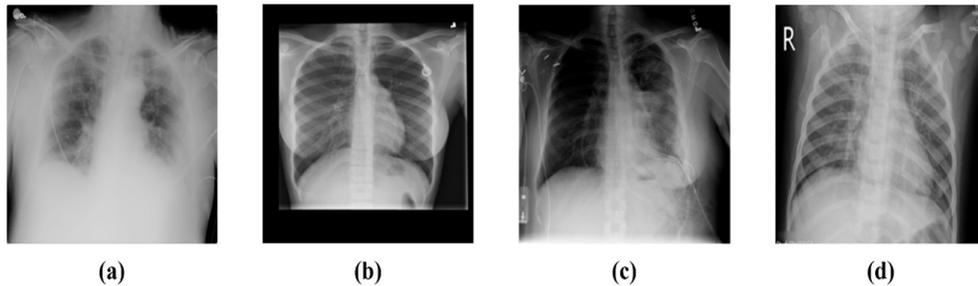


BAB IV HASIL DAN PEMBAHASAN

4.1. Deskripsi Data

Dataset yang digunakan pada penelitian ini yaitu *COVID-19 Radiography Database*. Dataset ini merupakan kumpulan citra CXR dari proyek penelitian *Qatar University* dan *University of Dhaka* yang berkolaborasi bersama Pakistan dan Malaysia. Dataset ini digunakan untuk analisis dan deteksi kasus *COVID-19*, serta kondisi kesehatan paru-paru lainnya. Terdapat 4 kelas yang digunakan pada penelitian ini yaitu 3.616 citra *COVID-19*, 10.192 citra normal, 6.012 citra *lung opacity*, dan 1.345 citra *pneumonia*. Adapun contoh citra CXR masing-masing kelas dapat dilihat pada Gambar 4.1.



Gambar 4.1. Contoh Citra CXR Paru-paru (a) *COVID-19* (b) Normal (c) *Lung Opacity* (d) *Pneumonia*

Terlihat bahwa pada Gambar 4.1 terdapat contoh 4 kelas yang ada pada citra CXR yaitu *COVID-19*, normal, *lung opacity*, dan *pneumonia*. Pada citra CXR dari pasien yang terinfeksi *COVID-19* sering menunjukkan tanda-tanda opasitas paru-paru yang bervariasi. Opasitas ini mungkin terlihat seperti bercak putih atau abu-abu yang menutupi area paru-paru. Kadang-kadang, terlihat peningkatan kepadatan pada bagian-bagian paru tertentu. Opasitas ini mungkin berkembang dalam pola yang tidak teratur dan tersebar di berbagai area paru. Terkadang, kondisi ini dapat diiringi dengan tanda-tanda *pneumonia* atau komplikasi pernapasan lainnya pada paru-paru.

Pada citra CXR normal, paru-paru akan terlihat transparan dengan jelas. Tidak ada opasitas yang terlihat, dan struktur anatomi seperti tulang rusuk dan jantung juga dapat terlihat dengan baik. Citra CXR normal tidak menunjukkan tanda-tanda infeksi, inflamasi, atau kondisi medis lainnya yang mempengaruhi paru-paru.

Pneumonia adalah infeksi pada paru-paru yang dapat menyebabkan peradangan dan pengumpulan cairan di dalam *alveoli* (kantong-kantong udara di dalam paru-paru). Pada citra CXR *pneumonia*, dapat terlihat area-area yang tampak lebih gelap atau kabur, mengindikasikan adanya cairan atau *infiltrat* yang mengganggu aliran udara di dalam paru-paru. Area ini mungkin berada di berbagai lokasi di paru-paru tergantung pada jenis *pneumonia* dan organisme yang menyebabkannya.

Lung opacity adalah area di citra CXR yang tampak lebih gelap atau lebih terang dari sekitarnya, menunjukkan perbedaan kepekatan jaringan. Opasitas dapat disebabkan oleh berbagai kondisi seperti *pneumonia*, tumor, efusi (pengumpulan cairan di rongga *pleura*), atau adanya benda asing di dalam saluran pernapasan. Keberadaan dan jenis opasitas dapat memberikan petunjuk tentang jenis masalah medis yang mungkin ada dalam paru-paru.

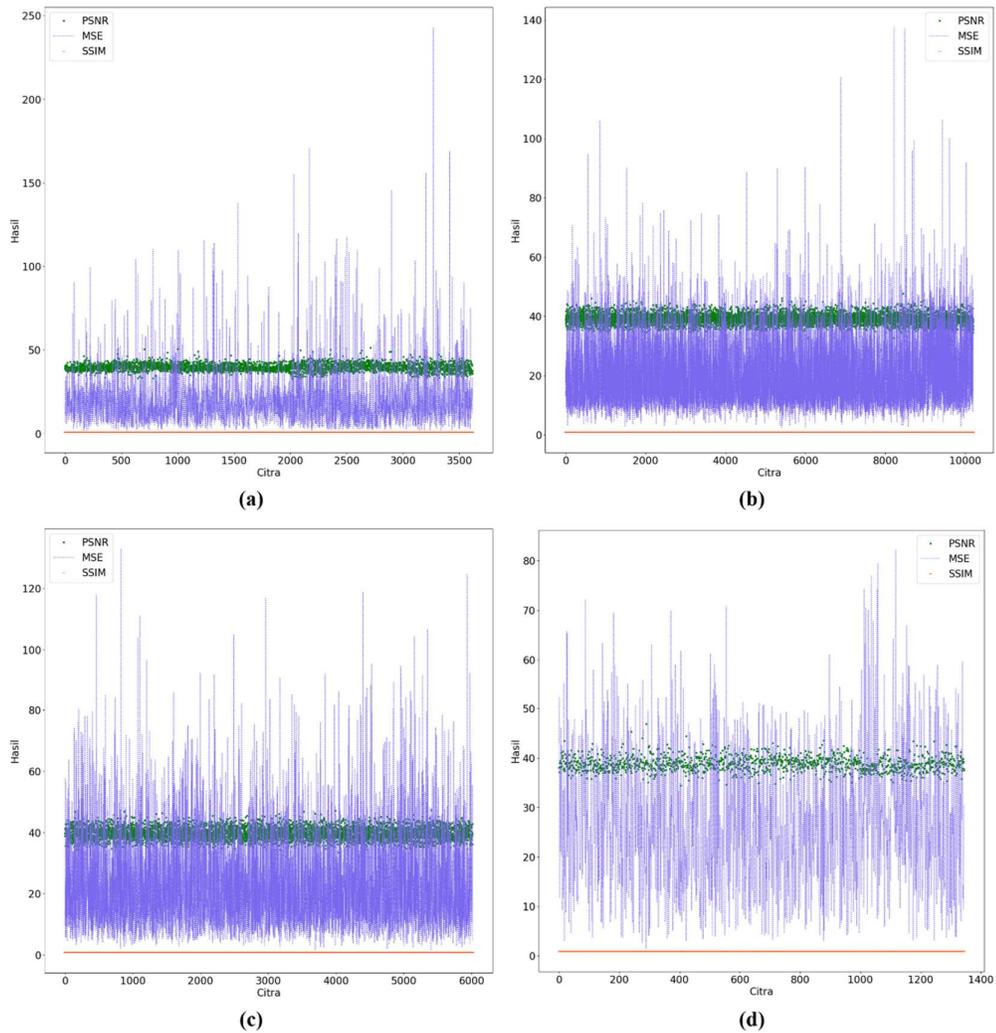
4.2. Peningkatan Kualitas Citra CXR

Citra CXR pada penelitian ini memiliki intensitas citra yang tidak merata pada skala keabuan sehingga sulit untuk mendeteksi *detail* struktur pada area paru-paru. Untuk itu diperlukan teknik yang dapat meningkatkan kualitas citra pada citra CXR sehingga dapat memudahkan dokter dan ahli radiologi dalam mendeteksi penyakit paru-paru. Penelitian ini menggunakan metode Morfologi *Opening* yang bertujuan untuk memperbaiki kontur dan menghilangkan objek-objek tipis yang ada pada citra. Hasil citra dari morfologi *opening*, selanjutnya dilakukan pengurangan *noise* menggunakan metode *Median Filter*. Hasil perbandingan peningkatan citra dengan menggunakan metode yang digunakan pada masing-masing kelas citra dapat dilihat pada Tabel 4.1.

