TUGAS AKHIR – EB184803

PENINGKATAN KUALITAS CITRA *FOCAL LIVER DISEASE* MENGGUNAKAN CLAHE DAN KLASIFIKASI *FOCAL LIVER DISEASE* MENGGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK*

Upik Mauludia Rahmah
07311640000010

DOSEN PEMBIMBING:
Dr. Tri Arief Sardjono, S.T., M.T.
Ir. Siti Halimah Baki, M.T.

PROGRAM SARJANA
DEPARTEMEN TEKNIK BIOMEDIK
FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2020

TUGAS AKHIR – EB184803

PENINGKATAN KUALITAS CITRA *FOCAL LIVER DISEASE* MENGGUNAKAN CLAHE DAN KLASIFIKASI *FOCAL LIVER DISEASE* MENGGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK*

Upik Mauludia Rahmah
07311640000010

DOSEN PEMBIMBING:
Dr. Tri Arief Sardjono, S.T., M.T.
Ir. Siti Halimah Baki, M.T.

PROGRAM SARJANA
DEPARTEMEN TEKNIK BIOMEDIK
FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2020

FINAL PROJECT – EB184803

FOCAL LIVER DISEASE IMAGE ENCHANCEMENT USING CLAHE AND FOCAL LIVER DISEASE CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK

Upik Mauludia Rahmah
07311640000010

SUPERVISOR:
Dr. Tri Arief Sardjono, S.T., M.T.
Ir. Siti Halimah Baki, M.T.

UNDERGRADUATE PROGRAM
BIOMEDICAL ENGINEERING DEPARTMENT
FACULTY OF INTELLIGENT ELECTRICAL AND INFORMATICS TECHNOLOGY
SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY
SURABAYA
2020

PERNYATAAN KEASLIAN TUGAS AKHIR

Dengan ini saya menyatakan bahwa sebagian maupun keseluruhan isi tugas akhir saya yang berjudul "**Peningkatan Kualitas Citra *Focal Liver Disease* Menggunakan CLAHE dan Klasifikasi *Focal Liver Disease* Menggunakan Metode *Convolutional Neural Network***" merupakan hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya mandiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi seusai peraturan yang berlaku.

Surabaya, Agustus 2020

Upik Mauludia Rahmah
NRP. 07311640000010

Tugas Akhir disusun untuk memenuhi salah satu syarat memperoleh gelar
Sarjana Teknik (S.T.)
di
Institut Teknologi Sepuluh Nopember

Oleh
Upik Mauludia Rahmah
NRP. 07311640000010

Tanggal Ujian : 14 Juli 2020
Periode Wisuda : September 2020

Disetujui Oleh :

Dosen Penguji :

1. **Dr. Rachmad Setiawan, S.T., M.T.**
   NIP. 196905291995121001

2. **Atar Fuady Babgei, S.T., M.Sc.**
   NIP. 198911112018121001

3. **Eko Agus Suprayitno, S.Si., M.T.**
   NIP. 1987202011026

Dosen Pembimbing :

1. **Dr. Tri Arief Sardjono, S.T., M.T.**
   NIP. 197002121995121001

2. **Ir. Siti Halimah Baki, M.T.**
   NIP. 195611211983032001

Kepala Departemen Teknik Biomedik,

Dr. Achmad Arifin, S.T., M.Eng.
NIP. 197103141997021001

PENINGKATAN KUALITAS CITRA *FOCAL LIVER DISEASE* MENGGUNAKAN CLAHE DAN KLASIFIKASI *FOCAL LIVER DISEASE* MENGGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK*

Nama Mahasiswa	: Upik Mauludia Rahmah
NRP	: 07311640000010
Pembimbing	: 1. Dr. Tri Arief Sardjono, S.T., M.T.
	: 2. Ir. Siti Halimah Baki, M.T.

ABSTRAK

Proses diagnosa dan deteksi *focal liver diseases* seperti *Hepatic Hemangioma* dan *Hepatocellular Carcinoma* (HCC), dan kista dapat dilakukan dengan menggunakan modalitas *B-Mode ultrasound*. Adanya *noise* dalam citra *ultrasound* mempengaruhi ekstraksi fitur, dan kemiripan fitur antar penyakit membuat proses klasifikasi menjadi sulit. Selain itu, penyakit HCC, dan *hemangioma* terkadang memiliki *echogenity* yang sama, dan HCC juga terkadang dapat berbentuk menyerupai kista, sehingga dibutuhkan metode peningkatan citra untuk memperjelas karakteristik masing-masing penyakit tersebut untuk memudahkan proses klasifikasi. Tugas akhir ini bertujuan untuk merancang perangkat lunak untuk peningkatan citra *focal liver diseases* dan klasifikasi *focal liver diseases* dari citra *ultrasound*. Metode yang digunakan untuk mengurangi *noise* adalah median filter. Untuk membantu membedakan fitur antar penyakit, dan memperjelas perbedaan kontras lesinya, digunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Kemudian, proses klasifikasi penyakit dilakukan menggunakan metode *Convolutional Neural Network* (CNN). Untuk mengatasi *dataset* dengan ukuran kecil, dilakukan proses augmentasi data berupa transformasi geometris, dan penambahan *noise* untuk memperkaya jumlah dan variasi *dataset*. Dari hasil pengujian didapatkan bahwa median filter dengan *window* 3 × 3 memiliki nilai PSNR lebih tinggi dibandingkan dengan *window* 5 × 5, dan *window* 7 × 7. Augmentasi data dapat menambah jumlah data, menambah variasi, dan mengurangi *overfitting* model CNN. Peningkatan kualitas kontras citra *ultrasound* menggunakan metode CLAHE dapat membantu proses klasifikasi, dan nilai *clip limit* yang paling efektif untuk proses klasifikasi penyakit HCC adalah 0.03, untuk penyakit kista sebesar 0.01, dan penyakit *hemangioma* tidak di proses menggunakan CLAHE. Penggunaan CNN untuk klasifikasi *focal liver diseases* yaitu, penyakit HCC, *hemangioma*, dan kista, memiliki akurasi sebesar 69.70% ketika tidak ditingkatkan kontrasnya menggunakan CLAHE. Setelah ditingkatkan kontrasnya menngunakan CLAHE, akurasinya dapat naik hingga 93.94%. Mekipun akurasi yang didapat bisa mencapai 93.94%, tetapi hasil ini masih dapat berubah-ubah serta nilai *clip limit* dari CLAHE juga dapat berbeda jika menggunakan *dataset* lain karena model yang digunakan masih mengalami *overfitting*.

Kata kunci: *Ultrasound, Peningkatan Citra, CLAHE, Klasifikasi, CNN*

FOCAL LIVER DISEASE IMAGE ENCHANCEMENT USING CLAHE AND FOCAL LIVER DISEASE CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK

By : Upik Mauludia Rahmah
Student identity number : 07311640000010
Supervisor : 1. Dr. Tri Arief Sardjono, S.T., M.T.
: 2. Ir. Siti Halimah Baki, M.T.

ABSTRACT

The process of diagnosis and detection of focal liver diseases such as Hepatic Hemangioma, Hepatocellular Carcinoma (HCC), and cysts can be done using the B-Mode ultrasound modality. The presence of noise in ultrasound images affects feature extraction process, and the similarity of features between diseases makes the classification process difficult. In addition, HCC, and hemangioma sometimes have the same echogenity in ultrasound, and HCC can also sometimes be similar to cysts. An image enhancement method is needed to determine the characteristics of each of these diseases to help the classification process. This final project aims to design software for enhancing the image of focal liver diseases and the classification of focal liver diseases from ultrasound images. The method that used to reduce noise is the median filter. To help differentiate between diseases features, and to determine differences in contrast lesions, the Contrast Limited Adaptive Histogram Equalization (CLAHE) method is used. Then, the diseases classification process is carried out using the Convolutional Neural Network (CNN) method. To overcome the small size dataset, a data augmentation process is used in the form of geometric transformations, and the addition of noise to enrich the number and variation of the dataset. From the test results it was found that the median filter with window 3 × 3 has a higher PSNR value compared to window 5 × 5, and window 7 × 7. Data augmentation can increase the amount of data, increase variation, and reduce CNN overfitting. Increasing the contrast quality of ultrasound images using the CLAHE method can help the classification process, and the most effective clip limit value for the HCC disease classification process is 0.03, for cysts by 0.01, and hemangioma disease is not processed using CLAHE. CNN for the classification of focal liver diseases, namely, HCC, hemangioma, and cysts, has an accuracy of 69.70% when the contrast is not enhanced using CLAHE. After increasing the contrast using CLAHE, its accuracy can increase to 93.94%. Even though the accuracy obtained can reach 93.94%, but this result can still change and the clip limit value of CLAHE can also be different if using another dataset because the model used is still experiencing overfitting.

Key Words: *Ultrasound, Image enhancement, CLAHE, Classification, CNN.*

KATA PENGANTAR

Penulis mengucapkan puji syukur kepada Tuhan Yang Maha Esa karena atas berkat dan rahmat-Nya penulis mampu menyelesaikan tugas akhir ini dengan lancar dan dapat selesai tepat pada waktunya. Penulis juga mengucapkan terima kasih kepada pihak-pihak yang telah membantu dan memberikan motivasi saat pengerjaan tugas akhir ini, maka dari itu penulis mengucapkan terima kasih kepada:

1. Orang tua serta keluarga penulis yang selalu memberi do'a dan dukungan dan memberikan kepercayaan untuk dapat menyelesaikan tugas akhir ini.
2. Dr. Tri Arief Sardjono, S.T., M.T. dan Ir. Siti Halimah Baki, M.T. selaku dosen pembimbing yang senantiasa membimbing, mengarahkan, dan menginspirasi penulis selama pengerjaan penelitian ini.
3. Dr. Achmad Arifin, S.T., M.Eng. selaku kepala departemen Teknik Biomedik ITS
4. Muhammad Yazid, B.Eng, M.Eng., selaku dosen wali
5. Rekan-rekan Teknik Biomedik angkatan 2016 yang saya sayangi.
6. Bapak Ibu dosen pengajar Teknik Biomedik ITS.
7. Serta seluruh pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis hingga Tugas Akhir ini ini bisa diselesaikan dengan semaksimal mungkin.

Penulis sadar bahwa masih terdapat banyak kekurangan pada berbagai aspek dan masih banyak hal yang perlu diperbaiki dalam tugas akhir ini. Oleh karena itu, penulis dengan terbuka menerima kritik dan saran dari pembaca agar dapat memperbaiki tugas akhir ini. Semoga penelitian ini dapat memberikan manfaat untuk banyak orang dan dapat dikembangkan lebih baik lagi pada penelitian selanjutnya.

