

OPTIMASI CONVOLUTIONAL NEURAL NETWORK UNTUK DETEKSI COVID-19 PADA X-RAY THORAX BERBASIS DROPOUT

I Gede Totok Suryawan^{*1}, I Putu Agus Eka Darma Udayana²

^{1,2}Institut Bisnis dan Teknologi Indonesia (INSTIKI), Denpasar
Email: ¹totok.suryawan@stiki-indonesia.ac.id, ²agus.ekadarma@gmail.com

*Penulis Korespondensi

(Naskah masuk: 14 Juni 2021, diterima untuk diterbitkan: 31 Mei 2022)

Abstrak

Pandemi COVID-19 yang melanda Indonesia sejak pertengahan tahun 2020 telah memberikan dampak luar biasa pada infrastruktur medis di Indonesia. Angka rata-rata penyebaran virus COVID-19 yang cukup tinggi membuat monitoring bed occupancy rate menjadi sebuah tantangan tersendiri. Dengan adanya penetrasi Artificial Intelligence yang tepat pada sistem medis di Indonesia, diharapkan dapat membantu terjadinya transfer knowledge antar paramedis menjadi lebih efektif. Salah satunya dengan menggunakan Deep learning yaitu Convolutional Neural Network (CNN) yang sudah terbukti merupakan salah satu metode yang dapat digunakan untuk melakukan skrining pasien dan mendeteksi COVID-19. Namun untuk melatih sebuah classifier CNN yang ampuh dan siap digunakan di dunia nyata membutuhkan computing power yang besar dan umumnya training rate yang lama. Penelitian ini bertujuan untuk membuat arsitektur jaringan syaraf tiruan berbasis deep learning yang lebih cepat dan efisien dengan pembuatan network yang lebih ramping sehingga lebih mudah dibuat oleh orang lain tanpa harus memiliki computing power yang besar. Metode yang digunakan adalah dengan menyisipkan dropout layer pada sistem jaringan syaraf tiruan. Metode ini akan memaksa sistem untuk belajar memakai rute yang tersingkat dengan cara menghilangkan beberapa node secara acak. Arsitektur ini kemudian diuji pada data ronsen thorax penyintas COVID-19 dan kemudian dibandingkan dengan arsitektur lainnya yang sama-sama memakai pendekatan deep learning. Setelah ditraining menggunakan 500 data COVID-19 thorax X-Ray public database dan diuji dengan jumlah data yang sama, classifier yang menggunakan arsitektur ini mampu menghasilkan akurasi sebesar 95,20%, precision 94,80%, recall 95,58%, specificity 94,88%, NVP sebesar 95,60%, F-Score sebesar 95,18 dan dapat menghemat waktu training sampai 62% dibandingkan dengan arsitektur deep learning lainnya.

Kata kunci: Deep Learning, Convolutional Neural Network (CNN), Dropout Layer, Thorax X-Ray, COVID-19.

OPTIMASI CONVOLUTIONAL NEURAL NETWORK UNTUK DETEKSI COVID-19 PADA X-RAY THORAX BERBASIS DROPOUT

Abstract

The COVID-19 pandemic that hit Indonesia in mid-2020 had a tremendous impact on medical infrastructure in Indonesia. The virus made monitoring the bed occupancy rate became a challenge in itself. New approach can be taken to fight the crisis. The Convolutional Neural Network (CNN), which has proved to be one of the methods that can use to screen patients and detect COVID-19, also have its own problem because it requires enormous computing power and generally a long training rate. Therefore, this study aimed to tackle that problem by creating a leaner network. Thus, it is easier for others to build without having enormous computing power. The method used was to insert a dropout layer on the artificial network system. This method will force the system to learn using the shortest route by eliminating some nodes at random. Then, this architecture was tested on chest X-ray data of COVID-19 survivors and compared with other architectures that both used a deep learning approach. It proved that when this system was tested with COVID-19 thorax x-ray public database data, the classifier that used this architecture could achieve an accuracy rate of 95.20% followed by precision and recall value reaching 94.80% and 94.80% respectively and last but not least F-score of 95.18% and Negative Predictive value of 95.60% It could also save training time up to 62% compared to other deep learning architectures. Using dropout layers proved could produce more efficient layers and more powerful classifiers while keeping training time to a minimum.

Keywords: Deep Learning, Convolutional Neural Network (CNN), Dropout Layer, Thorax X-Ray, COVID-19.

1. PENDAHULUAN

Pandemi Covid-19 yang melanda Indonesia sejak 2019 yang lalu telah menempatkan Indonesia dalam sebuah krisis kesehatan yang masif. Sistem kesehatan di Indonesia diuji kesiapannya dan kemampuan adaptasinya. Pada kasus covid-19 ini kecepatan deteksi dan penanganan dini adalah kunci untuk menghindari kematian pasien sehingga bisa menurunkan angka mortalitas sampai mengurangi tekanan pada infrastruktur kesehatan terutama rumah sakit dalam penanganan penyakitnya (Uscher-Pines *et al.*, 2006).