Tabel 4.1. Perbandingan hasil peningkatan citra CXR

| Nama <i>file</i> | Original | Morfologi <i>Opening</i> | <i>Median Filter</i> |
|--------------------|--|---|--|
| COVID-1.png |  |  |  |
| Normal-1.png |  |  |  |
| Lung_Opacity-1.png |  |  |  |
| Pneumonia-1.png |  |  |  |

Terlihat pada Tabel 4.1 menampilkan perbandingan visual dari hasil peningkatan citra untuk setiap kelas citra. Meskipun hasil visual menunjukkan perbaikan, namun sulit untuk secara subjektif menentukan kualitas citra yang terbaik. Untuk mempermudah penentuan kualitas citra yang terbaik, penelitian ini menggunakan pengukuran kuantitatif dengan menghitung nilai PSNR, MSE, dan SSIM pada citra asli dan citra hasil peningkatan kualitas. Nilai PSNR mengukur seberapa baik citra hasil peningkatan dibandingkan citra asli, semakin tinggi nilai PSNR, semakin baik citra hasil peningkatan. MSE mengukur rata-rata kesalahan per piksel antara citra asli dan hasil peningkatan, semakin rendah nilai MSE, semakin baik kualitas citra hasil peningkatan. Sedangkan SSIM mengukur tingkat kesamaan struktural antara citra asli dan hasil peningkatan, nilai SSIM mendekati 1 menunjukkan kualitas citra yang lebih baik. Grafik perbandingan nilai PSNR, MSE dan SSIM dapat dilihat seperti pada Gambar 4.2.



Gambar 4.2. Perbandingan Grafik Nilai Evaluasi Peningkatan Kualitas Citra CXR
(a) *COVID-19* (b) *Normal* (c) *Lung Opacity* (d) *Pneumonia*

Terlihat bahwa pada Gambar 4.2 grafik perbandingan nilai PSNR, MSE, dan SSIM antara citra asli dan hasil peningkatan kualitas citra menunjukkan perbedaan pada keempat kelas citra, yaitu citra *COVID-19*, *Normal*, *Lung Opacity*, dan *Pneumonia*. Kelas citra *Pneumonia* menunjukkan nilai evaluasi yang lebih bervariasi dibandingkan dengan kelas lainnya. Hasil evaluasi kinerja pada metode *Morfologi Opening* dan *Median Filter* menghasilkan parameter kualitas citra pada setiap kelas dengan rata-rata nilai PSNR, MSE, dan SSIM ditunjukkan seperti pada Tabel 4.2.

Tabel 4.2. Perbandingan Hasil Evaluasi Kinerja pada Metode *Median Filter*

| | PSNR | MSE | SSIM |
|---------------------------|-------------|------------|-------------|
| Citra <i>COVID-19</i> | 39,714 | 19,891 | 0,952 |
| Citra Normal | 39,022 | 19,965 | 0,954 |
| Citra <i>Lung Opacity</i> | 39,669 | 23,121 | 0,951 |
| Citra <i>Pneumonia</i> | 38,825 | 26,901 | 0,951 |

Terlihat bahwa pada Tabel 4.2 hasil evaluasi kinerja menggunakan metode Morfologi *Opening* dan *Median Filter* menunjukkan nilai rata-rata PSNR, MSE, dan SSIM yang telah mendekati atau mencapai angka yang dianggap baik. Nilai rata-rata PSNR berada pada rentang 38-39, nilai MSE berada pada rentang 19-27, dan SSIM berada pada rentang 0,95-0,96. Hal ini menunjukkan bahwa kualitas citra setelah dilakukan peningkatan sudah baik. Untuk lebih memvalidasi nilai evaluasi kinerja yang diusulkan, hasil peningkatan kualitas citra akan dibandingkan dengan hasil dari metode penelitian lainnya yang dapat dilihat seperti pada Tabel 4.3.

Tabel 4.3. Perbandingan Hasil Evaluasi Penelitian ini dengan Penelitian Lain

| Metode | PSNR | MSE | SSIM |
|--|---------------|---------------|--------------|
| <i>Region Growing</i> dan <i>Wavelet Transform</i> [124] | 37.122 | 25.5911 | - |
| <i>Gamma Correction, Gaussian Filter</i> [103] | 24.61 | 229.92 | - |
| <i>Wiener Filter</i> dan <i>Poisson Noise</i> [104] | 33 | 29 | 0.7876 |
| <i>Type-2 Neutrosophic Set</i> [105] | 28.58 | 23.6 | 0.9 |
| Morfologi <i>Opening</i> dan <i>Median Filter</i> [106]³ | 39.307 | 22.469 | 0.952 |

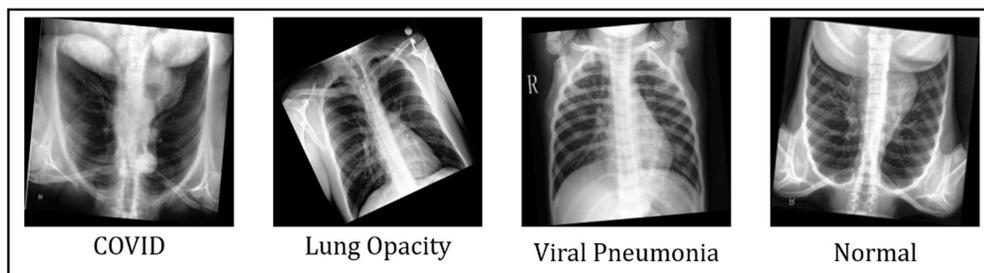
Pada Tabel 4.3 penelitian yang dilakukan oleh Allam Zanaty & Mostafa Ibrahim [124] dan Umamaheswari & Geetha [103] hanya menghitung nilai PSNR dan MSE, sedangkan SSIM tidak dihitung. Penelitian oleh Umamaheswari & Geetha [103] juga didapatkan nilai PSNR terendah dan MSE tertinggi dibandingkan

³ Kesuma, L. I., Ermatita, Erwin, Sari, P., & Purabaya, R. H. (2022). Improved Chest X - Ray Image Quality Using Median and Gaussian Filter Methods. *2022 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*. (Lampiran 1)

penelitian lainnya. Sementara itu, penelitian lain oleh Roy & Maity [104] dan Abdel- Basset et al [105] menghitung semua nilai yang digunakan. Penelitian oleh Roy & Maity [104] memperoleh skor SSIM terendah dibandingkan penelitian lainnya. Pada metode yang diusulkan menggunakan Morfologi *Opening* dan *Median Filter* memperoleh hasil PSNR dan SSIM tertinggi serta MSE terendah dibandingkan penelitian lainnya. Secara keseluruhan, penelitian ini berhasil mengatasi masalah intensitas citra yang tidak merata pada skala keabuan pada citra CXR dan meningkatkan kualitas citra secara signifikan menggunakan teknik Morfologi *Opening* dan *Median Filter*.