Surabaya, Agustus 2020
Penulis

DAFTAR ISI

PERNYATAAN KEASLIAN TUGAS AKHIR i
LEMBAR PENGESAHAN ii
ABSTRAK iii
ABSTRACT iv
KATA PENGANTAR v
DAFTAR ISI vi
DAFTAR GAMBAR viii
DAFTAR TABEL x
BAB I PENDAHULUAN 1
1.1. Latar Belakang 1
1.2. Rumusan Masalah 2
1.3. Batasan Masalah 3
1.4. Tujuan dan Manfaat 3
1.5. Kontribusi 3
BAB II TINJAUAN PUSTAKA 5
2.1. Liver Diseases 5
2.1.1. *Hepatocellular carcinoma* (HCC) 5
2.1.2. *Cyst* (Kista) 5
2.1.3. *Hepatic Hemangioma* 6
2.2. *Focal Liver Diseases Imaging* 6
2.3. Augmentasi Data 8
2.4. Median Filter 10
2.5. *Contrast Limited Adaptive Histogram Equalization* (CLAHE) 10
2.6. *Convolutional Neural Network* (CNN) 11
2.7 Rasional 14
BAB III PERANCANGAN SISTEM 17
3.1. Desain Sistem Secara Umum 17
3.2. *Dataset* 18
3.2.1. Keterangan *Dataset* 18
3.2.2. Penyiapan *Dataset* 18
3.3. Pemrosesan Data 19
3.3.1. Augmentasi Data 19

3.3.2. Image Pre-processimg 19
3.3.3. Perancangan CNN 20
3.4. Estimasi Performasi Sistem 22
BAB IV PENGUJIAN SISTEM 25
4.1. Augmentasi Data 25
4.2. *Image Pre-processing* 27
4.2.1. Median Filter 27
4.2.2. *Contrast Limited Adaptive Histogram Equalization* (CLAHE) 28
4.3. CNN Untuk Klasifikasi *Focal Liver Diseases* 32
4.4. CNN Untuk Data Hasil Pemrosesan dengan CLAHE 36
BAB V PEMBAHASAN 42
5.1. Augmentasi Data 42
5.2. *Image Pre-processing* 43
5.2.1. Median Filter 43
5.2.2. *Contrast Limited Adaptive Histogram Equalization* (CLAHE) 44
5.3. CNN untuk Klasifikasi *Focal Liver Diseases* 45
5.4. Pengaruh *Clip limit* CLAHE Terhadap Masing-masing Hasil Klasifikasi Penyakit 47
5.5. Perbandingan Dengan Penelitian Sebelumnya 48
5.6. Kontribusi dan Ruang Pengembangan 49
BAB VI KESIMPULAN DAN SARAN 50
6.1. Kesimpulan 50
6.2. Saran 50
DAFTAR PUSTAKA 52
BIODATA PENULIS 54

DAFTAR GAMBAR

Gambar 2. 1. Penggunaan Modalitas Pencitraan untuk diagnosa HCC dari EASL-EORTC [2] 7
Gambar 2. 2 Citra *Ultrasound* (a) Kista, (b) *Hemangioma*, (c) HCC, (d) *Metastases*, (e) *Normal Liver* [9]..... 8
Gambar 2. 3. Arsitektur CNN (a) VGG-19, (b) ResNet-152 [15] 12
Gambar 2. 4. Arsitektur yang diajukan oleh Pasupa et al. tahun 2016 [14] 13
Gambar 2. 5 *Fishbone Diagram*..... 16
Gambar 3. 1. Diagram blok sistem secara keseluruhan……18
Gambar 3. 2. Hasil *labeling* untuk masing-masing penyakit yang disimpan dalam *file* .csv..... 20
Gambar 3. 3. *Flowchart learning* CNN 24
Gambar 4. 1. Hasil augmentasi data geometris (a) *width shift*, (b) *height shift*..26
Gambar 4. 2. Hasil augmentasi data horizontal *flip* 26
Gambar 4. 3. Hasil augmentasi data *noise* (a) *Gaussian Noise*, (b) *Salt and pepper noise*..... 26
Gambar 4. 4. Gambar sebelum dilakukan *pre-processing* (a) Kista, (b) HCC, (c) *hemangioma* 27
Gambar 4. 5. Hasil median filter dengan *window* 3 × 3 (a) Kista, (b) HCC, (c) *Hemangioma*..... 28
Gambar 4. 6. Hasil median filter dengan *window* 5 × 5 (a) Kista, (b) HCC, (c) *Hemangioma*..... 28
Gambar 4. 7. Hasil median filter dengan *window* 7 × 7 (a) Kista, (b) HCC, (c) *Hemangioma*..... 28
Gambar 4. 8. Gambar penyakit kista setelah diproses dengan CLAHE dengan *clip limit* (a) 0.01, (b) 0.02, (c) 0.03 29
Gambar 4. 9 Gambar penyakit HCC setelah diproses CLAHE dengan *clip limit* (a) 0.01, (b) 0.02, (c) 0.03..... 29
Gambar 4. 10. Gambar penyakit Hemangima setelah diproses CLAHE dengan *clip limit* 0.01, 0.02, 0.03..... 30
Gambar 4. 11. Histogram sebelum diproses menggunakan CLAHE..... 30
Gambar 4. 12. Histogram gambar HCC setelah diproses dengan CLAHE, dengan *clip limit* 0.01, 0.02, 0.03..... 31
Gambar 4. 13. Histogram gambar *Hemangioma* setelah diproses dengan CLAHE, dengan *clip limit* 0.01, 0.02, 0.03 31
Gambar 4. 14. Histogram gambar Kista setelah diproses dengan CLAHE, dengan *clip limit* 0.01, 0.02, 0.03..... 32
Gambar 4. 15. Hasil grafik akurasi *training* dan validasi untuk data yang tidak diaugmentasi..... 34

Gambar 4. 16. Hasil grafik *loss* atau *error training* dan validasi untuk data yang tidak diaugmentasi 34
Gambar 4. 17. Hasil grafik akurasi *training* dan validasi untuk data yang diaugmentasi 35
Gambar 4. 18. Hasil grafik *loss* atau *error training* dan validasi untuk data yang diaugmentasi 35
Gambar 4. 19 *Confusion matrix* CNN untuk data yang tidak diproses dengan CLAHE, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC).... 37
Gambar 4. 20. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE, dengan *clip limit* 0.01, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC) 37
Gambar 4. 21. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE, dengan *clip limit* 0.02, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC) 38
Gambar 4. 22. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE, dengan *clip limit* 0.03, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC) 38
Gambar 4. 23. Hasil grafik akurasi *training* dan validasi untuk data yang diproses menggunakan *clip limit* efektif CLAHE..... 40
Gambar 4. 24. Hasil grafik *loss* atau *error training* dan validasi untuk data yang diprocess menggunakan *clip limit* efektif CLAHE 40
Gambar 4. 25. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE dengan *clip limit* berbeda-beda , (Keterangan: 0 = Kista, *clip limit* 0.01, 1 = *Hemangioma*, *clip limit* 0, 2 = HCC, *clip limit* 0.03).... 41
Gambar 5. 1. Perbandingan (a) data asli dengan (b) hasil rotasi dengan sudut 40 derajat……..43
Gambar 5. 2. Gambar kista yang menyerupai HCC, (a) gambar kista yang kontrasnya ditingkatkan terlalu tinggi (*clip limit* = 0.03) sehingga mirip dengan HCC, (b) Gambar HCC 45

DAFTAR TABEL

Tabel 3. 1. Arsitektur CNN yang diajukan 21
Tabel 3. 2. *Confusion matrix* untuk multi kelas 23
Tabel 4. 1. Tabel presisi dan spesifisitas per penyakit 39
Tabel 4. 2. Tabel presisi dan spesifisitas hasil *training* dengan *clip limit* efektif .41

BAB I PENDAHULUAN

1.1. Latar Belakang

Indonesia memiliki penderita kanker hati dengan presentase sebesar 12.4 per 100.000 penduduk dengan rata-rata kematian 7.6 per 100.000 penduduk [1]. Hati orang dewasa umumnya dipengaruhi oleh dua jenis kelainan yaitu penyakit *focal* atau *diffused liver*. Penyakit *focal liver*, seperti *Hepatocellular Carcinoma* (HCC) yang merupakan jenis kanker hati, *Cyst* atau kista, dan *Hepatic Hemangioma* atau tumor jinak, muncul sebagai bagian terkonsentrasi dan padat di satu titik atau di beberapa titik, sedangkan penyakit *diffused liver* seperti *fatty liver* tersebar di seluruh area atau seluruh hati.

B-Mode ultrasound adalah modalitas pertama yang biasa digunakan untuk proses deteksi penyakit hati. Hal ini berlaku untuk penyakit *focal liver* seperti HCC, *Hepatic Hemangioma*, dan juga kista. Terutama untuk HCC, berdasarkan *European Association for the Study of Liver - European Organisation for Research and Treatment Cancer* (EASL-EORTC) menyatakan bahwa pasien yang memiliki risiko untuk mengalami perkembangan dalam penyakit HCC harus melakukan program pengawasan, dimana pengawasan dilakukan menggunakan *abdominal ultrasound* setiap 6 bulan [2].

Tidak adanya informasi tambahan seperti warna, bentuk yang pasti atau fitur yang membedakan dan kontras membuat tugas klasifikasi penyakit secara otomatis dari citra *ultrasound* menjadi rumit. Kejelasan citra yang diperoleh juga tergantung pada beberapa parameter lain seperti arah pemindaian, tekanan yang diterapkan dan *echogenecity* yang diterima dari bagian tubuh dimana *probe* dioperasikan. Adanya *noise* dalam citra *ultrasound* juga mempengaruhi ekstraksi fitur dan karenanya akurasi klasifikasi dalam citra *ultrasound* memiliki hasil yang kurang baik.

Perkembangan di bidang pemrosesan citra dan otomatisasi telah mengarah pada penelitian yang intensif dan ekstensif di bidang klasifikasi penyakit otomatis berbasis citra *ultrasound* dalam beberapa tahun terakhir. *Image enhancement* merupakan salah satu cara peningkatan kualitas citra. Pengingkatan yang dilakukan dapat berupa beberapa hal seperti pengurangan noise, penigkatan kontras citra, dan lain-lain. Salah satu metode untuk *image enhancement* dalam segi peningkatan kontras adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Seperti dalam penelitian yang telah dilakukan oleh Smriti Sahu, et al dengan judul *Comparative Analysis of Image enhancement Techniques for Ultrasound Liver Image* [3] melakukan perbandingan empat metode *image enhancement*, yaitu *contrast stretching, shock filter, histogram equalization*, dan CLAHE. Dari hasil tersebut menunjukkan bahwa CLAHE dapat digunakan sebagai teknik untuk peningkatan kualitas citra *ultrasound* hati untuk tumor.

Dalam segi klasifikasi otomatis dari citra *ultrasound*, pada penelitian yang dilakukan oleh Raghesh Krishnan K, dengan judul *Focal and Diffused Liver Disease Classification from Ultrasound Image based on Isocontour Segmentation* melakukan sebuah pendekatan baru menggunakan Segmentasi *Isocontour* berdasarkan *Marching Squares* [4]. GLCM dan *fractal features* diekstraksi dari citra *ultrasound* tersegmentasi dan diklasifikasikan menggunakan SVM dan *Artificial Neural Network* (ANN) dan hasilnya dianalisis. Pada penelitian tersebut menjelaskan bahwa klasifikasi dengan menggunaka metode SVM untuk fitur GLCM mengalami beberapa kesalahan klasifikasi, seperti antara kista dan HCC karena letak dan penampilan yang hampir sama, dan *Hepatocellular carcinoma* (HCC) dapat muncul sebagai lesi padat, *cystic* atau *mixed lesion* dalam citra hati. Area nekrosis atau pendarahan di dalam tumor membuat penampilan *cystic* pada pencitraannya. HCC juga dapat menjadi *cystic* setelah *transarterial chemoembolization atau radio frequency ablation* [5]. Peneliti menyebutkan bahwa kesalahan klasifikasi ini dapat diatasi dengan metode untuk fitur ekstraksi atau teknik klasifikasi yang lebih baik.