Prioritas penanganan sangatlah penting untuk menghindari bed shortage pada daerah-daerah merah Covid-19. Selain menambah unit kesehatan siap tanggap Covid-19 memaksimalkan sumber daya yang ada dan delegasi tugas dinilai cukup efektif untuk mengurangi stress dan fatigue pada petugas medis yang menangani pandemi (Hou *et al.*, 2020). Transfer expert knowledge antar petugas medis sebenarnya dapat di akselerasi dengan artificial intelligence (AI) (Guo and Li, 2018) salah satu contoh terbaru adalah dengan terciptanya Genose Diagnostic yang memakai artificial intelligence untuk detection dan tracing Covid-19 (Vahrn, 2021).

Sebagai contoh di lingkungan rumah sakit salah satu proses diagnosa yang umum dilakukan untuk suspect penyintas Covid-19 adalah x-ray thorax selain akurat tes ini terbukti dapat mendeteksi tingkat progresi virus pada tubuh seseorang dan bisa cepat dilihat hasilnya dibanding tes lainnya seperti contohnya serology testing (Elgendi *et al.*, 2021). Pembacaan X-Ray thorax berbasis artificial intelligence sebenarnya bukan hal baru, beberapa penelitian terdahulu penggunaan teknologi artificial intelligence berbasis neural network sudah dilakukan untuk mendeteksi penyakit respiratori seperti TBC, namun penelitian yang dilakukan belumlah dikhususkan untuk penyakit Covid-19 (Liu and Alcantara, 2016) ataupun pneumonia (Rahman *et al.*, 2020). Saat ini metode berbasis neural network yang dikenal cukup akurat adalah Convolutional Neural Network (CNN) yang dipadukan dengan pembelajaran berbasis deep learning yang di beberapa penelitian bahkan sudah digunakan untuk membantu mendeteksi Covid-19 (Hou *et al.*, 2020) namun approach atau pendekatan ini umumnya memiliki kelemahan yaitu memiliki biaya komputasi yang besar waktu training yang lama dan kemampuan hardware yang tinggi untuk implementasinya (Shao *et al.*, 2020). Akan tetapi timbal balik yang ditawarkan juga sangatlah besar karena umumnya approach ini memiliki nilai akurasi yang baik untuk beberapa kasus pengenalan citra yang kompleks sebut saja pengenalan hasil x-ray (Suryawan and Udayana, 2020), pengenalan hasil MRI (Liu *et al.*, 2018), atau pengenalan hasil CT-scan (Grewal *et al.*, 2018), bahkan termasuk state of the art dalam bidang studi face recognition dalam satu dekade belakangan ini (Ghazi and Ekenel, 2016).

Deep neural network adalah sebutan untuk menggambarkan sebuah jaringan syaraf tiruan yang memiliki banyak sekali non linear hidden layer yang dimana mempunyai ciri khas hubungan yang sangat rumit antara input dan outputnya namun ternyata tidak semua hubungan tersebut berguna kebanyakan dari hubungan antar node ini adalah hasil dari sampling noise yang hanya akan muncul dalam training set dan bukan dunia nyata ini tentunya akan menimbulkan sebuah fenomena yang disebut overfitting (Rice, Wong and Kolter, 2020). Fenomena ini adalah momok lama bagi sistem pintar berbasis jaringan syaraf tiruan yang dimana sudah banyak usaha yang dilakukan untuk mengurangi dampaknya bahkan studi terlama sudah dilakukan sejak tahun 1992 dengan diperkenalkannya soft-weight sharing (Nowlan, 2018).

Dengan sifat natural dari jaringan syaraf tiruan yang memiliki perhitungan yang rumit cara terbaik untuk mengurangi masalah overfitting yang dilakukannya tentu dengan meratakan nilai dari tiap input dalam sebanyak banyaknya kondisi. sebuah teori yang akan bekerja untuk model yang tergolong kecil (Zhang *et al.*, 2018), namun solusi yang ditawarkan masih memiliki tingkat kebutuhan komputasi yang besar. Pendekatan kedua adalah dengan memberikan kombinasi pada deep neural network model yang dalam banyak kesempatan sudah terbukti selalu hampir berhasil membuat performa sebuah model machine learning menjadi lebih baik (Sun *et al.*, 2018). Namun, dengan sistem jaringan syaraf tiruan yang besar meniru fundamental berpikir seperti itu yang bergantung pada averaging operation bukanlah sesuatu yang bijak karena perhitungannya akan sangat lama atau computationally expensive belum lagi jika sistem yang digabungkan memiliki arsitektur yang jauh berbeda dan dilatih dengan dataset yang berbeda. Namun itu belum memperhitungkan masalah hyperparameter finding problem yang akan terjadi yang tentunya tidak menyelesaikan masalah komputasi yang mahal seperti yang telah kita sebut sebelumnya. Dropout adalah teknik yang lebih cocok untuk menangani masalah ini dia mengurangi overfitting dan memberikan solusi untuk menggabungkan berbagai macam jenis arsitektur jaringan syaraf tiruan. Kata dropout mengacu pada tindakan menghilangkan unit neural network (bersama input yang dia punya koneksi dan juga outputnya).

