sebesar 17.1% dan 33%, meningkatkan *precision*, *recall* dan *F1 score* sebesar 13%, 17% dan 18% jika dibandingkan dengan skenario pertama. Hal tersebut menunjukkan bahwa *hyperparameter tuning* memberikan peningkatan drastis walaupun hanya terdapat perbedaan pada *optimizer* dan nilai *dropout* yang digunakan. Kemudian pada skenario ketiga, model dengan hyperparameter ditambahkan algoritma tekstur analisis *filter gabor*. Penambahan *filter gabor* pada penelitian ini menghasilkan performa terbaik dengan peningkatan akurasi validasi, *precision*, *recall* dan *F1 score* sebesar 1.5%, 1%, 2% dan 2% jika dibandingkan dengan skenario kedua yang tidak menggunakan *filter gabor*.

3.5 Perbandingan dengan Penelitian Sebelumnya

Pada tahap ini, akan diberikan rangkuman dari beberapa penelitian sebelumnya yang menjadi landasan penelitian ini. Rangkuman berisikan mengenai data yang digunakan, distribusi data, metode dan hasil dari beberapa penelitian sebelumnya, kemudian akan disajikan rangkuman dari penelitian ini untuk melihat perbandingan dengan hasil penelitian yang telah dilakukan sebelumnya. Detail mengenai rangkuman perbandingan hasil dengan penelitian yang telah dilakukan sebelumnya dapat dilihat pada Tabel 6.

Tabel 6. Rangkuman Perbandingan Hasil

| Penulis | Dataset | Distribusi Data | Metode | Hasil | |
|----------------------|--|--|---|-----------|-------------|
| | | | | AUC | ACC |
| X. Wang et al., 2020 | Citra CT-Scan = 630 data | Data Train : 449, Data Validasi : 131 <i>Single Validation</i> | CNN DecovNet | 95,9 | 90,1 |
| Silva et al., 2020 | Citra CT-Scan SARS-CoV-2 dan CT-Scan COVID berjumlah 3228 (Data Train, 1252 COVID & 1229 Normal) (Data Test, 349 COVID & 397 Normal) | Data Train : 2481, Data Validasi : 746 <i>Cross Validation</i> | CNN EfficientNet | 90,5 | 87,6 |
| Jaiswal et al., 2020 | Citra CT-Scan SARS-CoV-2 berjumlah 2481 (1252 COVID & 1229 Normal) | <i>Single Validation</i> | CNN <i>Deep Transfer Learning</i> DenseNet201 | - | 96.25 |
| Skenario 1 | Citra CT-Scan SARS-CoV-2 berjumlah 2481 (1252 COVID & 1229 Normal) | Data Train : 1984, Data Validasi : 247, <i>Single Validation</i> | CNN (Model Usulan) | 95 | 95,1 |
| Skenario 2 | Citra CT-Scan SARS-CoV-2 berjumlah 2481 (1252 COVID & 1229 Normal) | Data Train : 1984, Data Validasi : 247, <i>Single Validation</i> | CNN (Model Usulan) dengan <i>Hyperparameter Tuning</i> | 99 | 96,4 |
| Skenario 3 | Citra CT-Scan SARS-CoV-2 berjumlah 2481 (1252 COVID & 1229 Normal) | Data Train : 1984, Data Validasi : 247, <i>Single Validation</i> | <i>Filter Gabor</i> -CNN (Model Usulan) dengan <i>Hyperparameter Tuning</i> | 99 | 97,9 |