Metode klasifikasi untuk citra medis menggunakan *neural network* telah banyak dikembangkan. Salah satu jenis neural network yang banyak digunakan untuk klasifikasi citra adalah *Convolutional Neural Network* [6]. Metode CNN digunakan untuk mengurangi proses pemilihan ektraksi fitur, seperti dalam SVM yang biasanya menggunakan fitur GLCM atau *fractal*, karena pada CNN sendiri terdapat *feature learning* yang dapat mendapatkan fitur secara otomatis pada saat proses *learning*. Oleh sebab itu, pada tugas akhir ini, bertujuan untuk mencoba metode baru pada proses klasifikasi berupa *Convolutional Neural Network* (CNN), serta penambahan *pre-processing* berupa reduksi *noise* dengan median filter, dan *image enhancement* dengan menggunakan metode CLAHE. Metode ini diharapkan dapat menghasilkan klasifikasi penyakit hati yang memiliki akurasi yang lebih baik untuk proses klasifikasi penyakit HCC, kista, dan *Hepatic Hemangioma*.

1.2. Rumusan Masalah

Permasalahan yang terdapat pada citra *ultrasound* dari *focal liver diseases* ini adalah dalam citra *ultrasound* biasanya terdapat *noise* yang dapat mempengaruhi kualitas citra dan membuat proses pembacaan dan klasifikiasi menjadi sulit. Selain itu dalam citra *ultrasound* untuk penyakit *liver* HCC, kista, dan *hepatic hemangioma* sering memiliki kesamaan baik dari bentuk, ukuran, dan dari sifat *echogenity* nya, sehingga sering terjadi kesalahan saat deteksi. Maka dari itu rumusan masalah yang diambil pertama adalah bagaimana perancangan perangkat lunak untuk megurangi *noise*, dan peningkatan kualitas kontras citra dari citra *ultrasound liver* dengan menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE).

Rumusan masalah yang kedua adalah mengenai bagaimana perancangan perangkat lunak untuk klasifikasi citra yang didapatkan menjadi 3 penyakit, yaitu HCC, *Hepatic Hemangioma*, dan Kista dengan menggunakan *Convolutional Neural Network*, dan bagaimana pengaruh penambahan *image enhancement* berupa CLAHE dapat mempengaruhi akurasi pengujian dari program CNN yang dirancang.

1.3. Batasan Masalah

Terdapat tiga batasan masalah dalam tugas akhir ini, yaitu:

1. Citra medis yang digunakan adalah citra modalitas *ultrasound*.
2. Data yang didapatkan merupakan data sekunder.
3. Data pengujian merupakan data *offline*.
4. Klasifikasi hanya dilakukan untuk tiga penyakit yaitu HCC, *Hepatic Hemangioma*, dan Kista.

1.4. Tujuan dan Manfaat

Tujuan dari tugas akhir ini dibagi menjadi dua yaitu, yang pertama adalah untuk meningkatkan kualitas kontras citra *ultrasound* dari *focal liver diseases* dengan menggunakan metode CLAHE, dan yang kedua adalah klasifikasi *focal liver diseases* menggunakan metode *Convolutional Neural Netwotk*. Peningkatan kualitas citra bertujuan agar kontras dari citra semakin tinggi dan dapat terlihat bagian tepi dari lesi secara agar memudahkan proses klasifikasi. Kemudian, metode CNN digunakan untuk tujuan agar citra *ultrasound liver* dari penyakit *focal liver* yaitu HCC, kista, dan *Hepatic Hemangioma* dapat terklasifikasikan sesuai dengan penyakitnya dengan tingkat klasifikasi akurasi yang tinggi.

Manfaat yang ingin dicapai dalam penelitian ini meliputi aspek teoritis dan aspek praktis. Manfaat dalam aspek teoritis yang diharapkan adalah dapat menambah wawasan dan khasanan ilmiah mengenai proses peningkatan citra *focal liver disease* dan klasifikasi citra *focal liver diseases* menggunakan metode CNN. Manfaat dalam aspek praktis yang diharapkan adalah peningkatan akurasi untuk proses klasifikasi citra *ultrasound* dari penyakit HCC, *Hepatic Hemangioma*, dan kista hati, dan juga peningkatan citra dari *focal liver diseases* untuk meningkatkan kontras dan memperjelas tepi dari lesi.

1.5. Kontribusi

Kontribusi dari penelitian ini dapat dilihat dari dua aspek yaitu ilmiah dan praktis. Pada aspek ilmiah, kontribusinya adalah menjadi suatu pengembangan untuk pendidikan dan penelitian dalam bidang biomedik. Penelitian ini merupakan sistem peningkatan kontras citra *focal liver disease* menggunakan CLAHE dan klasifikasi *focal liver diseases* dengan *Convolutional Neural Network*. Sedangkan untuk kontribusi dalam aspek praktisnya adalah pada penelitian sebelumnya, telah diusulkan penggunaan *Support Vector Machine* (SVM) dan *Artificial Neural*

Network (ANN) untuk klasifikasi. Untuk penelitian ini digunakan metode CNN untuk meningkatkan akurasi klasifikasi citra *ultrasound*, serta penambahan dalam proses *pre-processing* dengan menggunakan median filter untuk mereduksi *noise*, kemudian metode CLAHE digunakan untuk meningkatkan kontras dari lesi.

BAB II TINJAUAN PUSTAKA

2.1. *Liver Diseases*

Penyakit hati secara garis besar dapat diklasifikasi menjadi dua, yaitu *focal* dan *diffused liver disease*. *Focal liver disease* biasanya berbentuk seperti kista, atau lesion yang berada di satu, atau beberapa titik. Sedangkan *Diffused liver disease* merupakan penyakit hati yang bersifat menyebar keseluruh bagian hati. Beberapa contoh penyakit yang termasuk dalam kategori *focal liver diseases* adalah *Hepatocellular Carcinoma* (HCC), *Hemangioma*, dan Kista (*cyst*).

2.1.1. *Hepatocellular carcinoma* (HCC)

Hepatocellular carcinoma (HCC) adalah kanker hati primer yang paling umum dan merupakan penyebab utama kematian terkait kanker di seluruh dunia. Penyakit hati kronis dan sirosis merupakan faktor risiko paling penting untuk pengembangan HCC dimana virus hepatitis dan asupan alkohol berlebihan adalah faktor risiko utama di seluruh dunia [2].

Virus hepatitis kronis dapat menyebabkan sirosis hingga kanker hati. Hepatitis kronis merupakan hasil dari memperparahnya penyakit hepatitis B dan C. kronis. Hepatitis B ditularkan melalui transfusi darah yang terkontaminasi, suntikan intravena, dan kontak seksual. Peyebab utama infeksi virus hepatitis B adalah melalui penularan vertikal dari ibu ke janin. Hampir lima persen populasi dunia terinfeksi virus hepatitis B. Pada hepatitis C, perkembangan HCC atau kanker hati terjadi hampir secara keseluruhan di hati yang mengalami sirosis. Infeksi ganda antara HBV dan HCV pada pasien sirosis meningkatkan risiko HCC dengan *odds ratio* (OR) 165 dibandingkan dengan 17 untuk hepatitis C dan 23 untuk hepatitis B saja. Efek sinergis dengan alkohol meningkatkan kejadian HCC antara 1,7- dan 2,9 kali lipat bila dibandingkan dengan HCV-HCC saja. Risiko HCC berkurang secara signifikan pada pasien yang memperoleh penanganan virus yang berkelanjutan setelah pengobatan HCV dengan penurunan 54% dalam semua penyebab kematian. Sementara kemajuan dalam pengobatan baru-baru ini telah membuat mengobati HCV lebih mudah, vaksinasi terhadap virus tetap sulit.

2.1.2. *Cyst* (Kista)

Kista hati sering ditemukan secara kebetulan pada pencitraan abdominal. Meskipun sebagian besar kista bersifat jinak, dan tedapat beberapa yang bersifat ganas atau premaligna, diagnosis lesi kistik sangat penting agar dapat ditangani dengan baik. Pencitraan dengan *ultrasound*, *computed tomography*, *magnetic resonance imaging*, atau *contrast-ultrasound* dapat digunakan untuk lebih mengkarakterisasi dan mendiagnosis kista hati [5].

Kista hati biasanya dibagi menjadi dua yaitu *simple cyst*s, dan *complex cyst*s. *Simple hepatic cyst*s adalah lesi dengan dinding tipis dan halus, dilapisi dengan epitel berbentuk kubus, yang mengeluarkan cairan seperti empedu. *Simple*

*cyst*s memiliki diameter mulai dari <1 cm hingga 30 cm dan dapat mengandung hingga 2 septa, tidak seperti *complex cyst* yang biasanya *multiseptate*. *Simple cyst*s termasuk dalam kista kongenital, hamartoma bilier, penyakit Caroli dan penyakit hati polikistik (PCLD). PCLD adalah penyebab lain dari *simple cyst*s. PCLD adalah suatu kondisi genetik, yang dapat terjadi bersamaan dengan penyakit ginjal polikistik atau mungkin terbatas pada hati. Hati menjadi membesar, mengandung banyak kista (biasanya> 20), dengan berbagai ukuran.

*Complex cyst*s didefinisikan oleh adanya fitur kompleks dalam lesi, termasuk septasi, penebalan atau nodularitas mural, cairan yang mengandung puing-puing, peningkatan radiografi, konten hemoragik atau protein. *Complex cyst*s meliputi neoplastik, inflamasi, infeksi, pasca-trauma dan lainnya.

2.1.3. *Hepatic Hemangioma*

Hepatic Hemangioma atau *hemangioma* adalah tumor hati jinak yang terdiri dari kelompok rongga berisi darah, dan dibatasi oleh sel endote. Sebagian besar *Hepatic Hemangioma* tidak menunjukkan gejala dan paling sering ditemukan secara kebetulan selama proses pencitraan untuk berbagai patologi yang tidak terkait. *Hemangioma* kapiler, berkisar dari beberapa mm hingga 3 cm, tidak bertambah besar seiring waktu dan oleh karena itu tidak mungkin menghasilkan simptomatologi masa depan. *Hemangioma* kecil (>1mm-3 cm) dan sedang (<3 cm-10 cm) adalah lesi yang terdefinisi dengan baik, tidak memerlukan pengobatan aktif selain cek rutin [7].

2.2. *Focal Liver Diseases Imaging*

B-Mode ultrasound merupakan modalitas yang dapat digunakan dalam proses *screening* penyakit-penyakit hati karena radiasinya yang rendah, dari segi ketersediaan, dan juga dalam segi biaya tidak terlalu mahal [8]. Untuk proses screening HCC USG memiliki sensitivitas dari 58-89% [6], sedangkan untuk *Hepatic Hemangioma* sensitivitas nya bisa mencapai 96,9% [7].