Tujuan besar dari dropout operation adalah merampingkan jaringan yang ada dalam kata lain mengefisiensikan jaringan syaraf tiruan dimana yang dirampingkan adalah jaringan-jaringan yang tidak terpilih dari proses dropout acak. Jika kita matematikakan hubungan dari sebuah network biasa dan sebuah network ramping kita bisa mendapatkan persamaan, N unit mempunyai kesempatan membentuk 2^N neural network ramping dan karena tiap unit neural network tersebut saling berbagi weight atau bobot maka jumlah total parameter akan

tetap sama $O(N^2)$ atau memungkinkan untuk kurang dari 0, kemudian jaringan yang lebih ramping ini nantinya di random dan di training. Dengan model dropout ini mampu menghasilkan akurasi 96,35 dalam mendeteksi COVID-19 pada X-Ray Image, dan 99,08 pada CT Scan Image (Abdar *et al.*, 2021). Model dropout juga digunakan untuk mendeteksi COVID-19 pada gambar USG paru-paru dengan membandingkan struktur jaringan VGG19, InceptionV3, Xception, dan ResNet50, hasil penelitian menunjukkan Jaringan berbasis InceptionV3 mencapai ACC rata-rata lebih tinggi yaitu sebesar 89,1%, BACC sebesar 89,3% dan AUC-ROC sebesar 97% dari baseline POCOVID-net, VGG19-, dan Model berbasis ResNet50 (Diaz-Escobar *et al.*, 2021). Selain dua hasil penelitian tersebut, model dropout pada hasil penelitian lain juga menunjukkan CNN dengan sepuluh convolutional layer dan 15 epoch memberikan performa terbaik 88,23% pelatihan akurasi validasi 85,94% (Shinde and Mane, 2021).

Jadi tujuan dari penelitian ini adalah menyelesaikan masalah metode neural network yang menghabiskan biaya komputasi yang besar waktu training yang lama dan kemampuan hardware yang tinggi dengan cara melakukan dropout operation. Kami menemukan bahwa melatih neural network atau jaringan syaraf tiruan dengan cara ini dan memadukannya dengan averaging method dapat membuat performa deep learning network yang lebih baik dengan tingkat lower generalization error yang cenderung lebih rendah dan lebih robust karena sudah teruji dengan berbagai macam jenis dataset (Srivastava *et al.*, 2014).

2. METODE PENELITIAN


Penelitian ini dirancang berfokus pada studi kasus klasifikasi gambar x-ray untuk mendeteksi penyakit Covid-19 menggunakan 120 gambar x-ray untuk data training dengan masing-masing data training sebelumnya telah dilakukan preprocessing dengan menggunakan mean denoising. kemudian model akan di training untuk mempelajari seberapa baik model akan bekerja untuk mendeteksi kemungkinan objek terinfeksi Covid-19. Kemudian akan dibuat model kedua, dimana pada model kedua ini akan disisipkan dropout layer yang dimana akan dipilih secara acak oleh sistem dan dengan ketentuan

network yang dieliminasi adalah 20% dari overall system. Kemudian perbandingan akan dilakukan dengan data uji sebesar 120 pcs dan akan dibandingkan dengan 10 fold cross validation, hasil data uji tersebut sebagai tingkat akurasi dari model yang dikembangkan. Pada eksperimen ini juga akan ditarik data berupa jumlah epoch yang dicapai tiap sesi training untuk mencapai akurasi diatas 90 persen dan juga jumlah waktu yang dilakukan untuk melakukan training phase pada setiap iterasi untuk menyelesaikan masalah lamanya training waktu pada metode sebelumnya. Tahapan yang dilakukan pada penelitian ini terkait dalam pembentukan classifier pendeteksi Covid-19 dapat dilihat dalam Gambar 1 berikut ini.

Seperti yang terlihat pada Gambar 1 tahap pertama dimulai dengan mengambil feed data berupa data gambar yang diambil dari Covid-19 thorax x-ray public database, training dilakukan dengan berikan sebanyak 240 gambar dengan data uji masing-masing kelas sebesar 120 gambar untuk hasil thorax x-ray yang negatif dan 120 gambar untuk thorax x-ray yang positif dan menyiapkan tensor dasar berukuran 128 x 128 pixel yang dimana akan dilakukan feed ke dalam neural network berbasis CNN dengan berbagai macam ukuran neuron dengan kernel yang sama kemudian pada akhirnya semua layer digabungkan menjadi satu dan diberikan nilai dropout sebesar 20 persen yang dimana ini bertujuan untuk memutus koneksi antar layer secara random yang dimana nanti akan dipaksa untuk membentuk layer baru yang lebih efisien daripada layer sebelumnya.