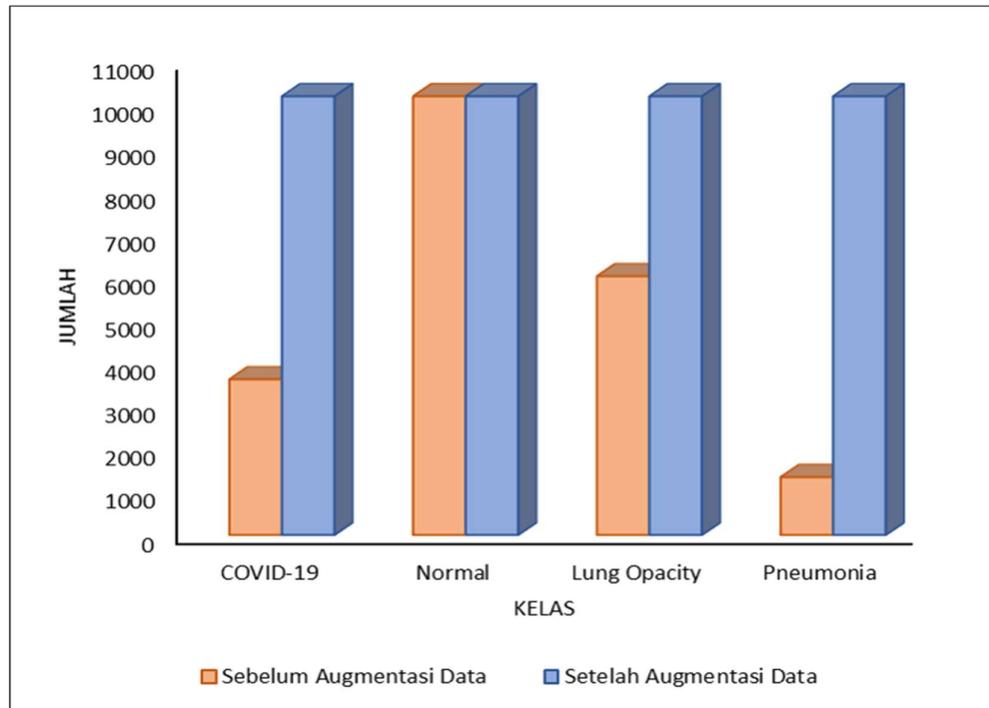
4.3. Augmentasi Data pada Citra CXR

Pada dataset Citra CXR yang digunakan dalam penelitian ini, terdapat ketidakseimbangan jumlah data pada setiap kelas. Ketidakseimbangan ini dapat menyebabkan model cenderung cenderung memprediksi kelas mayoritas dan mengabaikan kelas minoritas, sehingga performa model menjadi tidak optimal. Untuk mengatasi masalah ini, digunakan teknik augmentasi data pada citra CXR. Augmentasi data digunakan untuk memperbanyak data dengan cara mengubah citra asli menjadi variasi baru, namun tetap mempertahankan informasi yang sama. Pada penelitian ini, augmentasi data yang digunakan yaitu rotasi dan *flipping*. Teknik rotasi dilakukan dengan memutar citra CXR sebesar sudut tertentu. Sementara teknik *flipping* dilakukan dengan membalik citra secara horizontal dan vertikal. Ilustrasi beberapa contoh gambar CXR yang diperoleh dari augmentasi data dapat dilihat seperti pada Gambar 4.3 berikut.



Gambar 4.3. Hasil Augmentasi Data Menggunakan Transformasi Rotasi

Terlihat bahwa pada Gambar 4.3 beberapa contoh citra CXR yang telah mengalami proses augmentasi data ditampilkan. Terlihat bahwa transformasi rotasi dengan sudut 1° hingga 359° diterapkan pada citra-citra yang termasuk dalam kelas minoritas. Perbandingan jumlah data antara sebelum augmentasi data dan sesudah augmentasi data dapat dilihat seperti pada Gambar 4.4.

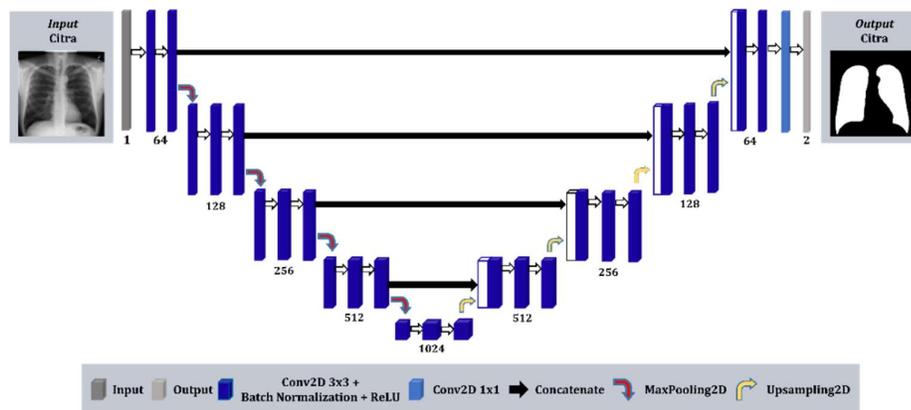


Gambar 4.4. Perbandingan Jumlah Data Antara Sebelum Augmentasi Data dan Sesudah Augmentasi Data

Pada Gambar 4.4 proses augmentasi data pada kelas COVID-19 yang semula hanya berisi 3.616 citra, melalui metode augmentasi data, jumlahnya berhasil diperbanyak menjadi 10.192 citra. Dengan cara yang sama, augmentasi data dilakukan pada kelas *lung opacity* dan *pneumonia*. Total keseluruhan citra yang dihasilkan dari proses augmentasi data adalah 40.768 citra dengan setiap kelas pada dataset memiliki jumlah citra yang seimbang yaitu 10.192 citra. Dengan meningkatnya jumlah data pada setiap kelas, diharapkan bahwa model yang dihasilkan dapat memiliki performa yang lebih baik dalam mengenali citra CXR dari berbagai kelas, termasuk kelas minoritas yang sebelumnya mungkin kurang terwakili dalam data latih.

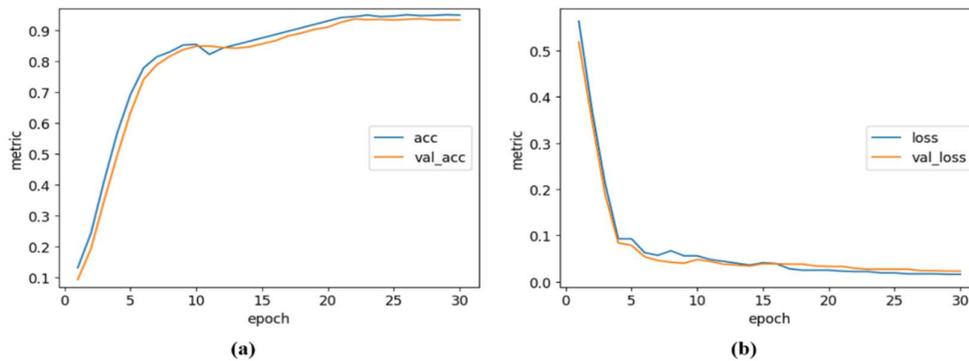
4.4. Segmentasi Citra CXR

Segmentasi citra paru-paru dapat membantu dalam mendeteksi kelainan pada paru-paru. Citra CXR akan dipisahkan menjadi dua bagian selama segmentasi citra yaitu paru-paru sebagai *foreground* dan daerah selain paru-paru sebagai *background*. Data yang dihasilkan dari proses augmentasi dipisahkan menjadi dua jenis: data latih dan data uji. Data latih dipisahkan lagi selama proses *training* menjadi data latih dan data validasi. Proses training segmentasi adalah untuk membangun model dari arsitektur yang diusulkan. Hasil dari proses *training* berupa bobot. Metode yang digunakan dalam penelitian ini yaitu modifikasi arsitektur *U-Net Batch Normalization* yang dapat dilihat seperti pada Gambar 4.5.