USG dilakukan pada populasi berisiko seperti pasien sirosis, pembawa HBV non-sirosis dengan hepatitis aktif atau riwayat keluarga dengan kanker hati, pasien non-sirosis dengan hepatitis C kronis atau fibrosis hati lanjut. Nodul kecil yang kurang dari 1 cm yang terdeteksi di USG harus diikuti setiap 3-4 bulan pada tahun pertama dan setiap 6 bulan sesudahnya. Pedoman AASLD merekomendasikan tes pencitraan diagnostik tunggal untuk nodul HCC> 1 cm pada pasien sirosis, sedangkan pedoman EASL-EORTC (Gambar 2.1), menyarankan tes pencitraan diagnostik tunggal untuk nodul> 2 cm dan 2 tes diagnostik dan / atau biopsi untuk nodul antara 1 dan 2 cm untuk karakterisasi. Beberapa peneliti telah mengusulkan penggunaan CT dan MRI untuk tujuan screening HCC sebagai alternatif untuk US karena sulit dengan penggunaan pada individu yang obesitas dan pasien yang memiliki sirosis lanjut. Namun, modalitas ini mahal dan ada risiko paparan radiasi kumulatif dari beberapa CT *scan*. Oleh

karena itu, USG biasanya digunakan sebagai alat pengawas untuk deteksi HCC pada hati sirosis, dan CT atau MRI digunakan untuk evaluasi lebih lanjut jika nodul> 1 cm terdeteksi [8].

Dalam segi *echogenitynya* (Gambar 2.2), kista memiliki karakteristik *anechoic* dengan peningkatan *distal acoustic* dan dinding tipis yang tidak terlihat. Sedangkan *Hemangioma* dalam *echogenitynya* bersifat *hyperechoic* dan memiliki tekstur yang homogen. *Hepatocelullar Carcinoma* memiliki sifat *hypoechoic* dengan tekstur yang bersifat *heterogeneous*, tetapi lesi HCC yang kecil dapat terlihat *hypoechoic* dan *homogenous*. Jaringan hati yang normal memiliki ciri *isoechoic* dan memiliki tekstur yang *homogeneous* [9]. Tetapi terkadang, *hemangioma* sering terdeteksi selama pengawasan HCC dan berpotensi meniru HCC terutama ketika lesi berukuran kecil. Pada citra *grayscale* USG, *hemangioma* biasanya *hyperechoic*. Tetapi *hemangioma* kadang-kadang bersifat *hypoechoic*, terutama ketika hati berlemak, atau menunjukkan *echogenicity* campuran, sehingga terdapat kemungkinan untuk kesalahan pembacaan hasil citra *ultrasound* antara HCC dengan *hemangioma* [10].

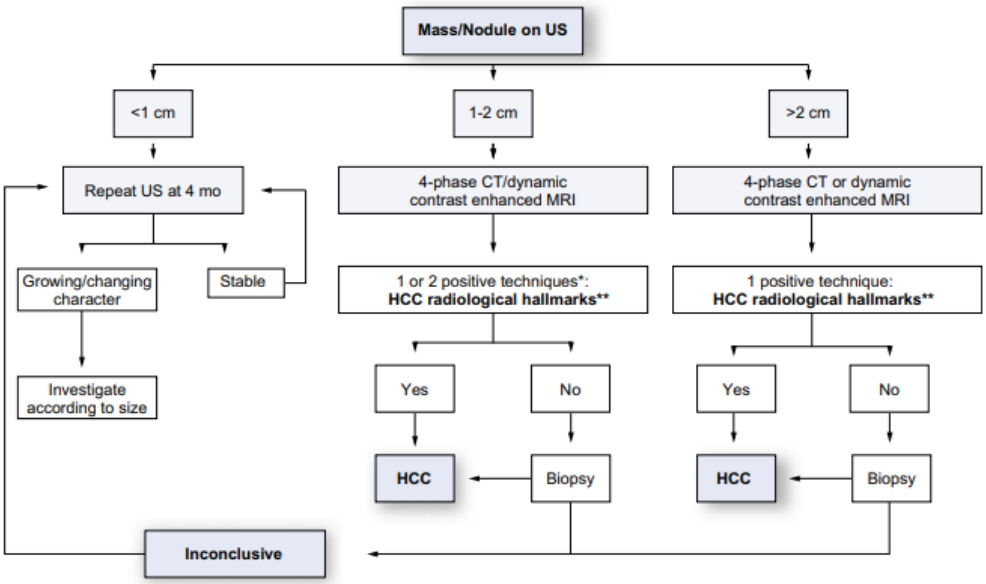

Gambar 2. 1. Penggunaan Modalitas Pencitraan untuk diagnosa HCC dari EASL-EORTC [2]

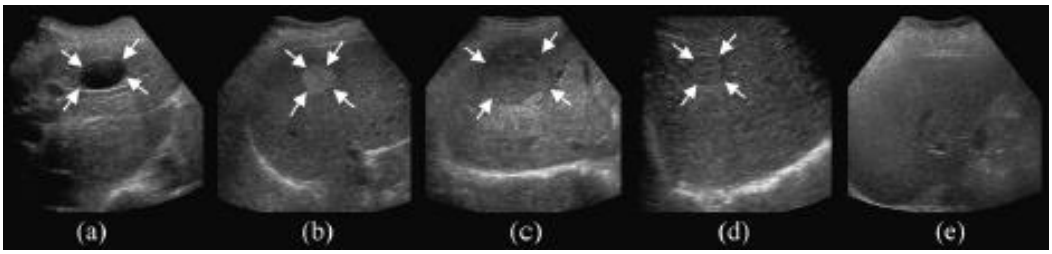

Gambar 2. 2 Citra *Ultrasound* (a) Kista, (b) *Hemangioma*, (c) HCC, (d) *Metastases*, (e) *Normal Liver* [9]

2.3. Augmentasi Data

Augmentasi Data merupakan salah satu metode untuk memperbanyak jumlah data dalam suatu *dataset* yang berukuran kecil untuk dilatih dalam model *deep learning* yang kompleks. Augmentasi data dapat digunakan sebagai solusi untuk mengatasi masalah *over-fitting*.

Augmentasi data tradisional dapat menaikkan performansi dalam pekerjaan *visual* seperti *image classification* dan *recognition*. *Data augmentation* tradisional dapat memperbanyak jumlah gambar menjadi beberapa kali bahkan 10 kali lebih dari gambar aslinya. *Data augmentation* dapat secara efektif meningkatkan kemampuan generalisasi dari citra yang di latih.

Konsep kunci dari augmentasi data adalah bahwa deformasi yang diterapkan pada data berlabel tidak mengubah makna semantik label. Contoh seperti dalam *computer vision*, gambar mobil yang diputar, ditranslasi, dicerminkan atau diskalakan akan tetap menjadi gambar dari sebuah mobil, dan dengan demikian dimungkinkan untuk menerapkan deformasi ini untuk menghasilkan data *training* tambahan dengan tetap menjaga keabsahan label semantik mobil. Dengan *training* jaringan pada data deformasi tambahan, diharapkan jaringan menjadi invarian terhadap deformasi ini dan men-generalisasikan dengan lebih baik untuk data yang tidak terlihat [11].

Demonstrasi augmentasi data awal yang menunjukkan keefektifan dari augmentasi data adalah menggunakan transformasi sederhana, seperti *horizontal flipping*, augmentasi *color space*, dan *random cropping*. Selain itu terdapat beberapa jenis augmentasi seperti transformasi geometris, transformasi *color space*, *kernel filter*, pencampuran gambar, *random erasing*, *feature space augmentation*, dll. [12]

Augmentasi data berdasarkan manipulasi gambar yang paling sederhana adalah transformasi geomteri. Beberapa contoh transformasi geometri yang adalah:

- *Flipping*

Penggunaan *horizontal flipping* lebih umum dilakukan dibandingkan dengan *vertical flipping*. Augmentasi ini merupakan jenis augmentasi paling

mudah dan telah terbukti kegunaanya pada *dataset* seperti *dataset* CIFAR-10, dan ImageNet. Pada *dataset* yang digunakan untuk pengenalan teks, augmentasi ini tidak bisa dilakukan karena dapat mengubah fitur utama dari data.

- *Color Space*

Data gambar digital biasanya dikodekan sebagai tensor dimensi (tinggi × lebar, *color channel*). Augmentasi pada *color channel* gambar dapat dilakukan dengan sangat mudah, yaitu dengan mengisolasi satu dari tiga *color channel* (R, G, B). Gambar dapat dengan mudah diubah menjadi representasi lain hanya dengan menggunakan satu *channel color*, dan 2 matriks *color channel* lainnya di nol kan. Selain itu nilai-nilai RBG dapat dengan mudah dimanipulasi dengan operasi matriks sederhana untuk menambah atau mengurangi tingkat kecerahan gambar. Augmentasi data dalam *color space* lainnya adalah dengan mengatur histogram gambar. Dengan mengubah intensitas histogram dapat dihasilkan perubahan pencahayaan seperti yang digunakan dalam aplikasi pengeditan foto.

- *Cropping*

Memotong gambar dapat digunakan sebagai langkah pemrosesan praktis untuk data gambar dengan dimensi tinggi dan lebar campuran. Tinggi dan lebar dipotong sesuai dengan pusat dari masing-masing gambar. Selain itu, pemotongan bagian gambar secara acak juga dapat memberikan efek yang sama dengan proses translasi. Perbedaan dari *cropping* dan translasi adalah pada *cropping*, ukuran input gambar seperti 256 × 256 dipotong mejadi 224 × 224, sedangkan transalasi akan menjaga dimensi spasial dari gambar.

- Rotasi

Augmentasi rotasi dilakukan dengan cara merotasi *axis* kanan atau kiri gambar dengan sudut antara 1 dan 359 derajat. Kegunaan augmentasi rotasi sangat bergantung pada nilai derajat yang digunakan. Rotasi dengan derajat antara 1 sampai 20 derajat, atau -1 sampai -20 derajat dapat digunakan untuk tugas pengenalan digit seperti dalam MINIST, tetapi nilai derajat yang lebih tinggi dapat membuat fitur utama data berubah.

- Translasi

Menggeser gambar ke kiri atau kanan, ke atas atau bawah sangat berguna untuk mencegah positional bias dari data. Sebagai contoh, jika semua gambar dalam *dataset* tepat berada di tengah, hal ini membuat model hanya dapat melakukan pengujian dengan baik jika gambar juga berapa tepat di tengah. Saat gambar asli digeser ke suatu arah, ruang yang tersisa dapat di isi dengan nilai konstan seperti 0 atau 255, atau dapat di isi dengan *random* atau *Gaussian noise*. *Padding* ini membantu mempertahankan dimensi spasial pasca augmentasi gambar.

2.4. Median Filter

Median filter adalah filter *non-linear* dan merupakan teknik filter paling baik untuk mengurangi *noise salt and paper*. Median filter juga merupakan filter yang dapat mempertahankan tepi-tepi tajam pada gambar. Tetapi, filter median filter ini memliki kelemahan yaitu tidak bisa membedakan antara detail yang *noisy* dan *non-noisy* [13].