Dua layer pada Gambar 4 akan dibandingkan dari segi efektifitas dan lamanya waktu training serta divalidasi juga dengan metode 10 fold cross validation dan hasilnya disajikan dalam tabel.

Detail dari tahapan skema deep learning yang diusulkan dapat dilihat pada Gambar 3, dimana proses pertama dimulai dengan memahami dan merapikan data yang diambil dari Brixia dataset webpage kemudian dari data tersebut diberikan tindakan penyamaan data dan dilanjutkan dengan pembuatan desain AI. CNN yang mengimplementasikan pendekatan deep learning sebagai salah satu bentuk dari AI didesain ulang dan juga diberikan layer baru berupa dropout layer. Selanjutnya hasil modifikasi CNN ini dibandingkan dengan model yang lama melalui beberapa pengujian.



Gambar 1. Arsitektur CNN yang Diusulkan




Gambar 2. Paru-Paru Normal



Gambar 3. Paru-Paru Terinfeksi COVID-19

Proses dropout layer diilustrasikan seperti gambar 4 berikut ini.

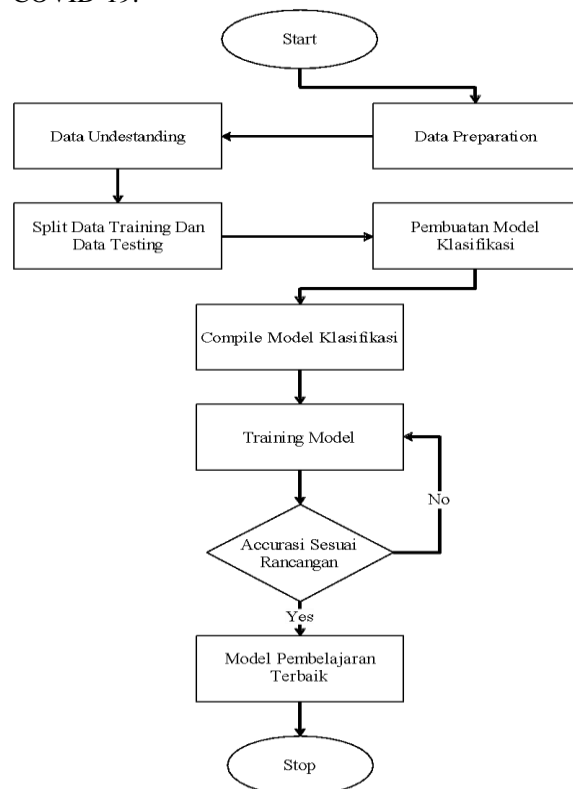


Gambar 4. Ilustrasi Dropout Layer

Model deep learning yang diusulkan menggunakan media supervised data, pada supervised data model ini dilakukan dropout layer, metode ini dibuat untuk mengatasi masalah overfitting pada jaringan syaraf tiruan yang sering terjadi yang dipacu oleh dataset training yang besar terutama sejak dipopulerkannya pendekatan deep learning oleh Yann Lecun. Solusi pendekatan dropout ini sangatlah sederhana dimana dropout akan menghilangkan beberapa neuron beserta koneksi yang diberikan oleh neuron tersebut secara random. Dengan menghilangkan koneksi ini dropout approach memaksa jaringan syaraf tiruan untuk

menjadi lebih efisien karena hanya akan mentraining jaringan yang tidak terkena proses dropout. Mekanisme dropout ini tidak akan mengubah tujuan utama dari neural network tersebut karena proses penting seperti *benchmark (network metric)* metode belajar (*activation function*) dan langkah koreksi per langkahnya (*correction step*) tidak akan berubah sama sekali, hanya saja network akan dipaksa bekerja dengan resources yang lebih ringkas dan hemat.

Sumber data mentah atau dataset yang digunakan dalam penelitian ini adalah data berupa hasil rontgen terpapar COVID-19 di bagian thorax yang merupakan hasil dari pengambilan data rekam medis dari sebuah rumah sakit di Spanyol dimana data bersifat anonymous dan memuat data terpapar COVID-19.



Gambar 5. Tahapan Skema Deep Learning yang Diusulkan

Seperti yang terlihat pada Gambar 5 bahwa proses pertama yang dilakukan pada skema ini adalah data preparation atau persiapan data, data preparation ini dilakukan dengan menyamakan data, setiap data disamakan ukurannya dan diberikan image preprocessing berupa operasi denoising untuk mengurangi kemungkinan data yang buruk (yang umum terjadi di citra X-Ray).