Penelitian ini menggunakan *dataset* dan distribusi data dengan *single validation* yang sama dengan penelitian yang dilakukan oleh Jaiswal. Perbedaan penelitian ini dengan yang dilakukan Jaiswal terdapat pada metode yang digunakan. Hasil penelitian Jaiswal mendapatkan akurasi sebesar 96,25% sedangkan pada penelitian ini mendapatkan akurasi sebesar 97,9%. Penelitian lainnya yang sejenis juga dilakukan oleh X. Wang dengan *single validation* dan Silva dengan *cross validation* menggunakan *dataset* yang memiliki jumlah lebih sedikit. Hasil penelitian X. Wang mendapatkan AUC 95,9% dan akurasi 90,1%, sedangkan Silva mendapatkan AUC 90,5% dan akurasi 87,6%. Hasil penelitian ini masih lebih baik dibandingkan penelitian X. Wang dan Silva dalam akurasi maupun AUC. Berdasarkan perbandingan tersebut, model dengan *hyperparameter tuning* dan *filter gabor* pada penelitian ini berhasil melampaui hasil dari Jaiswal dengan *dataset* yang sama maupun berbeda.

4. KESIMPULAN

Berdasarkan penelitian yang dilakukan, hasil penelitian menjadi yang terbaik dari penelitian sebelumnya dengan data yang sama mendapatkan akurasi sebesar 96.25% dan AUC terbesar pada penelitian lainnya sebesar 96,2%, sedangkan penelitian ini mendapatkan AUC sebesar 99% dan akurasi sebesar 97,9%. Maka dapat disimpulkan bahwa model dengan tambahan *hyperparameter tuning* dan *filter gabor* terbukti berhasil meningkatkan hasil klasifikasi. Hal tersebut terbukti dari tiga skenario yang telah dilakukan, peningkatan hasil akurasi dan AUC yang signifikan terjadi pada model dengan *hyperparameter tuning*. Kemudian hasil dari penambahan *filter gabor* membuat akurasi lebih meningkat dan membuat model memiliki hasil yang stabil. Penelitian mengenai klasifikasi COVID-19 menggunakan data citra CT-Scan masih perlu dilakukan untuk meningkatkan akurasi dan mengurangi *loss* dari model klasifikasi. Maka dari itu, penelitian kedepannya disarankan untuk mencoba teknik *preprocessing* agar gambar

dapat lebih jelas untuk proses klasifikasi. Selain itu, dikarenakan masih kurangnya data citra untuk penelitian ini, maka disarankan untuk mencoba teknik augmentasi data lainnya yang lebih baik untuk klasifikasi.

DAFTAR RUJUKAN

- Chen, Y., Zhu, L., Ghamisi, P., Jia, X., Li, G., & Tang, L. (2017). Hyperspectral Images Classification with Gabor Filtering and Convolutional Neural Network. *IEEE Geoscience and Remote Sensing Letters*, *14*(12), 2355–2359. <https://doi.org/10.1109/LGRS.2017.2764915>
- Dani, R., Sugiharto, A., & Winara, G. A. (2015). Aplikasi Pengolahan Citra Dalam Pengenalan Pola Huruf Ngalagena Menggunakan MATLAB. *Konferensi Nasional Sistem & Informatika*, (pp. 9–10).
- El-Kenawy, E. S. M., Ibrahim, A., Mirjalili, S., Eid, M. M., & Hussein, S. E. (2020). Novel feature selection and voting classifier algorithms for COVID-19 classification in CT images. *IEEE Access*, *8*. <https://doi.org/10.1109/ACCESS.2020.3028012>
- Fan, D. P., Zhou, T., Ji, G. P., Zhou, Y., Chen, G., Fu, H., Shen, J., & Shao, L. (2020). Inf-Net: Automatic COVID-19 Lung Infection Segmentation from CT Images. *IEEE Transactions on Medical Imaging*, *39*(8), 2626–2637. <https://doi.org/10.1109/TMI.2020.2996645>
- Freni, F., Meduri, A., Gazia, F., Nicastro, V., Galletti, C., Aragona, P., Galletti, B., & Galletti, F. (2020). Symptomatology in head and neck district in coronavirus disease (COVID-19): A possible neuroinvasive action of SARS-CoV-2. *American Journal of Otolaryngology - Head and Neck Medicine and Surgery*, *41*(5), 102612. <https://doi.org/10.1016/j.amjoto.2020.102612>
- Hariyani, Y. S., Hadiyoso, S., & Siadari, T. S. (2020). Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, *8*(2), 443. <https://doi.org/10.26760/elkomika.v8i2.443>
- Harvey, H. B., & Sotardi, S. T. (2018). The Pareto Principle. *Journal of the American College of Radiology*, *15*(6), 931. <https://doi.org/10.1016/j.jacr.2018.02.026>
- Jaiswal, A., Gianchandani, N., Singh, D., Kumar, V., & Kaur, M. (2020). Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning. *Journal of Biomolecular Structure and Dynamics*, 1–8. <https://doi.org/10.1080/07391102.2020.1788642>
- Loey, M., Manogaran, G., & Khalifa, N. E. M. (2020). A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography

- digital images. *Neural Computing and Applications*, 0123456789. <https://doi.org/10.1007/s00521-020-05437-x>
- Lovse, L., Poitras, S., Dobransky, J., Huang, A., & Beaulé, P. E. (2019). Should the Pareto Principle Be Applied as a Cost Savings Method in Hip and Knee Arthroplasty? *Journal of Arthroplasty*, 34(12), 2841–2845. <https://doi.org/10.1016/j.arth.2019.07.034>
- Polsinelli, M., Cinque, L., & Placidi, G. (2020). A light CNN for detecting COVID-19 from CT scans of the chest. *Pattern Recognition Letters*, 140, 95–100. <https://doi.org/10.1016/j.patrec.2020.10.001>
- Sarwar, S. S., Panda, P., & Roy, K. (2017). Gabor filter assisted energy efficient fast learning convolutional neural networks. *ArXiv*.
- Shi, F., Wang, J., Shi, J., Wu, Z., Wang, Q., Tang, Z., He, K., Shi, Y., & Shen, D. (2020). Review of Artificial Intelligence Techniques in Imaging Data Acquisition, Segmentation and Diagnosis for COVID-19. *IEEE Reviews in Biomedical Engineering*, 3333(c), 1–13. <https://doi.org/10.1109/RBME.2020.2987975>
- Silva, P., Luz, E., Silva, G., Moreira, G., Silva, R., Lucio, D., & Menotti, D. (2020). COVID-19 detection in CT images with deep learning: A voting-based scheme and cross-datasets analysis. *Informatics in Medicine Unlocked*, 20, 100427. <https://doi.org/10.1016/j.imu.2020.100427>
- Singhal, T. (2020). A Review of Coronavirus Disease-2019 (COVID-19). *Indian Journal of Pediatrics*, 87(4), 281–286. <https://doi.org/10.1007/s12098-020-03263-6>
- Soares, E., Angelov, P., Biaso, S., Higa Froes, M., & Kanda Abe, D. (2020). *SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification*. 1–8. <https://doi.org/10.1101/2020.04.24.20078584>
- Tripathi, A. M., & Mishra, A. (2020). *Fuzzy Unique Image Transformation: Defense Against Adversarial Attacks On Deep COVID-19 Models*. 14(8), 1–11. <http://arxiv.org/abs/2009.04004>
- Ucar, F., & Korkmaz, D. (2020). COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Medical Hypotheses*, 140(April), 109761. <https://doi.org/10.1016/j.mehy.2020.109761>
- Wang, X., Deng, X., Fu, Q., Zhou, Q., Feng, J., Ma, H., Liu, W., & Zheng, C. (2020). A Weakly-Supervised Framework for COVID-19 Classification and Lesion Localization from Chest CT. *IEEE Transactions on Medical Imaging*, 39(8), 2615–2625. <https://doi.org/10.1109/TMI.2020.2995965>
- Wang, Z., Liu, Q., & Dou, Q. (2020). Contrastive Cross-Site Learning with Redesigned Net for

Minarno, dkk

COVID-19 CT Classification. *IEEE Journal of Biomedical and Health Informatics*, 24(10), 2806–2813. <https://doi.org/10.1109/JBHI.2020.3023246>