Cara kerja median filter adalah dengan menerapkan *window* biasanya berukuran 3 × 3, 5 × 5, atau 7 × 7, pada gambar. Kemudian nilai intensitas piksel yang berada dalam *window* akan diurutkan dari yang terkecil hingga terbesar, dan kemudian diambil nilai tengahnya. Kemudian *window* akan bergerak terus hingga sampai pada ujung gambar. Rumus untuk median filter dapat dilihat pada Persamaan (2.1)

$$f(x, y) = median\,\{g(s, t)\}, (s, t\ \in Sxy) \tag{2.1}$$

2.5. *Contrast Limited Adaptive Histogram Equalization* (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) adalah generalisasi dari *Adaptive Histogram Equalization* dan digunakan untuk mencegah masalah amplifikasi *noise*. Algoritma CLAHE membagi gambar menjadi bagian-bagian daerah dan kemudian pada daerah-daerah tersebut diterapkan pemerataan histogram. Algortima ini meratakan distribusi *gray-level* yang digunakan dan dengan demikian distribusi tersebut dapat membuat fitur tersembunyi dari gambar lebih terlihat [3]. Metode ini memiliki dua parameter, yaitu:

- Ukuran blok, adalah ukuran wilayah lokal sekitar piksel yang histogramnya disamakan. Ukuran ini harus lebih besar dari ukuran fitur yang harus dipertahankan.
- Histogram *bin*, adalah jumlah histogram *bin* yang digunakan untuk proses pemerataan histogram, dimana harus lebih kecil dari jumlah piksel dalam satu blok. Nilai ini juga membatasi kuantifikasi output saat memproses gambar 8 bit *grayscale* atau 24 bit RGB.

Terdapat satu parameter tambahan *clip limit* yang bisa diatur dengan variasi antara 0 dan 1. Metode ini menghitung histogram untuk setiap piksel dan kemudian dilakukan proses *equalization* pada ukuran blok. Setelah dihasilkan nilai histogram, jika nilai tersebut di atas *clip limit*, maka nilai yang lebih dari *clip limit* akan didistribusikan secara rata ke semua *bin*, sehingga kontras dapat naik [3].

2.6. *Convolutional Neural Network* (CNN)

Convolutional Neural Network (CNN) pertama kali diperkenalkan oleh Fukushima pada tahun 1980. Hal ini terinspirasi oleh proses pembelajaran biologis nyata dari manusia atau jaringan syaraf. Kombinasi kompleks sel-sel dalam korteks visual hewan disebut bidang reseptif. Bidang ini memroses *subpictures* kecil dari gambar dan menggabungkannya untuk mengenali konteks. Dalam *deep learning* suatu daerah dalam gambar input yang ditutupi oleh *mask* adalah bidang reseptif untuk *neuron* di lapisan tersembunyi. *Mask* digeser oleh satu atau lebih piksel di seluruh gambar input. Sub-gambar memiliki fitur yang mirip dengan yang lain jika nilai outputnya dekat satu sama lain. Jumlah *mask* mewakili jumlah *neuron* di lapisan tersembunyi. Lapisan tersembunyi terstruktur secara hierarkis sebagai layer dalam ANN. Bobot masing-masing *mask* dapat disesuaikan untuk mencapai kinerja yang optimal. Proses ini disebut "*Feature learning*". *Feature learning* melakukan ekstraksi fitur otomatis sebelum fase klasifikasi [14]. *Feature learning* merupakan kemampuan penting dari algoritma *deep learning* yang dapat belajar untuk mengekstrak fitur dari data mentah tanpa bantuan manusia. Setelah *feature learning*, hal selajutnya yang dilakukan adalah proses klasifikasi. *Layer-layer* yang ada dalam CNN sendiri adalah:

1. *Feature Learning*

   Feature learning layer terdiri dari 2 layer yaitu:

   a. *Convolutional layer* bertugas menghitung output dari neuron dan menghasilkan weight dari besar filter yang digunakan. Dalam *layer* konvolusi, diterapkan fungsi aktivasi berupa *Rectified Linear Unit* (ReLU). ReLU bekerja untuk menghilangkan *vanishing gradient*.

   b. *Pooling layer* adalah *layer* yang berfungsi untuk melakukan proses pengurangan parameter yang biasa disebut *downsampling*. Proses ini akan mempercepat proses perhitungan karena parameter yang di*update* dan mengatasi *overfitting* karena pengurangan parameter.

2. *Classification*

   Layer ini berguna untuk mengklasifikasikan tiap neuron yang telah diekstraksi fitur pada bagian *feature learning*. *Layer* ini terdiri dari :

   a. *Flatten*

   Berguna untuk mengubah bentuk fitur menjadi sebuah vektor agar bisa kita gunakan sebagai input dari *fully-connected layer*

   b. *Fully-connected*

   Layer Fully-connected akan menghitung skor kelas. Seperti *neural network* biasa dan seperti namanya, setiap *neuron* dalam *layer* ini akan terhubung ke semua *hidden layer*. *Dalam layer fully connected* diterapkan fungsi aktivatsi yaitu *softmax*. Fungsi *Softmax* berguna untuk menghitung probabilitas dari setiap kelas dari semua kelas klasfikasi yang diinginkan. Output dari *softmax* adalah nilai probabilitas dari 0 hingga 1, dan jumlah

semua probabilitas dari setiap kelas yang digunakan adalah 1. Fungsi *softmax* bekerja dengan baik untuk klasifikasi multi kelas.

Gambar 2. 3. Arsitektur CNN (a) VGG-19, (b) ResNet-152 [15]

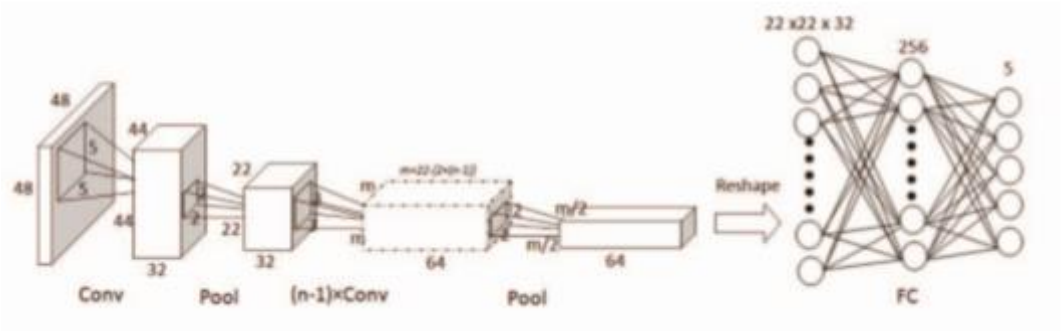

Gambar 2. 4. Arsitektur yang diajukan oleh Pasupa et al. tahun 2016 [14]

Selain *layer-layer*, terdapat beberapa parameter yang mengatur kerja dari CNN yang disebut dengan *hyperparameter*. *Hyperparameter* ini mengatur kerja proses *leraning* CNN dengan cara mengatur jumlah *epoch*, *batch size*, dll. *Epoch* adalah nilai yang dapat ditentukan, dimana satu *epoch* artinya seluruh data dalam *dataset* telah melewati 1 kali proses *training*. Kemudian *batch size* adalah jumlah data yang diproses dalam satu kali proses sebelum *weight* di update. Nilai iterasi didapatkan dengan membagi jumlah data *training* dengan nilai *batch size* yang digunakan.

CNN memiliki banyak jenis arsitektur, jenis-jenis arstektur ini dibedakan dari banyaknya jumlah *convolutional layer*, dan *fully connected* layer, besar filter, dan tambahan-tambahan layernya. Arsitektur-arsitektur yang banyak digunakan untuk *image classification* contohnya adalah VGG-19, ResNet, dll. Kedua arsitektur tersebut bagus untuk *image classification* karena dapat mengambil banyak parameter dan tingkat kedalaman jaringannya cukup dalam [15]. VGG-19 sendiri terdiri dari 19 *layer*. ResNet memiliki jumlah layer yang bervariasi, terdapat beberapa jenis model aristektur ResNet yang biasa digunakan, seperti ResNet50, atau ResNet152. Gambar 2.4(a) menunjukkan arsitektur dari VGG-19, dan Gambar 2.4(b) menunjukkan arsitektur dari ResNet-152.

Ketika *dataset* yang digunakan untuk proses *training* kecil, model CNN akan mudah mengalami *overfitting*. *Overfitting* terjadi karena parameter yang diambil terlalu banyak sehingga fitur yang didapatkan terlalu detail, sehingga model tidak dapat mengeneralisasi data. Ketidakmampuan model CNN untuk men-generalisasi data dapat menyebabkan model memiliki hasil klasifikasi yang bersifat *high variance*, dan *low bias*, sehingga hasil klasifikasinya akan memiliki akurasi yang rendah. Dalam penelitian yang dilakukan Pasupa, et al. pada tahun 2016 [14], penelitian ini mengajukan model dengan *layer* yang kecil dan tidak terlalu dalam untuk mengatasi masalah *dataset* yang kecil ini. Selain itu, penambahan penggunaan metode augmentasi data dan penambahan *regularization layer* menggunakan *drop out*, dapat meningkatkan akurasi model CNN. Arsitektur yang diajukan dalam penelitian ini dapat dilihat pada Gambar 2.4. Arsitektur ini

terdiri dari 3 sampai 5 *convolutional layer* dengan ukuran filter 32 dan 64, serta 1 *fully connected layer* dengan ukuran *dense* 256 [14].

2.7 Rasional

B-Mode ultrasound adalah modalitas pertama yang biasa digunakan untuk proses deteksi penyakit hati. Berdasarkan *European Association for the Study of Liver - European Organisation for Research and Treatment Cancer* (EASL-EORTC) menyatakan bahwa pasien yang memiliki risiko untuk mengalami perkembangan dalam penyakit HCC harus melakukan program pengawasan, dimana pengawasan dilakukan menggunakan *abdominal ultrasound* setiap 6 bulan [2]. Sedangkan untuk Kista dalam artikel dari Marianna G. Mavilia, *et al* (2018), dengan judul *Differentiating Cysic Liver Lesions: A Review of Imaging Modalities, Diagnosis and Management* menyatakan bahwa *ultrasound* merupakan modalitas pertama yang digunakan untuk mediagnosa kista, dengan akurasi sebesar 90% [4], dengan kelebihan dibanding modalitas lain yaitu murah, banyak tersedia dan juga tidak ada paparan radiasi. Kemudian untuk *Hepatic Hemangioma*, Bajenaru N, *et al* proses diagnosa dari *Hepatic Hemangioma* dapat dilakukan dengan *ultrasound conventional* dengan akurasi sebesar 96,9% [6]. Sehingga dapat dikatakan bahwa *ultrasound* merupakan modalitas pertama yang digunakan untuk mendiagnosa penyakit *focal liver*.

Tetapi *ultrasound* memiliki beberapa kekurangan seperti adanya *speckle noise* yang mengganggu kualitas citra sehingga bisa menyebabkan kesalahan klasifikasi dari penyakit. Dari penelitian yang dilakukan oleh Seepti Mittal, *et al* (2011) dengan judul *Neural Network based focal liver diagnosis using ultrasound* [9] mengatakan bahwa untuk meningkatkan efisiensi dari diagnosa, maka kualitas citra yang baik sangat dibutuhkan. Radiologis atau sonografer yang berpengalaman mencitrakan tekstur dari citra *ultrasound* untuk membedakan lesi karena *noise* merupakan bagian dari tekstur di dalam ultrasound. Sehingga untuk mendapatkan kualitas citra yang baik dibutuhkan metode *image enhancement* untuk meningkatkan kualitas citra dan mereduksi *noise* untuk memperjelas fitur. Dalam penelitiannya, Seepti Mittal, *et al* menggunakan *anisotropic diffusion scheme*. CLAHE merupakan salah satu metode yang dapat dilakukan untuk *image enhacement.* Hal ini diteliti oleh Smriti Sahu, *et al* (2012) yang membandingkan empat metode untuk *image enhancement* dimana salah satunya adalah CLAHE, dari ke empat metode tersebut CLAHE merupakan metode yang cukup baik untuk *image enhancement* karena memiliki nilai MSE yang kecil, dan PSNR yang tinggi dibandingkan dengan *Contrast stretching* dalam citra tumor ganas [3].