Proses kedua adalah data understanding dimana pada penelitian ini dilakukan pelabelan tiap data berdasarkan pengetahuan dari 3 ahli radiologi yang telah melakukan pengamatan dan melakukan pelabelan data medis yang berupa kumpulan gejala COVID-19 dan pengelompokan tingkatan paparan COVID-19 yang dibagi menjadi 3 yaitu; (1) tidak adanya progresif virus di paru-paru, (2) ada infeksi ringan di paru-paru (3), ada infeksi berat di paru-paru, kemudian masing-masing data akan dikelompokkan dalam satu folder tertentu untuk mempermudah training dan testing. Proses selanjutnya adalah proses Pembagian data dimana data dibagi menjadi dua bagian yaitu berupa data latih atau disebut data training dan juga data testing atau biasa juga dikenal sebagai data uji Nantinya sumber pemahaman dari kecerdasan buatan ini akan berasal dari data training dan pemahaman yang dipergunakan komputer Akan diuji akurasi Menggunakan data testing yang telah disediakan kunci jawabannya sebagai alat ukur akurasi sistem Jumlah data training yang digunakan dalam penelitian ini sebanyak 1.500 gambar X-Ray dan data testing sebesar 10% dari data training yaitu 150 gambar.

Dalam tahapan pelatihan data atau yang biasa disebut sebagai data training. himpunan data tadi dibagi menjadi dua yang pertama disebut training set adalah sebuah himpunan data yang digunakan untuk melatih atau membangun mesin classifier. Pada penelitian ini jumlah data latih adalah 70 % dari jumlah dataset atau sebanyak 1.050 gambar. himpunan data yang kedua disebut sebagai validation set atau data validasi. Pengertiannya ini adalah data yang digunakan untuk mengoptimasi mesin classifier. Singkatnya model / mesin classifier dilatih menggunakan data latih dan kinerja akan dievaluasi dengan data validasi. Hal ini berguna untuk generalisasi agar model mampu mengenali pola secara umum. Jumlah validation set pada penelitian ini adalah 30% dari jumlah dataset yaitu sebanyak 450 gambar.

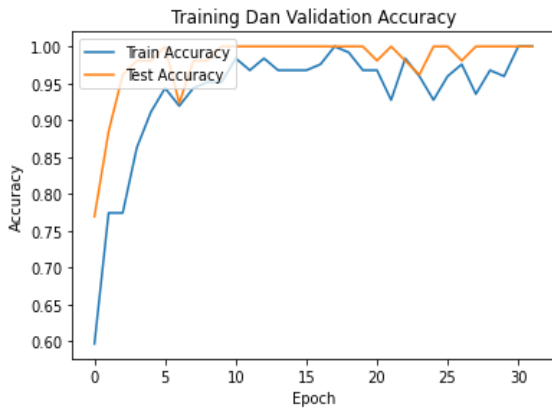
Proses keempat adalah Membuat model klasifikasi klasifikasi dibuat dengan memanipulasi layer fitur yang ditugaskan mendapatkan data dari inputan. Input layer yang baik dibuat dengan membuat layer sesuai piksel gambar dan jumlah hidden layer yang diinginkan. Dimana dalam hidden layer ini tiap bobot dari neuron akan dimanipulasi hidden layer ini arsitekturnya dapat diganti ganti sampai menemukan kombinasi yang terbaik dan diakhir ditentukan jumlah hidden layer berupa konstanta 3 hidden layer. Jumlah node di masing-

masing layer juga ditentukan melalui konstanta dimana dalam setiap layer diisi sejumlah 128 nodes fungsi aktivasi. Fungsi aktivasi atau fungsi matematika pembelajaran dari network ini untuk menentukan output dari node tersebut yang diberikan saluran input. Fungsi aktivasi yang digunakan dalam penelitian ini adalah relu dan softmax.