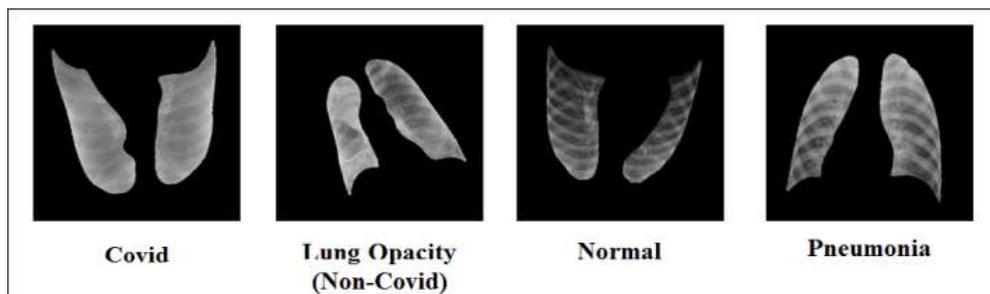
Gambar 4.5. Arsitektur *U-Net* pada Citra CXR

Pada Gambar 4.5 terlihat bahwa arsitektur *U-Net* terdiri dari jalur *encoder* (sisi kiri) dan jalur *decoder* (sisi kanan). Jalur *encoder* memiliki empat blok konvolusi dengan fungsi aktivasi *ReLU*, dilanjutkan dengan *batch normalization* dan *max pooling* untuk mengurangi dimensi. Jumlah *feature maps* di jalur *encoder* akan berlipat ganda. Jalur *decoder* menggunakan *transposed convolution* untuk mengembalikan dimensi *feature maps* dan dilakukan *concatenate* dengan *feature maps* dari jalur *encoder*. Kemudian, dilakukan empat blok konvolusi dengan jumlah *feature maps* berkurang dua kali lipat hingga mencapai jumlah awal. Tahap terakhir adalah konvolusi 1×1 dengan fungsi aktivasi *softmax* untuk menghasilkan gambar hasil segmentasi dengan probabilitas untuk setiap kelas objek. Grafik akurasi dan *loss* tahap segmentasi selama proses *training* dapat dilihat seperti pada Gambar 4.6.



Gambar 4.6. Grafik *Training* Segmentasi Citra CXR (a) Akurasi (b) *Loss*

Pada Gambar 4.6 terlihat bahwa grafik akurasi data latih pada segmentasi citra mengalami peningkatan. Untuk *epoch* pertama, nilai akurasi 13%, kemudian meningkat hingga 95%. Grafik akurasi untuk data validasi juga meningkat. Untuk *epoch* pertama, nilai akurasinya 9%, kemudian meningkat menjadi 93%. Grafik *loss* untuk data latih mengalami penurunan. Untuk *epoch* pertama, nilai *loss* 57%, kemudian menurun hingga 1%. Grafik *loss* untuk data validasi juga mengalami penurunan. Untuk *epoch* pertama nilai *loss* 52%, kemudian menurun hingga 2%. Berdasarkan Gambar 4.6, kinerja model pada *U-Net Batch Normalization* sangat baik dalam segmentasi paru-paru pada citra CXR karena nilai akurasi diatas 93% dan nilai *loss* mendekati 1%. Tahap *testing* dilakukan untuk menguji bobot yang dihasilkan selama proses *training*. Bobot terbaik hasil proses *training* digunakan untuk menguji segmentasi citra CXR paru-paru dengan menggunakan data uji. Hasil segmentasi CXR paru-paru dipisahkan menjadi dua bagian yaitu paru-paru (*foreground*) dan daerah selain paru-paru (*background*). Ilustrasi beberapa contoh citra CXR yang diperoleh dari proses segmentasi dapat dilihat pada Gambar 4.7.



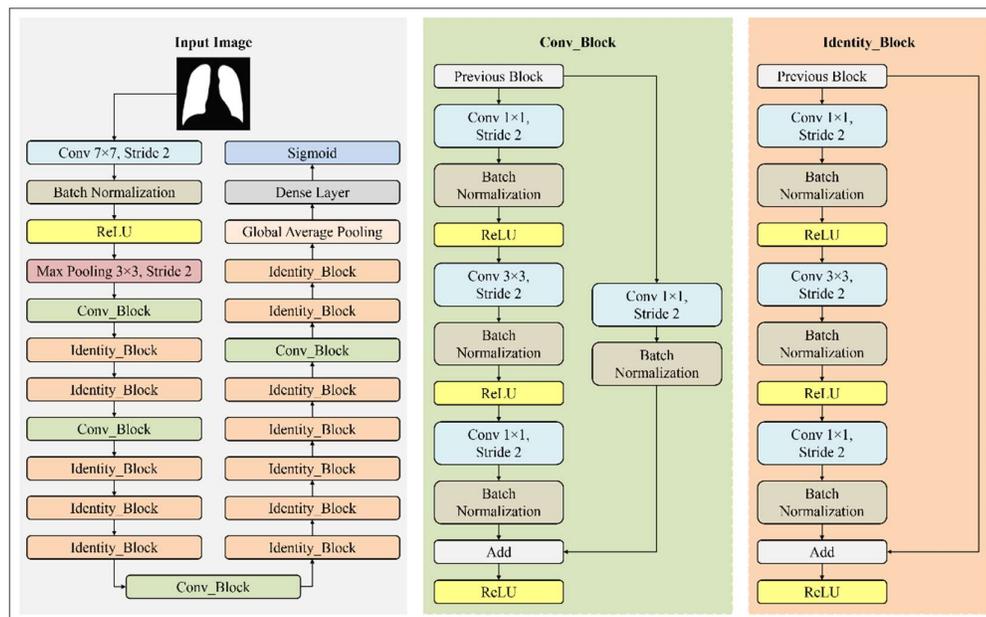
Gambar 4.7. Hasil Segmentasi Citra CXR Paru-paru Menggunakan *U-Net Batch Normalization*

4.5. Klasifikasi Citra CXR

Pada tahap klasifikasi citra, data yang digunakan adalah data hasil segmentasi citra CXR. Data ini dibagi menjadi data latih dan data uji. Proses *training* untuk data latih dibagi lagi menjadi data latih dan data validasi. Pada tahap ini digunakan 40.768 data latih, dengan 90% (36.691 data latih) dan 10% (4.077 data validasi).

4.5.1. Training Klasifikasi Citra CXR Menggunakan *ResNet*

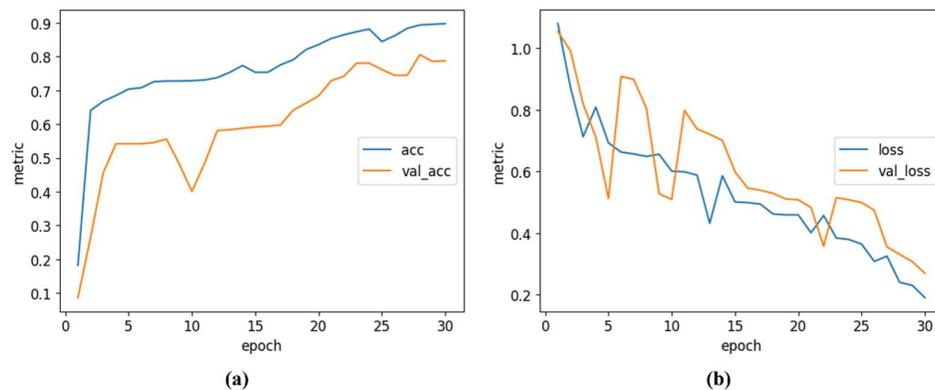
ResNet merupakan arsitektur CNN yang dikenal dalam mengatasi masalah *vanishing gradient*. Dengan menggunakan *residual block*, *ResNet* dapat menyederhanakan proses pelatihan jaringan yang dalam dan memungkinkan untuk melatih model yang lebih dalam. Pada klasifikasi citra CXR, *ResNet* dapat mempelajari fitur-fitur kompleks yang ada dalam citra dan menghasilkan representasi fitur yang akurat. Arsitektur *ResNet* pada klasifikasi citra CXR dapat dilihat seperti pada Gambar 4.8.