Bidang sistem klasifikasi otomatis untuk citra *ultrasound* hati telah banyak dikembangkan. Dalam penelitian yang dilakukan oleh Raghesh Krishnan K, *et al* (2015) dengan judul *Focal and diffused liver disease classification form ultrasound images based on isocontour segmentation* dengan menggunakan

metode SVM dan ANN sebagai classifier [3]. Pada penelitian ini menjelaskan bahwa klasifikasi dengan menggunaka metode SVM untuk fitur GLCM mengalami beberapa misklasifikasi, contohnya, antara kista dan HCC karena letak dan penampilan yang hampir sama, dan *Hepatocellular carcinoma* (HCC) dapat muncul sebagai lesi padat, *cystic* atau *mixed lesion* dalam citra *ultrasound* hati. Area nekrosis atau pendarahan di dalam tumor membuat penampilan *cyst*ic pada pencitraannya. HCC juga dapat menjadi *cystic* setelah *transarterial chemoembolization* atau *radio frequency ablation* [5]. Peneliti menyebutkan bahwa kesalahan klasifikasi ini dapat diatasi dengan metode untuk fitur ekstraksi atau teknik klasifikasi yang lebih baik. Sehingga dibutuhkan *classifier* yang lebih baik. Lalu terdapat beberapa kesamaan dari citra HCC dengan *Hepatic Hemangioma* dimana terkadang bersifat *hypoechoic* [9], terutama ketika hati berlemak (*fatty liver*), atau menunjukkan *echogenicity* campuran, sehingga terdapat kemungkinan untuk kesalahan pembacaan hasil citra *ultrasound* antara HCC dengan *hemangioma*, hal ini disebutkan dalam penelitian oleh Tae Kyoung Kim, *et al* (2015), dengan judul *Imaging findings of mimickers hepatocellular carcinoma* [10].

Model arsitektur CNN biasanya membutuhkan *dataset* dengan jumlah besar dan memiliki banyak variasi agar bisa didapatkan akurasi yang baik. Tetapi pada kenyataannya terkadang terdapat beberapa *dataset* yang digunakan memiliki jumlah data yang sedikit sehingga penggunaan arsitektur harus dibatasi agar data tidak mengalami *overfitting* karena model yang terlalu kompleks. Pada tahun 2016, Kitsuchart Pasupa, dan Wisuwat Sunhem melakukan penelitian dengan judul *A Comparison between Shallow and Deep Architecture Classifiers on Small Datatset* [14]. Dalam penelitian tersebut menjelaskan bahwa ketika *dataset* yang digunakan kecil, masalah yang akan muncul adalah *overfitting*. Pada penelitian ini, dilakukan perbaikan pada *deep architecture* dengan menambahkan teknik regularisasi dengan *overlap pooling*, *flipped image augmentation*, dan *dropout*. Dalam penelitian tersebut dihasilkan bahwa penggunaan *deep model augmented* yang ditambah dengan regularisasi dengan *dropout* dapat menyaingi teknik klasifikasi lain seperti SVM.

Dari penjabaran beberapa metode yang ada, maka pada penelitian tugas akhir ini, diusulkan sebuah sistem yang dapat mengklasifikasikan *focal liver diseases* (HCC, *Hepatic Hemangioma*, dan Kista) secara otomatis dengan metode CNN sebagai *classifier*. Untuk *image enhancement* dilakukan dengan menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) sebagai metode *pre-processing* untuk mereduksi *noise*. Penelitian ini diharapkan menjadi system dengan metode baru untuk proses klasifikasi *focal liver diseases*.

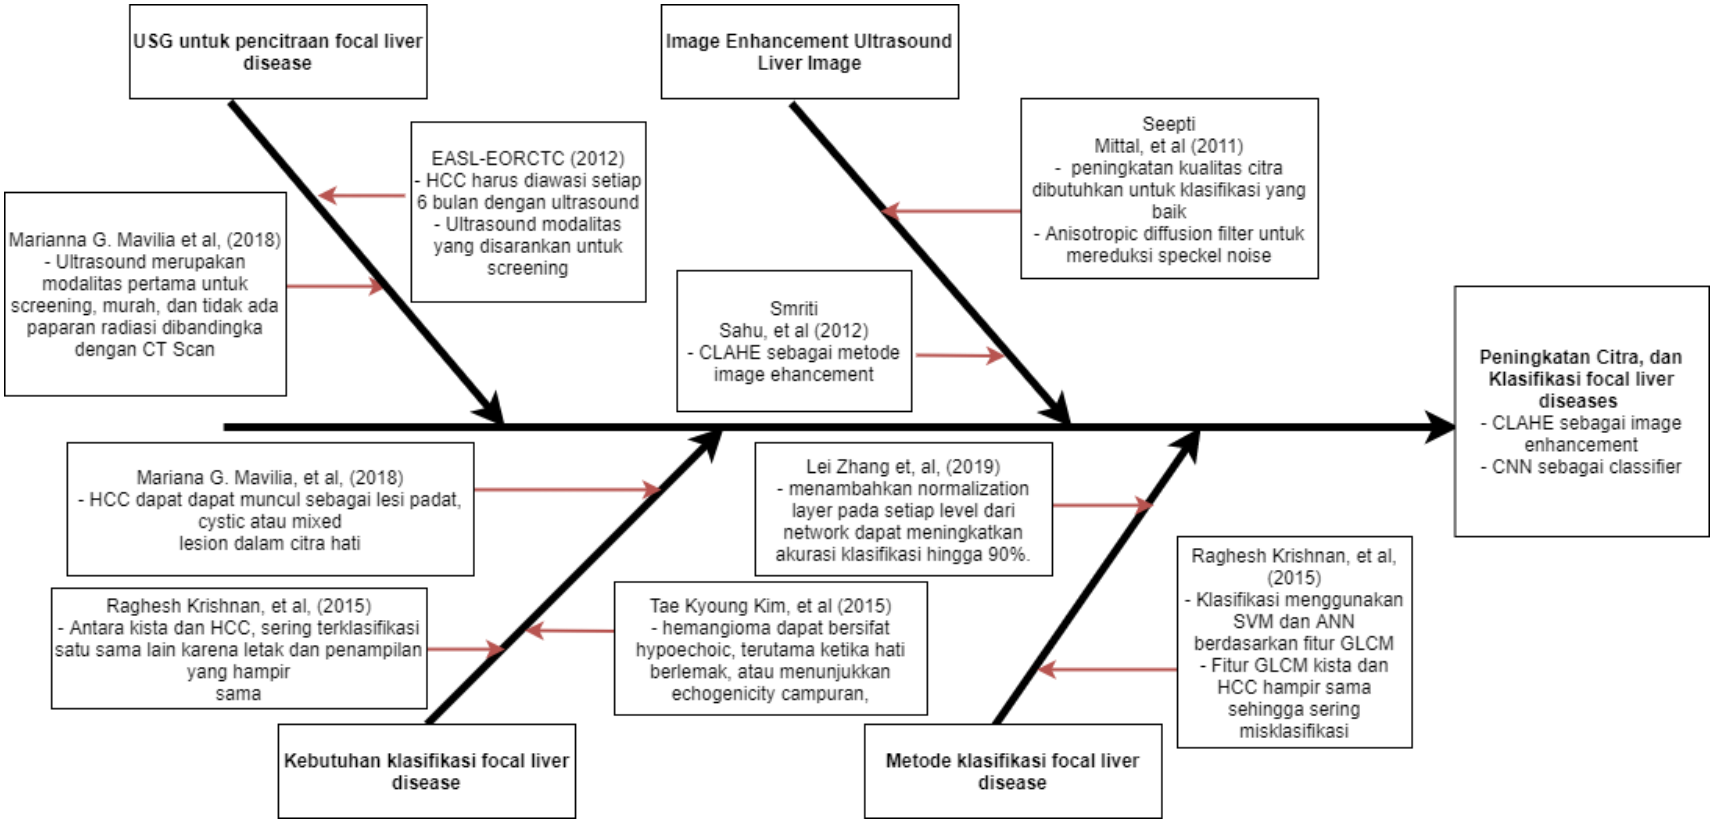

Gambar 2. 5 *Fishbone Diagram*

BAB III PERANCANGAN SISTEM

Kerangka kerja dari tugas akhir ini dapat dibagi menjadi empat bagian yaitu: (1) perancangan augmentasi data untuk mempersiapkan *dataset* untuk di *training* menggunakan CNN, (2) perancangan *image pre-processing* berupa pengurangan *noise* dengan menggunakan median filter, (3) peningkatan kontras menggunakan metode CLAHE, dan (4) peracangan arsitektur CNN untuk klasifikasi citra *ultrasound* 2D dari *liver* terutama untuk tiga *focal liver diseases* yaitu *hemangioma*, HCC, dan kista. Serangkaian kerangka kerja ini merupakan bagian dari bidang penelitian pengolahan citra medis yang berfokus pada pengolahan citra modalitas *B-Mode ultrasound* 2 dimensi klasifikasi penyakit secara otomatis. Bab ini menjelaskan kerangka kerja yang ada pada tugas akhir ini.

3.1. Desain Sistem Secara Umum

Secara umum, sistem kerja dari peningkatan citra medis *focal liver diseases* menggunakan CLAHE, dan klasifikasi *focal liver diseases* menggunakan *Convolutional Neural Network* adalah, pertama adalah penyiapan data citra *ultrasound* dari ketiga penyakit yang diklasifikasikan (*Hemangioma*, HCC, dan Kista) yang didapatkan dari UltrasoundCases.info [16]. Data yang didapatkan kemudian dibagi menjadi data *training* dan validasi, sedangkan data pengujian diambil dari data validasi. Data *training* diperbanyak menggunakan metode augmentasi data. Kemudian data-data tersebut masuk ke proses *pre-processing* dimana citra di*resize* sesuai dengan ukuran input CNN yang digunakan yaitu 350 × 450, kemudian citra dikonversi dari bentuk RGB menjadi *grayscale*. Citra tersebut kemudian direduksi *noise* nya menggunakan median filter, dan setelah itu ditingkatkan kontrasnya menggunakan CLAHE. Setelah data melewati *pre-processing*, maka data siap untuk di *training* menggunakan CNN untuk mendapatkan *threshold* dan *weight*. Arsitektur CNN yang digunakan mengacu pada penelitian Pasupa et al. [14]. Kemudian nilai ukuran filter dan jumlah *layer* disesuaikan hingga didapatkan model yang paling baik. Setelah proses *training* selesai maka dilakukan proses pengujian sistem untuk klasifikasi menggunakan *confusion matrix* dan akurasi, presisi, dan spesifisitas diukur untuk mengestimasi tingkat keberhasilan klasifikasi. Estimasi performansi klasifikasi ini dalam subbab 3.4. Diagram blok sistem secara keseluruhan dapat dilihat pada Gambar 3.1.