Proses selanjutnya adalah proses compile model klasifikasi untuk menentukan proses belajar dari neural network yang diprogram untuk menjadi mesin cerdas, pengaturan model klasifikasi yang digunakan dalam penelitian ini adalah (a) pengaturan kecepatan belajar, kecepatan belajar atau disebut juga sebagai learning rate adalah parameter pengaturan dalam algoritma untuk optimalisasi, dimana learning rate atau rata rata belajar ini akan menentukan yang jumlah perbaikan dalam setiap langkah (step) pembelajaran pada setiap proses belajar sistem akan bergerak mengikuti kurva loss function. Karena fungsi matematika ini akan mempengaruhi sejauh mana informasi baru ini menggantikan informasi informasi lama, secara gamblang angka ini melambangkan cepatnya pemahaman sebuah mesin angka kecepatan pembelajaran atau *learning rate* yang digunakan dalam penelitian ini mulai dari 0.1 sampai dengan 0.0001 dengan harapan didapatkan hasil terbaik dari model yang dibangun. (b) Pemilihan metode optimasi untuk menghasilkan model yang optimal dimana pada penelitian ini menggunakan optimizer adam. (c) Pemilihan fungsi loss atau loss function yaitu sebuah fungsi yang melambangkan representasi matematis seberapa dekat atau berbeda model yang dihasilkan dengan hasil yang diharapkan oleh peneliti, sementara error adalah sebuah terminologi yaitu sebuah ukuran untuk mengukur akurasi dari sebuah model. Untuk menghasilkan model optimal pada penelitian ini menggunakan loss function Cross-Entropy, yang sudah umum digunakan pada kasus penggolongan binary. (d) Pemilihan matriks atau metode pengukuran untuk dijadikan acuan penilaian konsep belajar AI yang dilatih, apakah AI yang dilatih masih harus belajar ataukah tidak (sudah siap diuji diluar setting lab) matrik yang yang digunakan dalam penelitian ini adalah akurasi model dalam mendeteksi testing set dalam kerangka proses training.

3. HASIL DAN PEMBAHASAN

Untuk menghasilkan hasil yang maksimal diperlukan proses training dan validasi penerapan metode CNN dropout layer dengan akurasi yang tertinggi dan loss terendah. Dari penerapan arsitektur yang dikembangkan hasil training dapat dilihat pada Gambar 6, sedangkan loss dari setiap training dan validasi yang dilakukan dapat dilihat pada Gambar 6 berikut ini.




Gambar 6. Hasil Training Dan Validasi Akurasi



Gambar 7. Hasil Training Dan Validasi Loss

Gambar 7 menunjukkan hasil training dan akurasi dari arsitektur yang dikembangkan bisa mencapai 1 dengan tingkat loss dibawah 0,2 seperti yang terlihat pada Gambar 8. Hal ini menunjukkan bahwa arsitektur yang dikembangkan memiliki tingkat akurasi yang tinggi. Selain menguji tingkat akurasi pada penelitian ini juga dilakukan pengukuran waktu training dari arsitektur yang dikembangkan dan dibandingkan dengan arsitektur CNN tanpa dropout layer. Hasil pengukuran menunjukkan bahwa, arsitektur CNN dengan dropout layer membutuhkan waktu training sebesar 237 detik dan arsitektur CNN tanpa dropout layer membutuhkan waktu sebesar 436 detik. Berdasarkan hasil pengujian waktu training, arsitektur yang dikembangkan bisa menyelesaikan training 163 detik lebih cepat daripada model training CNN tanpa dropout layer.



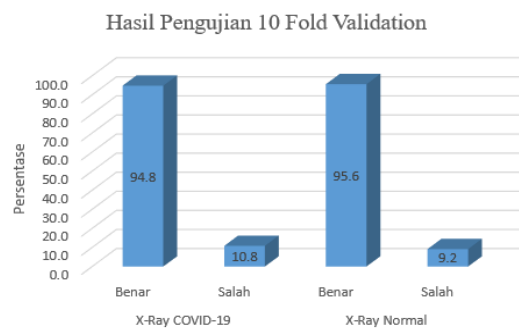
Gambar 8. Hasil Perbandingan Waktu Training Dengan Dropout Layer

Eksperimen arsitektur CNN dengan dropout layer ini diuji menggunakan COVID-19 thorax x-ray public database dengan melatih 2 buah neural network yang berbeda, dimana masing-masing neural network di training menggunakan 500 gambar dengan spesifikasi ukuran yang sama dan diuji menggunakan data uji sebanyak 500 buah data uji yang disebar sesuai ketentuan metode 10 fold cross validation. Berikut Tabel 1 dan Gambar 9 merupakan perbandingan hasil pengujian menggunakan metode 10 fold cross validation.

Tabel 1. Hasil Pengujian 10 Fold Cross Validation

Fold Ke	X-Ray COVID-19		X-Ray Normal	
	Benar	Salah	Benar	Salah
1	24	1	24	1
2	23	2	24	1
3	23	2	24	1
4	24	1	24	1
5	24	1	24	1
6	24	1	24	1
7	24	1	24	1
8	23	2	24	1
9	24	1	23	2
10	24	1	24	1
Persentase (%)	94.8	10.8	95.6	9.2

Gambar 9 menunjukkan bahwa arsitektur yang dikembangkan mampu menghasilkan akurasi sebesar 97% dalam melakukan klasifikasi Covid-19 thorax x-ray. Hasil ini menunjukkan eksperimen metode CNN dengan dropout-enforced layer pada percobaan ini berhasil mengalahkan performa classifier neural network berbasis CNN yang biasa sebesar 3,58% pada suatu masa tes uji seperti yang terlihat pada tabel 2.