Gambar 4.8. Arsitektur *ResNet* pada Klasifikasi Citra CXR

Pada Gambar 4.8 terlihat bahwa pada arsitektur *ResNet*, citra CXR diproses melalui *convolutional layer* dengan fungsi aktivasi *ReLU* dan *batch normalization*. Selanjutnya, dilakukan operasi *max pooling* untuk mengurangi dimensi *feature*

maps. *Feature maps* tersebut kemudian diproses melalui *conv_block* dan jalur *residual connection*. Hasil yang diperoleh selanjutnya dijumlahkan dan dilakukan fungsi aktivasi menggunakan *ReLU*. Langkah ini diulangi beberapa kali, termasuk pengulangan pada *identity_block*. Setelah beberapa kali pengulangan, ukuran *feature maps* dikurangi menggunakan *global average pooling*. Selanjutnya, hasilnya diproses melalui *dense layer* dan fungsi aktivasi *sigmoid* untuk menghasilkan probabilitas kelas. Grafik akurasi dan *loss* tahap klasifikasi citra pada arsitektur *ResNet* selama proses *training* dapat dilihat seperti pada Gambar 4.9.



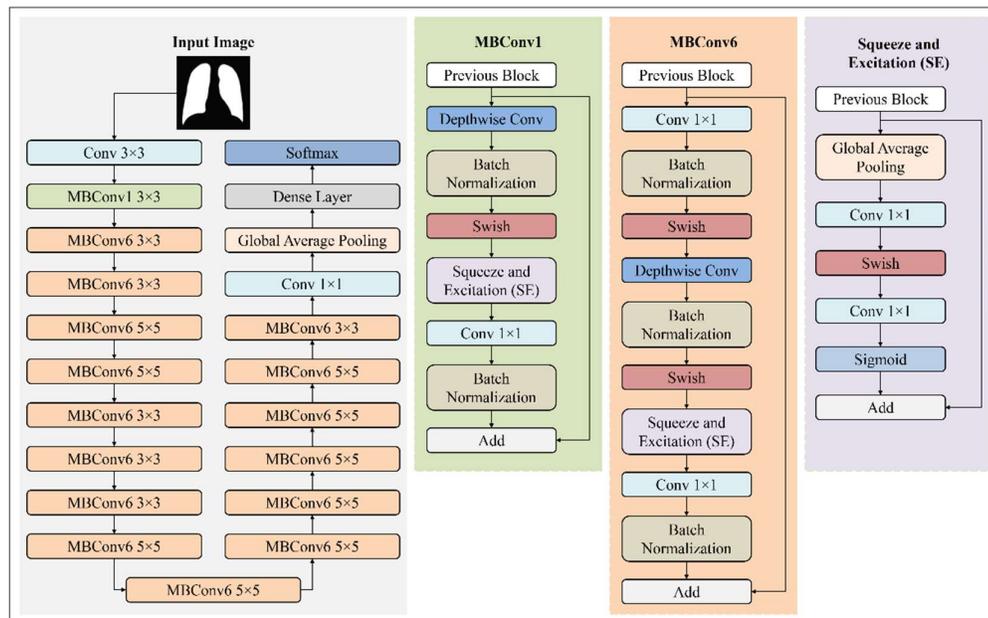
Gambar 4.9. Grafik *Training* Klasifikasi Citra CXR Menggunakan Arsitektur *ResNet* (a) Akurasi (b) *Loss*

Pada Gambar 4.9 terlihat bahwa grafik akurasi untuk data latih dalam arsitektur *ResNet* meningkat di setiap *epoch*. Untuk *epoch* pertama, nilai akurasi pada data latih adalah 18%, kemudian meningkat menjadi 89%. Selain itu, grafik akurasi untuk data validasi pada arsitektur *ResNet* mengalami peningkatan dan penurunan. Untuk *epoch* pertama sebesar 8% dan meningkat menjadi 55% di *epoch* kedelapan. Pada *epoch* kesepuluh, nilainya menurun menjadi 40% dan kemudian meningkat menjadi 78% pada *epoch* berikutnya. Sementara untuk grafik *loss* pada data latih mengalami penurunan pada setiap *epoch*. Untuk *epoch* pertama, nilai *loss* lebih dari 100%, kemudian terus menurun hingga mencapai 20%. Sedangkan untuk grafik *loss* pada data validasi mengalami penurunan dan peningkatan pada setiap *epoch*. Untuk *epoch* pertama nilai *loss* lebih dari 100%, kemudian pada *epoch* kelima menurun menuju 55%. Pada *epoch* kesebelas, nilainya kembali meningkat ke 79% dan kemudian menurun menuju 23% pada *epoch* berikutnya. Terlihat

bahwa grafik yang diperoleh arsitektur *ResNet* masih mengalami *overfitting* karena model hanya mampu mengenali pola pada data latih.

4.5.2. Training Klasifikasi Citra CXR Menggunakan *EfficientNet*

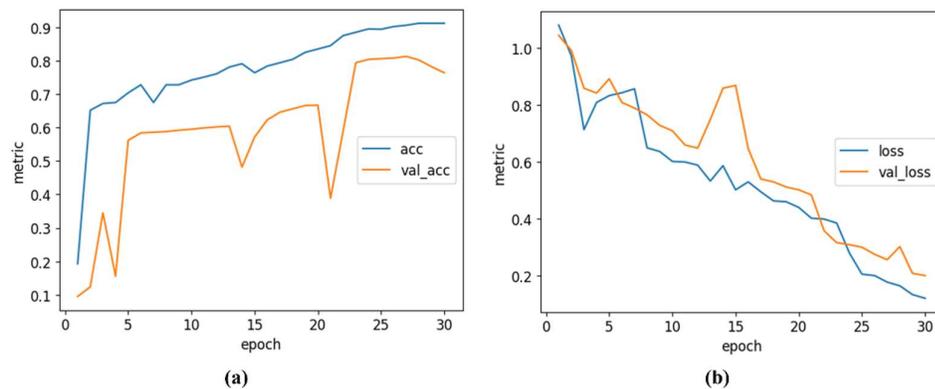
EfficientNet adalah arsitektur CNN yang dikenal karena berhasil mengatasi masalah penskalaan dimensi dengan seragam dan seimbang pada kedalaman (*depth*), lebar (*width*), serta resolusi di setiap lapisannya. Dengan melakukan penyesuaian dimensi secara seragam, arsitektur ini mampu meningkatkan kemampuannya dalam menangkap fitur-fitur yang kompleks dan abstrak. Arsitektur *EfficientNet* pada klasifikasi citra CXR dapat dilihat pada Gambar 4.10.



Gambar 4.10. Arsitektur *EfficientNet* pada Klasifikasi Citra CXR

Pada Gambar 4.10 terlihat bahwa pada arsitektur *EfficientNet*, citra CXR diproses melalui *convolutional layer* yang diikuti dengan operasi *batch normalization* dan fungsi aktivasi *ReLU*. Selanjutnya hasil tersebut diproses ke dalam blok *MBConv*. Terdapat dua jenis blok *MBConv* yang digunakan pada penelitian ini yaitu *MBConv1* dan *MBConv6*. *MBConv1* digunakan satu kali setelah proses konvolusi dengan kernel berukuran 3×3 . Sedangkan *MBConv6* digunakan setelahnya dengan ukuran kernel yang berbeda yaitu (3×3 dan 5×5). *MBConv*

terdiri dari operasi *depthwise convolution*, *batch normalization*, fungsi aktivasi *swish*, *squeeze and excitation*, *convolution layer*, dan *add*. Selanjutnya hasil yang diperoleh dari proses *MBCConv6* dilakukan operasi *convolutional layer* kembali dengan kernel 1×1 yang diikuti operasi *batch normalization* dan fungsi aktivasi *ReLU*. Setelah itu dilakukan pengurangan ukuran *feature maps* menggunakan operasi *global average pooling*. *Feature maps* tersebut kemudian diproses melalui *dense layer* dengan aktivasi *softmax* untuk menghasilkan probabilitas kelas. Grafik akurasi dan *loss* tahap klasifikasi citra menggunakan arsitektur *EfficientNet* selama proses *training* dapat dilihat seperti pada Gambar 4.11.