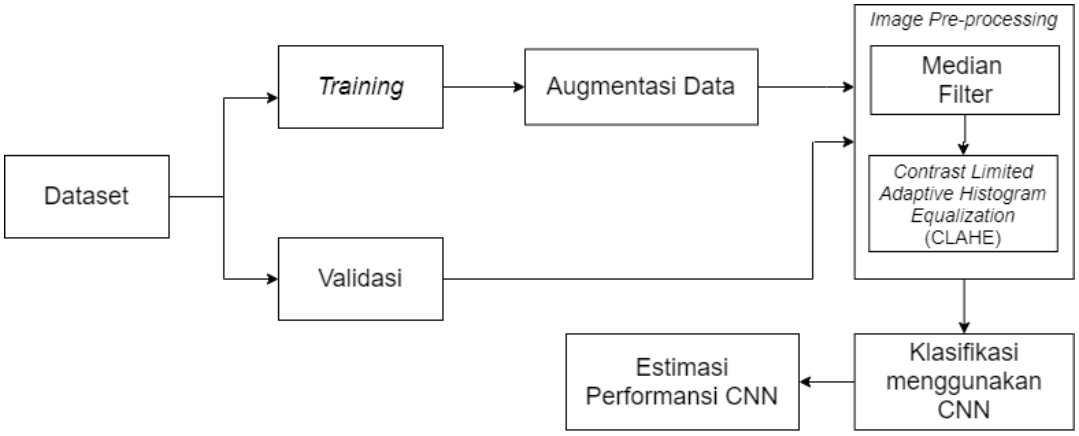

Gambar 3. 1. Diagram blok sistem secara keseluruhan

3.2. *Dataset*

Dataset yang digunakan dalam penelitian ini digunakan untuk melatih CNN dan menguji sistem. *Dataset* yang diguanakan didapatkan dari *database* citra *ultrasound* 2 dimensi HCC, *hemangioma*, dan kista. Semua citra *ultrasound* yang digunakan dalam tugas akhir ini didapatkan dari UltrasoundCases.info [16].

3.2.1. Keterangan *Dataset*

Situs UltrasoundCases.info ini memiliki banyak data *ultrasound* dari beberapa bagian organ tubuh seperti, *abdomen, gynaecology, head and neck*, dll. Fokus yang digunakan pada tugas akhir ini adalah pada data *ultrasound* pada bagian *abdomen and retroperitonemum* dan difokuskan lagi pada organ *liver*. Dalam data *ultrasound liver* tersebut terdapat banyak penyakit-penyakit *liver*, dan setiap penyakit memiliki beberapa kasus yang berbeda-beda. Dalam satu kasus merupakan data *ultrasound* dari satu orang, dan satu kasus biasanya memiliki beberapa data *ultrasound*.

Pada tugas akhir ini hanya digunakan 3 penyakit yaitu HCC, *hemangioma* dan kista. Penyakit HCC memiliki 11 kasus, *hemangioma* memiliki 28 kasus, dan kista memiliki 16 kasus. Setiap kasus memiliki jumlah data yang berbeda-beda dan terdapat beberapa data *ultrasound* bagian lain seperti ginjal yang ikut masuk dalam kasus tersebut, sehingga dilakukan pemilihan secara manual sehingga hanya didapatkan citra *ultrasound focal liver diseases* yang digunakan saja.

3.2.2. Penyiapan *Dataset*

Data yang didapatkan untuk penyakit HCC adalah 49 data, penyakit *hemangioma* sebanyak 63 data, dan penyakit kista sebanyak 60 data, sehingga total data gambar dalam *dataset* yang didapatkan yaitu 172 data. *Dataset* tersebut kemudian dibagi menjadi 2 bagian, yaitu untuk *training*, dan validasi dengan data *training* sebanyak 139 data, dan validasi sebanyak 33 data. Sebelum data *training* dibagi, dilakukan proses augmentasi data untuk memperbanyak jumlah data

training, kemudian ditambahkan dengan data asli sebelum diaugmentasi, hal ini dijelaskan pada subbab 3.3.1.

3.3. Pemrosesan Data

Pemrosesan data secara garis besar dapat dibagi menjadi 3, yaitu augmentasi data, *image pre-processing*, perancangan CNN. Pemrosesan data dilakukan secara bertahap, dimana proses augmentasi data dilakukan, kemudian data tersebut digunakan sebagai input untuk tahap *pre-processing*. Terkahir hasil *pre-processing* digunakan untuk input *learning* menggunakan CNN.

3.3.1. Augmentasi Data

Sebelum data masuk ke tahap *image pre-processing*, data diperbanyak terlebih dahulu menggunakan augmentasi data. Augmentasi data bertujuan untuk memperbanyak jumlah data karena CNN membutuhkan jumlah data yang banyak untuk proses *training*. Augmentasi data ini juga dilakukan untuk memperbanyak variasi gambar sehingga pada saat proses *learning* bisa didapatkan parameter-parameter yang lebih banyak. Proses augmentasi data ini hanya dilakukan pada data *training*, karena untuk data validasi diinginkan data yang se-mirip mungkin dengan keadaan aslinya. Terdapat 5 jenis augmentasi data yang dilakukan yaitu, secara geometris berupa pergeseran pada lebar (*width shift*) sebesar 0.1, pergeseran pada tinggi (*height* shift) dengan *range* 0.1, di *flip* secara horizontal, dan penambahan *noise* menggunakan *noise salt and pepper* sebesar persebaran sebanyak 0.05, dan *Gaussian noise* dengan standar deviasi 0.01. Jenis augmentasi data ini dipilih karena pada penggunaan pada *medical image* [17], teknik-teknik ini dapat memberikan *high mutual information* pada hasil augmentasinya.

3.3.2. *Image Pre-processimg*

Terdapat beberapa tahap yang dilakukan dalam *pre-processing* untuk mereduksi *noise* dan meningkatkan kualitas kontras citra. Pertama, proses *resize* citra dilakukan untuk mengubah ukuran citra atau data menjadi ukuran yang sama, semua data citra yang digunakan di-*resize* menjadi 350 × 450. Kedua, dilakukan proses konversi citra RGB menjadi *grayscale* karena semua proses dalam program ini dilakukan dengan gambar *grayscale* sehingga proses ini dilakukan agar semua data memiliki dimensi yang sama, dan agar dapat difiliter menggunakan median filter dan ditingkatkan kontrasnya menggunakan CLAHE. Ukuran kernel median filter yang digunakan adalah 3 × 3, 5 × 5, dan 7 × 7. Setelah difilter, nilai PSNR sebelum dan sesudah difilter dihitung. Ukuran kernel yang memilki PSNR paling tinggi kemudian yang digunakan untuk tahap *pre-process* selanjutnya. Tahap keempat adalah proses *image enhancement* dengan menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Nilai *clip limit* yang digunakan untuk proses CLAHE ada 3 yaitu 0.01, 0.02, dan 0.03. Hasil

1	Id	Genre	Cyst	Hemangioma	HCC
2	hh_0.jpg	['Hemangioma']	0	1	0
3	hh_2.jpg	['Hemangioma']	0	1	0
4	hh_4.jpg	['Hemangioma']	0	1	0
5	hh_1.jpg	['Hemangioma']	0	1	0
6	hh_3.jpg	['Hemangioma']	0	1	0
7	hh_11.jpg	['Hemangioma']	0	1	0
8	hh_5.jpg	['Hemangioma']	0	1	0
9	hh_6.jpg	['Hemangioma']	0	1	0
10	hh_10.jpg	['Hemangioma']	0	1	0
11	hh_9.jpg	['Hemangioma']	0	1	0
12	hh_8.jpg	['Hemangioma']	0	1	0
13	hh_12.jpg	['Hemangioma']	0	1	0
14	hh_7.jpg	['Hemangioma']	0	1	0
15	hcc_0.jpg	['HCC']	0	0	1
16	hcc_1.jpg	['HCC']	0	0	1
17	hcc_2.jpg	['HCC']	0	0	1

Gambar 3. 2. Hasil *labeling* untuk masing-masing penyakit yang disimpan dalam *file* .csv

peningkatan kontras dengan CLAHE ini digunakan untuk memperjelas atau meningkatkan kontras agar tepi dari lesi lebih terlihat, dan memperjelas *echogenity* lesi, kemudian hasil *pre-process* tersebut digunakan sebagai *input* untuk proses *training*, dan dilihat pengaruh serta estimasi performansinya terhadap hasil klasifikasi menggunakan CNN.

3.3.3. Perancangan CNN

Dataset yang digunakan telah dijelaskan pada subbab 3.2.2, dan subbab 3.3.1. Data *training* yang didapatkan berjumlah 139 data dan validasi sebesar 33 data. Data *training* kemudian di augmentasi menggunakan metode yang telah dijelaskan pada subbab 3.3.1. Hasil data *training* yang telah diaugmentasi ditambahkan dengan data aslinya, sehingga didapatkan data *training* sebesar 1112. Data tersebut kemudian diberi label sesuai dengan penyakitnya yaitu untuk penyakit kista memiliki label [1, 0, 0], untuk *Hemangioma* memiliki label [0, 1, 0], dan untuk penyakit HCC memiliki label [0, 0, 1]. Gambar 3.2 menunjukkan contoh hasil *labeling* yang dilakukan. Proses pelabelan digunakan untuk memberi tanda dan memisahkan desired output pada tiap kelas. Data *labeling* kemudian di simpan dalam bentuk .csv, dan di *load* bersama dengan data *training*, dan mulai dilakukan proses *training* CNN.

Secara umum, *flowchart learning* CNN yang diajukan dijelaskan dalam Gambar 3.2. Rancangan arsitektur yang digunakan mengacu pada penelitian sebelumnya [14] dimana arsitektur yang digunakan dapat dilihat pada Gambar 2.4. Arsitektur tersebut terdiri dari 3 *convolutional layer* dengan 1 *convolutional layer* memiliki besar filter 32 dan 2 *layer* lainnya menggunakan filter sebesar 64.

Kemudian pada *layer fully connected* digunakan *dense* dengan besar 256 dan pada masing-masing layer *fully connected* ditambah dengan Drop Out.

Arsitektur tersebut kemudian dimodifikasi menyesuaikan dengan hasil program, serta jumlah data yang digunakan untuk *training* agar bisa didapatkan akurasi paling tinggi. Perbedaan dari arsitektur pada penelitian sebelumnya adalah perubahan nilai *filter size*, dan nilai *kernel* dari filter. *Dropout* berfungsi untuk mengurangi jumlah *neuron* pada model sehingga diharapkan dapat mengurangi *overfitiing*. Selain itu ditambahkan *layer* regularisasi berupa *Gaussian noise layer* yang juga berguna untuk mengurangi *overfitting*, dan meningkatkan *robustness* dari model. *Gaussian noise layer* diterapkan pada masing-masing *hidden layer*. *Gaussian layer* menambahkan parameter atau fitur dari model dimana fitur tersebut merupakan fitur yang telah ditambahkan dengan *noise*. Penambahan *noise* ini memperkaya variasi hasil fitur, dan juga meningkatkan *robustness* model karena fitur yang digunakan memiliki *noise*. *Layer* output diatur menggunakan *softmax*, karena pada program klasifikasi multi kelas hanya ada 1 nilai probabilitas untuk masing-masing kelas dan total probabilitas semua kelas adalah 1, dan *loss* atau penghitunan *error* dalam porses validasi atau biasa disebut *cross validation* yang digunakan adalah *categorical cross entropy*. *Categorical cross entropy* digunakan karena jenis klasifikasi ini merupakan klasifikasi multi kelas. Tabel 3.1 menunjukkan *layer-layer* model arsitektur yang diajukan.