Gambar 9. Hasil Pengujian 10 Fold Cross Validation

Tabel 2. Tabel Perbandingan Akurasi Classifier

No.	Metode	Data	Akurasi (100%)
1	CNN Control	X-Ray Paru Positif COVID-19	91,00
2	CNN + Mean Denoising	X-Ray Paru Positif COVID-19	93.35

No.	Metode	Data	Akurasi (100%)
3	CNN + Mean Denoising Coloring	X-Ray Paru Positif COVID-19	92,21
4	CNN + Contrast Enhancement	X-Ray Paru Positif COVID-19	90,25
5	CNN + Dropout Layer	X-Ray Paru Positif COVID19	95,20

Berdasarkan perbandingan tabel 2, gambar 10 adalah ilustrasi dari perbedaan akurasi dari setiap kombinasi metode yang ditawarkan.



Gambar 10. Perbandingan Akurasi Classifier

Selain melakukan pengujian akurasi dengan 10 fold cross validation, peneliti juga melakukan pengujian precision, recall, specificity dan F1-Score. Berbeda dengan pengujian akurasi sebelumnya yang digunakan untuk mengevaluasi kinerja metode secara keseluruhan, pengujian precision, recall, specificity dan f1-score digunakan untuk melihat kinerja klasifikasi metode yang ditawarkan untuk setiap fold data pengujian pada kasus metode CNN yang dikombinasikan dengan dropout layer.

Tabel 3. Hasil Pengujian Precision, Recall dan F-Score Metode CNN + Dropout Layer

Fold ke	Precision (%)	Recall (%)	F-Score (%)
1	96.00	96.00	96.00
2	92.00	95.83	93.88
3	92.00	95.83	93.88
4	96.00	96.00	96.00
5	96.00	96.00	96.00
6	96.00	96.00	96.00
7	96.00	96.00	96.00
8	92.00	95.83	93.88
9	96.00	92.31	94.12
10	96.00	96.00	96.00
Rata-Rata (%)	94.80	95.58	95.18

Tabel 3 adalah tabel hasil pengujian yang dilakukan dengan penerapan 10 fold validation, dimana setiap fold menghasilkan nilai pengujian yang beragam, dimana jika diambil rata nilai pengujian precision sebesar 94,80%, recall sebesar 95,58% dan F-Score sebesar 95,18%.

Tabel 4. Hasil Pengujian Specificity, NPV dan Accuracy Metode CNN + Dropout Layer

Fold ke	Specificity (%)	NPV (%)	Accuracy (%)
1	96.00	96.00	96.00
2	92.31	96.00	94.00
3	92.31	96.00	94.00
4	96.00	96.00	96.00
5	96.00	96.00	96.00
6	96.00	96.00	96.00
7	96.00	96.00	96.00
8	92.31	96.00	94.00
9	95.83	92.00	94.00
10	96.00	96.00	96.00
Rata-Rata (%)	94.88	95.60	95.20

Nilai yang didapat pada pengujian tabel 3, jika dibandingkan memiliki nilai yang hampir mirip dengan pengujian tabel 4. Dimana, jika diambil dinilai rata-rata dari setiap pengujian yang dilakukan dari tabel 3 dan 4 memiliki rentang nilai rata-rata antara 94% sampai dengan 95%.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, perbedaan arsitektur CNN dalam pembuatan sistem cerdas ternyata dapat mempengaruhi akurasi sistem dalam mengenali thorax x-ray yang terinfeksi COVID-19 dan thorax x-ray yang tidak terinfeksi COVID-19. Penambahan dropout layer pada sistem cerdas yang berbasis CNN selain dapat meningkatkan akurasi sampai dengan 95.20 % dengan nilai presisi mencapai 94,80% dengan recall 95.58%, specificity 94,88%, NPV 95,60% dan F-score sebesar 95.18%, metode ini juga dapat mengurangi waktu training sampai 64% pada satu periode training dan validation dibandingkan dengan dengan arsitektur CNN tanpa menggunakan dropout layer.

UCAPAN TERIMA KASIH

Penelitian ini didanai oleh LPPM STMIK STIKOM Indonesia dan STMIK STIKOM Indonesia dalam skema Pusat Studi COVID-19. Penulis mengucapkan terima kasih kepada seluruh tim yang telah berkontribusi dalam pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- ABDAR, M., *dkk.* 2021. UncertaintyFuseNet: Robust Uncertainty-aware Hierarchical Feature Fusion with Ensemble Monte Carlo Dropout for COVID-19 Detection. *IEEE TRANSACTIONS*, pp. 1–16. Available at: <http://arxiv.org/abs/2105.08590>.
- DIAZ-ESCOBAR, J., *dkk.* 2021. Deep-learning based detection of COVID-19 using lung ultrasound imagery. *PLoS ONE*, 16(8 August), pp. 1–21. doi: 10.1371/journal.pone.0255886.
- ELGENDI, M., *dkk.* 2021. The Effectiveness of