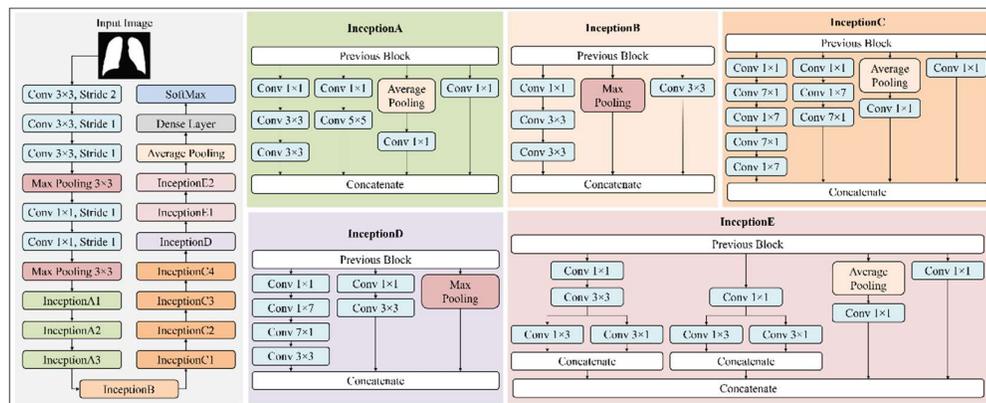
Gambar 4.11. Grafik *Training* Klasifikasi Citra CXR Menggunakan Arsitektur *EfficientNet* (a) Akurasi (b) *Loss*

Pada Gambar 4.11 terlihat bahwa grafik akurasi untuk data latih pada arsitektur *EfficientNet* mengalami peningkatan pada setiap *epoch* namun mengalami penurunan pada beberapa *epoch*. Pada *epoch* pertama nilai akurasi pada data training adalah 19% yang kemudian meningkat menjadi 91%. Sementara itu, grafik akurasi untuk validasi data pada arsitektur *EfficientNet* mengalami peningkatan dan penurunan di setiap *epoch*. Pada *epoch* pertama sebesar 9%, kemudian meningkat menjadi 34%, dan menurun lagi pada *epoch* ke-4, 14, dan 20. Selanjutnya, akurasi meningkat dan menurun lagi, mencapai 76%. Sementara untuk grafik *loss* pada data latih mengalami penurunan pada setiap *epoch*. Untuk *epoch* pertama, nilai *loss* lebih dari 100%, kemudian terus menurun hingga mencapai 12%. Sedangkan untuk grafik *loss* pada data validasi mengalami penurunan dan peningkatan pada setiap *epoch*. Untuk *epoch* pertama nilai *loss* lebih dari 100%,

kemudian pada *epoch* ke-12 menurun menuju 64%. Pada *epoch* ke-15, nilainya kembali meningkat ke 87% dan kemudian menurun menuju 20% pada *epoch* berikutnya. Terlihat bahwa grafik yang diperoleh arsitektur *EfficientNet* juga masih mengalami *overfitting* karena model hanya mampu mengenali pola pada data latih dan tidak dapat mengenali data yang baru.

4.5.3. Training Klasifikasi Citra CXR Menggunakan *Inception-v3*

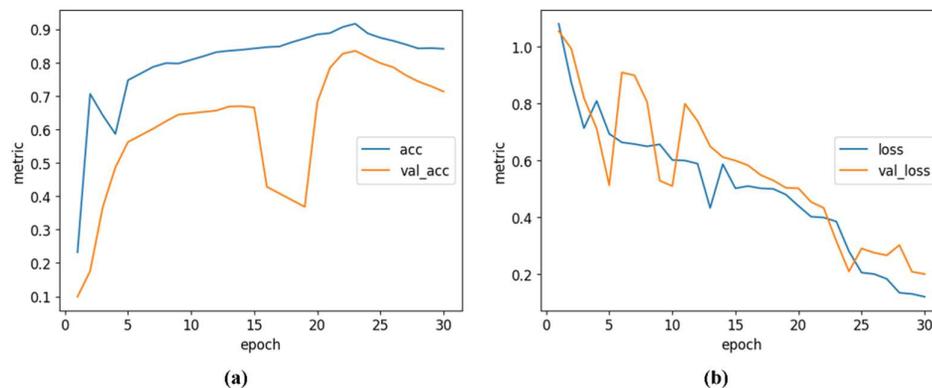
Inception-v3 merupakan arsitektur CNN yang dapat mengatasi masalah kompleksitas jaringan. Dengan menggunakan *inception block*, arsitektur *Inception-v3* mempelajari representasi jaringan yang lebih baik dari data *input*. Arsitektur *Inception-v3* pada klasifikasi citra CXR dapat dilihat seperti pada Gambar 4.12.



Gambar 4.12. Arsitektur *Inception-v3* pada Klasifikasi Citra CXR

Pada Gambar 4.12 terlihat bahwa arsitektur *Inception-v3* terdiri dari beberapa blok *Inception*, yakni A, B, C, D, dan E, setiap blok *Inception* memiliki jalur-jalur yang berbeda untuk melakukan operasi konvolusi dengan ukuran kernel yang berbeda. Proses dimulai dengan operasi konvolusi 3×3 , diikuti oleh *batch normalization* dan fungsi aktivasi *ReLU*. Kemudian, dilakukan operasi *max pooling* untuk mengurangi dimensi *feature maps*. Setelah itu, dilakukan kembali operasi konvolusi dengan kernel 1×1 dan kemudian *max pooling* lagi. Hasil dari *max pooling* diproses ke dalam blok *Inception A* sebanyak tiga kali. Pada setiap blok tersebut, terdapat empat jalur yang masing-masing melakukan operasi konvolusi dengan ukuran kernel yang berbeda dan pengurangan dimensi menggunakan

average pooling. Hasil dari setiap jalur digabungkan menggunakan *concatenate*. Hasil dari blok *Inception A* kemudian diproses ke dalam blok *Inception B*. Pada blok ini, terdapat tiga jalur yang melibatkan operasi konvolusi dan penggunaan *max pooling* untuk pengurangan dimensi *feature maps*. Setelah itu, hasil dari setiap jalur pada *Inception B* digabungkan menggunakan *concatenate* dan diproses ke dalam blok *Inception C* sebanyak empat kali. Blok ini memiliki empat jalur dengan kombinasi operasi konvolusi dan pengurangan dimensi menggunakan *average pooling*. Hasil dari setiap jalur pada *inception C* juga digabungkan menggunakan *concatenate* dan diproses ke dalam blok *Inception D* serta *E* secara berulang sesuai jumlah blok masing-masingnya. Hasil pada blok *Inception E* dilakukan pengurangan ukuran *feature maps* menggunakan *global average pooling*. Kemudian, hasil tersebut diproses ke dalam *dense layer* dan diaktivasi dengan *softmax* untuk mendapatkan output klasifikasi. Grafik akurasi dan *loss* tahap klasifikasi citra menggunakan arsitektur *Inception-v3* selama proses *training* dapat dilihat seperti pada Gambar 4.13.