- Image Augmentation in Deep Learning Networks for Detecting COVID-19: A Geometric Transformation Perspective. *Frontiers in Medicine*. doi: 10.3389/fmed.2021.629134.
- GHAZI, M. M. & EKENEL, H. K. 2016. A Comprehensive Analysis of Deep Learning Based Representation for Face Recognition. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, pp. 102–109. doi: 10.1109/CVPRW.2016.20.
- GREWAL, M. , dkk. 2018. RADnet: Radiologist level accuracy using deep learning for hemorrhage detection in CT scans. *Proceedings - International Symposium on Biomedical Imaging*, 2018-April(Isbi), pp. 281–284. doi: 10.1109/ISBI.2018.8363574.
- GUO, J. & LI, B. 2018. The Application of Medical Artificial Intelligence Technology in Rural Areas of Developing Countries. *Health Equity*, 2(1), pp. 174–181. doi: 10.1089/hecq.2018.0037.
- HOU, T., dkk. 2020. Self-efficacy and fatigue among health care workers during COVID-19 outbreak: A moderated mediation model of posttraumatic stress disorder symptoms and negative coping. pp. 1–21. doi: 10.21203/rs.3.rs-23066/v1.
- LIU, C. & ALCANTARA, M. F. 2016. Tx-Cnn : Detecting Tuberculosis In Chest X-Ray Images Using Convolutional Neural Network Partners In Health Per ' U'. *2017 IEEE International Conference on Image Processing (ICIP)*, doi: 10.1109/ICIP.2017.8296695.
- LIU, J., dkk. 2018. Applications of deep learning to MRI Images: A survey. *Big Data Mining and Analytics*, 1(1), pp. 1–18. doi: 10.26599/BDMA.2018.9020001.
- NOWLAN, S. J. 2018. Simplifying Neural Networks by Soft Weight Sharing. *The Mathematics of Generalization*, 493, pp. 373–394. doi: 10.1201/9780429492525-13.
- RAHMAN, T., dkk. 2020. Transfer learning with deep Convolutional Neural Network (CNN) for pneumonia detection using chest X-ray', *Applied Sciences (Switzerland)*, 10(9). doi: 10.3390/app10093233.
- RICE, L., WONG, E. & KOLTER, J. Z. 2020. Overfitting in adversarially robust deep learning', *arXiv*.
- SHAO, S., dkk. 2020. Hardware for Machine Learning Course Overview Instructor Teaching Assistants Lectures and Office Hours', *Berkeley University*, pp. 1–5.
- SHINDE, S. V & MANE, D. T. 2021. Deep Learning for COVID-19: COVID-19 Detection Based on Chest X-Ray Images by the Fusion of Deep Learning and Machine Learning Techniques', *Understanding COVID-19: The Role of Computational Intelligence. Studies in Computational Intelligence*, 963, pp. 471–500. doi: 10.1007/978-3-030-74761-9_21.
- SRIVASTAVA, N., dkk. 2014. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 299(3–4), pp. 345–350. doi: 10.1016/0370-2693(93)90272-J.
- SUN, G, dkk. 2018. Combined Deep Learning and Multiscale Segmentation for Rapid High Resolution Damage Mapping. *Proceedings - 2017 IEEE International Conference on Internet of Things, IEEE Green Computing and Communications, IEEE Cyber, Physical and Social Computing, IEEE Smart Data, iThings-GreenCom-CPSCoM-SmartData 2017*, 2018-Janua, pp. 1101–1105. doi: 10.1109/iThings-GreenCom-CPSCoM-SmartData.2017.238.
- SURYAWAN, I. G. T. & UDAYANA, I. P. A. E. D. 2020. A Deep Learning Approach For COVID 19 Detection Via X-Ray Image With Image Correction Method. *International Journal of Engineering and Emerging Technology*, 5(2), pp. 1–5.
- Available at:<https://ocs.unud.ac.id/index.php/ijeet/article/view/64535/37517>.
- doi:<https://doi.org/10.24843/IJEET.2020.v05.i02.p018>.
- USCHER-PINES, L., dkk. 2006. Priority setting for pandemic influenza: An analysis of national preparedness plans. *PLoS Medicine*, 3(10), pp. 1721–1727. doi: 10.1371/journal.pmed.0030436.
- VAHRUN. 2021. *Dirjen Dikti Apresiasi GeNose C19 Hasil Inovasi Karya Anak Bangsa, lldikti1.ristekdikti.go.id*. Available at: <https://lldikti1.ristekdikti.go.id/details/apps/2609>.
- ZHANG, C., dkk. (2018). A study on overfitting in deep reinforcement learning', *arXiv*, pp. 1–25.