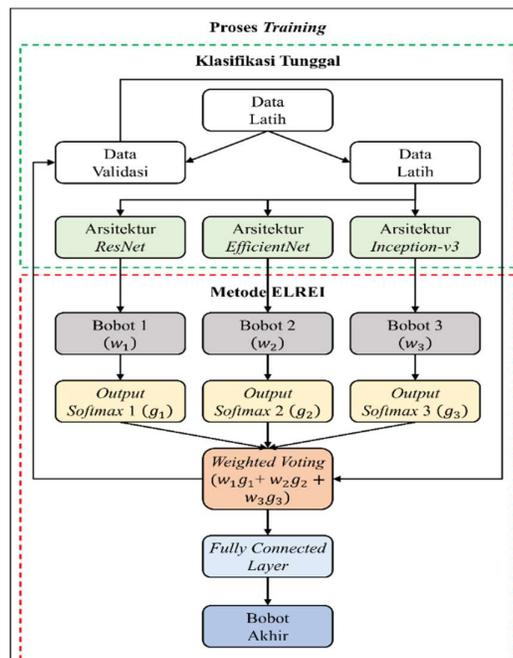
Gambar 4.13. Grafik *Training* Klasifikasi Citra CXR Menggunakan Arsitektur *Inception-v3* (a) Akurasi (b) *Loss*

Pada Gambar 4.13 terlihat bahwa grafik akurasi untuk data pelatihan dan validasi menggunakan arsitektur *Inception-v3*. Sama halnya dengan arsitektur *EfficientNet*, nilai akurasi mengalami kenaikan dan penurunan pada setiap *epoch*. Pada *epoch* pertama nilai akurasi pada data latih sebesar 23% dan terus meningkat menjadi 91% pada *epoch* ke-23. Selain itu, nilai akurasi data validasi meningkat dari 10% menjadi 83%. Namun, untuk *epoch* selanjutnya menurun menjadi 71%.

Sementara untuk grafik *loss* pada data latih mengalami penurunan pada setiap *epoch*. Untuk *epoch* pertama, nilai *loss* lebih dari 100%, kemudian terus menurun hingga mencapai 11%. Sedangkan untuk grafik *loss* pada data validasi mengalami penurunan dan peningkatan pada setiap *epoch*. Untuk *epoch* pertama nilai *loss* lebih dari 100%, kemudian pada *epoch* kelima menurun menuju 51%. Pada *epoch* keenam, nilainya kembali meningkat ke 91% dan kemudian menurun menuju 50% pada *epoch* ke-10. Selanjutnya pada *epoch* ke-11 kembali meingkat ke 80% dan menurun menuju 19% pada *epoch* berikutnya. Terlihat bahwa grafik yang diperoleh arsitektur *Inception-v3* sama seperti arsitektur *ResNet* dan *EfficientNet* yaitu masih mengalami *overfitting* karena model hanya mampu mengenali pola pada data latih.

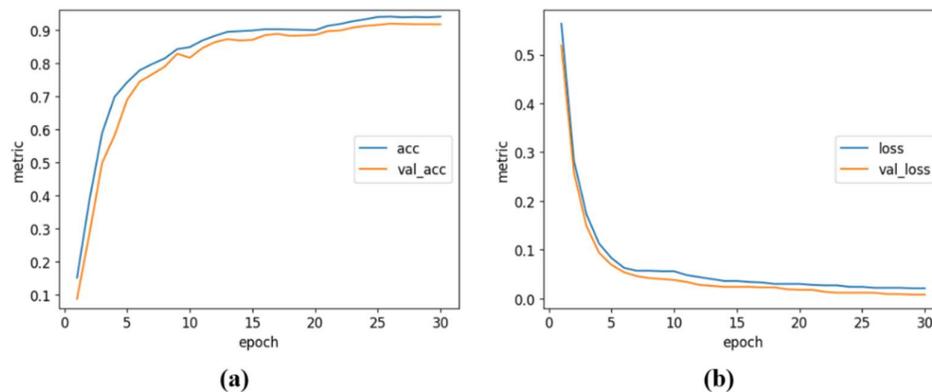
4.5.4. Training Klasifikasi Citra CXR Menggunakan ELREI

ELREI (*Ensemble Learning* dari *ResNet*, *EfficientNet*, dan *Inception-v3*) mengatasi keterbatasan dan memanfaatkan keunggulan arsitektur masing-masing arsitektur (*ResNet*, *EfficientNet*, dan *Inception-v3*) dengan menggabungkan hasilnya. ELREI bekerja pada tahap *training* di setiap *epoch*. Tahapan klasifikasi citra pada proses *training* menggunakan ELREI dapat dilihat pada Gambar 4.14.



Gambar 4.14. Proses ELREI pada Klasifikasi Citra CXR

Pada Gambar 4.14 terlihat bahwa proses awal *training* data dilakukan klasifikasi tunggal dengan menggunakan arsitektur *ResNet*, *EfficientNet*, dan *Inception-v3*. Hasil dari proses *training* ini adalah bobot terbaik setiap *epoch*-nya dari masing-masing arsitektur. Selanjutnya, dilakukan klasifikasi dengan menggunakan metode *Ensemble Learning* dari *ResNet*, *EfficientNet*, dan *Inception-v* (ELREI). Metode ELREI bekerja pada setiap *epoch* dalam proses *training*. Bobot yang dihasilkan dari setiap arsitektur kemudian dihitung nilai *softmax* nya, dan kemudian dilakukan teknik *weighted voting* untuk menggabungkan hasil dari ketiga arsitektur tersebut. Setelah itu, *Fully Connected Layer* (FCN) digunakan pada tahap berikutnya untuk penentuan bobot akhir dan menangani masalah *overfitting* selama proses *training*. FCN mempelajari pola-pola dari data secara menyeluruh tanpa kehilangan informasi spasialnya, sehingga dapat digunakan untuk melakukan klasifikasi penyakit paru-paru berdasarkan citra CXR. Grafik akurasi dan *loss* tahap klasifikasi citra menggunakan metode ELREI selama proses *training* dapat dilihat seperti pada Gambar 4.15.



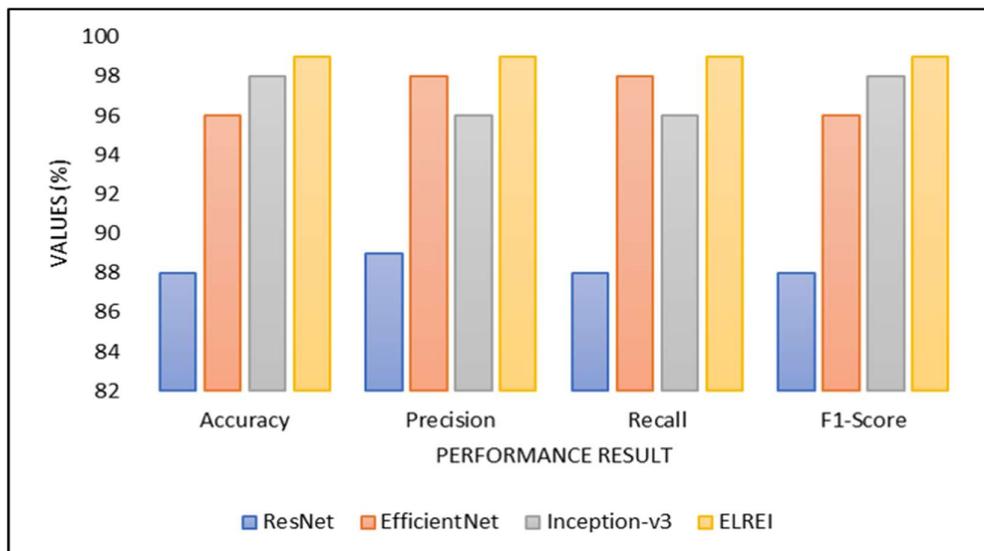
Gambar 4.15. Grafik *Training* Klasifikasi Citra CXR Menggunakan Metode ELREI (a) Akurasi (b) *Loss*

Pada Gambar 4.15 terlihat bahwa grafik grafik akurasi data latih pada metode ELREI mengalami peningkatan pada setiap *epoch*. Untuk epoch pertama nilai akurasinya 15%, kemudian meningkat terus menerus hingga 94%. Grafik akurasi untuk data validasi pada metode ELREI juga meningkat pada setiap *epoch*. Untuk *epoch* pertama nilai akurasinya adalah 9%, kemudian meningkat terus

menerus menjadi 92%. Grafik *loss* untuk data latih mengalami penurunan pada setiap *epoch*. Untuk *epoch* pertama, nilai *loss* 56%, kemudian terus menurun hingga mencapai 1%. Grafik *loss* untuk data validasi pada metode ELREI juga mengalami penurunan pada setiap *epoch*. Untuk *epoch* pertama nilai *loss* adalah 51%, kemudian terus menurun hingga 0%. Grafik yang diperoleh menunjukkan bahwa metode ELREI tidak mengalami *overfitting*. ELREI dapat mengenali dan mempelajari pola dalam data yang telah terlatih maupun data yang tidak terlatih. Berdasarkan Gambar 4.15, kinerja model pada metode ELREI sangat baik dalam mengkategorikan citra CXR paru-paru karena nilai akurasinya diatas 92% dan nilai *loss* mendekati 0%.

4.5.5. *Testing* pada Klasifikasi Citra CXR

Pada tahap *testing*, data uji digunakan untuk melihat sejauh mana keberhasilan metode klasifikasi citra CXR paru-paru. Ukuran kinerja evaluasi yang digunakan pada klasifikasi citra CXR adalah akurasi, presisi, *recall*, dan *F1-Score*. Perbandingan nilai evaluasi kinerja pada metode klasifikasi tunggal dan metode ELREI dapat dilihat seperti pada Gambar 4.16.



Gambar 4.16. Perbandingan Evaluasi Kinerja pada Proses Klasifikasi Citra CXR Menggunakan *ResNet*, *EfficientNet*, *Inception-v3*, dan ELREI

Pada Gambar 4.16 terlihat bahwa hasil kinerja dengan menggunakan metode ELREI pada klasifikasi citra CXR mengalami peningkatan kinerja dibandingkan dengan ResNet, EfficientNet, dan Inception-v3. Peningkatan nilai akurasi sebesar 11% (*ResNet*), 3% (*EfficientNet*), dan 1% (*Inception-v3*). Peningkatan nilai presisi adalah 10,5% (*ResNet*), 1% (*EfficientNet*), dan 3% (*Inception-v3*). Sedangkan peningkatan nilai *recall* adalah 10,75% (*ResNet*), 1% (*EfficientNet*), dan 3,25% (*Inception-v3*). Sementara peningkatan nilai *F1-Score* adalah 10,25% (*ResNet*), 3,25% (*EfficientNet*), dan 1% (*Inception-v3*).

4.5.6. Evaluasi Kinerja pada Klasifikasi Citra CXR

Hasil evaluasi kinerja klasifikasi citra menggunakan metode ELREI pada citra CXR telah dilakukan pada penelitian ini. Ukuran kinerja evaluasi yang digunakan yaitu nilai akurasi, presisi, *recall* dan *F1-Score* pada setiap kelas yang ditunjukkan seperti pada Tabel 4.4.

Tabel 4.4. Perbandingan Hasil Evaluasi Kinerja Menggunakan Metode ELREI

| Kelas | Akurasi (%) | Presisi (%) | <i>Recall</i> (%) | <i>F1-Score</i> (%) |
|---------------------|-------------|-------------|-------------------|---------------------|
| <i>COVID-19</i> | 99 | 99 | 99 | 99 |
| Normal | | 96 | 99 | 98 |
| <i>Lung Opacity</i> | | 100 | 97 | 99 |
| <i>Pneumonia</i> | | 100 | 100 | 100 |

Terlihat bahwa pada Tabel 4.4, metode ELREI memperoleh nilai presisi, *recall*, dan *F1-Score* pada setiap kelas dengan nilai yang berbeda-beda. Sementara nilai akurasi dihitung keseluruhan bukan pada setiap kelasnya. Untuk nilai presisi terendah diperoleh kelas normal, sedangkan untuk nilai presisi tertinggi diperoleh kelas *lung opacity* dan *pneumonia*. Untuk nilai *recall* terendah diperoleh kelas *lung opacity*, sedangkan untuk nilai *recall* tertinggi diperoleh kelas *pneumonia*. Untuk nilai *F1-Score* terendah diperoleh kelas normal, sedangkan untuk nilai *F1-Score* tertinggi diperoleh kelas *pneumonia*. Nilai rata-rata akurasi yang dihasilkan sebesar 99%, rata-rata presisi 98,75%, rata-rata *recall* sebesar 98,75%, dan rata-rata *F1-Score* 99%.

4.6. Analisis dan Interpretasi Hasil

Pada penelitian ini telah dilakukan klasifikasi citra CXR paru-paru menggunakan metode ELREI. Penelitian mengevaluasi kinerja metode ini dan membandingkannya dengan penelitian sebelumnya. Perbandingan hasil klasifikasi citra CXR paru-paru pada penelitian ini dengan penelitian lain dapat dilihat pada Tabel 4.5.

Tabel 4.5. Perbandingan Hasil Evaluasi Penelitian ini dengan Penelitian Lain

| Metode | Tahun | Akurasi (%) | Presisi (%) | Recall (%) | F1-Score (%) |
|--|-------------|-------------|--------------|--------------|--------------|
| EDL-COVID[119] | 2021 | 97.8 | 97.83 | 97.77 | 97.77 |
| Ensemble DCNN[120] | 2021 | 97.47 | - | 98.18 | - |
| Ensemble ResNet & DenseNet [121] | 2022 | 94.1 | 94.5 | 94.1 | 94 |
| CNN-Ensemble[122] | 2022 | 98 | 98 | 98.25 | 97,75 |
| Metode yang Diusulkan (ELREI) [123]⁴ | 2023 | 99 | 98,75 | 98,75 | 99 |

Pada Tabel 4.5 merupakan perbandingan hasil penelitian dengan menggunakan dataset yang sama pada citra CXR untuk klasifikasi penyakit paru-paru. Penelitian oleh [119] dan [120] memiliki nilai akurasi dan recall sama dengan atau lebih dari 95% tetapi tidak mengukur nilai presisi dan *F1-score*. Penelitian oleh [121] mencapai akurasi, presisi, *recall*, dan *F1-score* terendah dengan nilai di bawah 95%. Metode yang diusulkan (ELREI) mencapai akurasi, presisi, *recall*, dan *F1-score* tertinggi dengan nilai di atas 98%. Nilai akurasi dari metode yang diusulkan menunjukkan bahwa secara akurat mengklasifikasikan penyakit paru-paru pada gambar CXR. Nilai presisi dan *recall* menunjukkan bahwa model bekerja dengan baik dalam mengidentifikasi kasus positif dengan meminimalkan *false positive* dan *false negatives*. Nilai *F1-Score* menunjukkan performa yang seimbang

⁴ Kesuma, L. I., Ermatita, & Erwin. (2023). ELREI : Ensemble Learning of ResNet , EfficientNet , and Inception-v3 for Lung Disease Classification based on Chest X-Ray Image. *International Journal of Intelligent Engineering and Systems*, 16(5), 149–161. (Lampiran 2)

antara presisi dan *recall*. Berdasarkan hasil perbandingan pada Tabel 4.3, metode ELREI untuk klasifikasi citra CXR paru-paru memiliki kinerja yang sangat baik. Dilihat dari nilai performansi metode ELREI, metode ini dapat mengklasifikasikan citra CXR paru-paru dengan sangat baik.