Tabel 3. 1. Arsitektur CNN yang diajukan

Layer (type)	**Feature Maps**	**Filter size**
Conv2D	348 × 448 × 8	3 × 3
Max pooling	174 × 224 × 8	2 × 2
Gaussian Noise	174 × 224 × 8	0.1
Dropout	174 × 224 × 8	0.5
Conv2D	172 × 222 × 8	3 × 3
Max pooling	86 × 111 × 8	2 × 2
Gaussian Noise	86 × 111 × 8	0.1
Dropout	86 × 111 × 8	0.5
Conv2D	84 × 109 × 8	3 × 3
Max pooling	42 × 54 × 8	2 × 2
Gaussian Noise	42 × 54 × 8	0.1
Dropout	42 × 54 × 8	0.5
Flatten	18144	-
Dense	8	8
Gaussian Noise	8	0.1
Dropout	16	0.5
Output (softmax)	3	-

Selain mengatur *layer* pada arsitektur atau model, parameter lain yang diatur untuk mendapatkan hasil klasifikasi paling baik adalah *hyperparameter*. *Hyperparameter* yang digunakan adalah *optimizer* Adam, dan nilai *epoch* maksimal yang digunakan sebesar 100, setelah proses *training*, hasil grafik akurasi, dan *loss* dianalisa untuk mendapatkan nilai *epoch* yang paling baik. Nilai *epoch* yang paling baik adalah ketika grafik hasil *training* tidak mengalami *overfitting* dan akurasi yang didapatkan sudah cukup baik.

3.4. Estimasi Performasi Sistem

Estimasi performasi sistem untuk proses *filtering* dengan median filter dilakukan dengan menghitung *Peak Signal to Noise Ratio* (PSNR). *Peak Signal-to-Noise Ratio* (PSNR) adalah perbandingan antara nilai maksimum dari sinyal yang diukur dengan besarnya *noise* yang berpengaruh pada sinyal tersebut. PSNR biasanya diukur dalam satuan desibel (dB), dimana persamaannya didefisinikan dalam Persamaan 3.1, dan persamaan MSE didefinisikan dalam Persamaan 3.2.

$$PSNR = 10\log_{10}\left(\frac{C^2max}{MSE}\right) \tag{3.1}$$

$$MSE = \frac{1}{MN}\sum_{x=1}^{M}\sum_{y=1}^{N}(S_{xy} - C_{xy})^2 \tag{3.2}$$

Variabel x dan y adalah koordinat dari citra, M dan N adalah dimensi dari citra, S_{xy} menyatakan citra sebelum di filter dan C_{xy} menyatakan citra setelah di filter. C^2max adalah nilai maksimum dalam citra yaitu nilai maksimum dari nilai piksel. Ukuran *window* atau *kernel* median filter yang memiliki PSNR paling tinggi digunakan.

Estimasi performansi yang digunakan untuk mengukur ke efektifan *image enhancement* menggunakan CLAHE adalah dengan cara perbandingan antara hasil klasifikasi dari citra yang telah melalui proses *image enchancement* dengan nilai *clip limit* limit yang berbeda-beda, dan dengan citra yang tidak melewati proses *image enhancement*. Hal ini dilakukan untuk melihat pengaruh dari *image enhancement* menggunakan CLAHE beserta *clip limit* yang paling berpengaruh pada setiap penyakit dalam proses klasifikasi.

Kemudian untuk mengukur estimasi performansi dari CNN untuk klasifikasi *focal liver diseases* dilakukan dengan membuat *confusion matrix* untuk klasifikasi *multi-class*, Matriks tersebut dapat dilihat pada Tabel 3.2. *Confusion matrix* berguna untuk menunjukkan jumlah data yang terklasifikasikan pada setiap penyakitnya. Data dalam *confusion matrix* ini kemudian digunakan untuk mengukur akurasi, presisi, dan spesfisitas. Perhitungan akurasi dilakukan dengan Persamaan 3.3. Selain akurasi, dihitung juga nilai presisi, dan spesifisitas untuk

masing-masing hasil klasifikasi penyakit, Persamaan 3.4 menunjukkan persamaan untuks presisi (*precision)*, dan Persamaan 3.5 untuk spesifisitas (*specificity*).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\ \% \tag{3.3}$$

$$Precision = \frac{TP}{TP + FP} \tag{3.4}$$

$$Spesificity = \frac{TN}{TN\ + FP} \tag{3.5}$$

TP adalah nilai di diagonal utama atau *True Positive* pada masing-masing penyakit, merupakan data yang terklasifikasikan dengan benar sesuai penyakitnya. FN atau *False Negative* untuk setiap kelas adalah jumlah dari semua nilai dalam baris kelas tersebut, dan TP tidak termasuk. FP atau *False Positive* untuk setiap kelas adalah jumlah dari semua nilai dalam kolom yang sesuai dengan kolom kelas tersebut, dan nilai TP tidak termasuk. TN atau *True Negative* untuk setiap kelas adalah jumlah dari semua nilai dari *Confusion matrix* yang tidak termasuk baris dan kolom kelas tersebut.

Tabel 3. 2. *Confusion matrix* untuk multi kelas

	Class A	***Class B***	***Class C***
Class A	TP_A	E_{AB}	E_{AC}
Class B	E_{BA}	TP_B	E_{BC}
Class C	E_{CA}	E_{CB}	TP_C

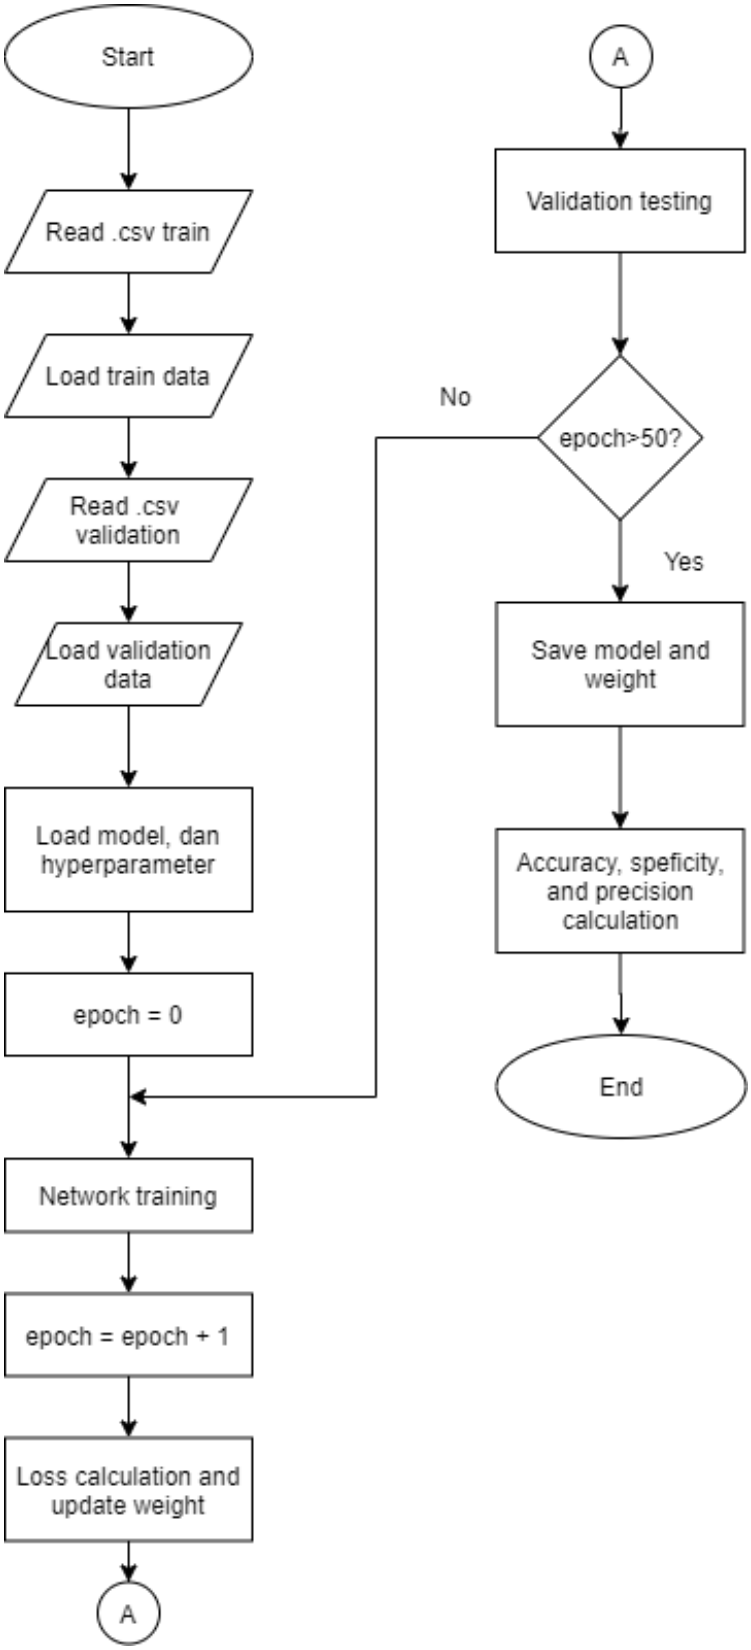

Gambar 3. 3. *Flowchart learning* CNN

BAB IV PENGUJIAN SISTEM

4.1. Augmentasi Data

Augmentasi data yang dilakukan untuk memperbanyak jumlah data citra untuk masing-masing penyakit, karena proses *training* atau pembelajaran dengan menggunakan CNN membutuhkan banyak data. Selain itu, augmentasi data juga digunakan untuk memperkaya variasi dari *dataset* karena data yang digunakan memiliki banyak kemiripan. Kemiripan ini ada karena beberapa data yang didapatkan merupakan data dari satu subjek yang sama, sehingga varisinya kurang. Augmentasi data biasanya digunakan untuk mengurangi *overfitting* pada model CNN.

Terdapat lima jenis augmentasi data yang di lakukan dengan rincian, tiga augmentasi secara geometris berupa pergeseran pada lebar (*width shift*) dengan *range* 0.1, pergeseran pada tinggi (*height shift*) dengan *range* 0.1, *flip* atau dibalik secara horizontal. Kemudian, dua augmentasi lain dilakukan dengan cara penambahan *noise* berupa *noise salt and pepper* dengan persebaran sebesar 0.05, dan *Gaussian noise* dengan standar deviasi sebesar 0.01. Augmentasi data berupa penambahan *noise* dilakukan menggunkan bantuan *library* yang disediakan oleh program *python*, yaitu *library scikit-image*. Kemudian, augmentasi data secara geomteris dilakukan dengan memanfaatkan *library* yang disediakan oleh *tensorflow* berupa *ImageGenerator*.

Augmentasi dilakukan untuk hanya untuk data *training*. Data validasi dan pengujian tidak diaugmentasi agar hasil validasi atau pengujian dapat merepresentasikan data pada keadaan nyata atau aslinya. Total data sebelum diaugmentasi adalah 139 data dengan rincian data per masing-masing penyakit telah dijelaskan pada subbab 3.2.2. Setelah di augmentasi total data yang didapatkan menjadi 1112 data, dengan rincian data hasil augmentasi tersebut adalah, penambahan *noise salt and pepper* menambahkan 139 data augmentasi, augmentasi *nosie* berupa *Gaussian noise* menambahkan 139 data augmentasi, dan augmentasi secara geomteris berupa *height shift*, *width shift*, dan *flip* secara horizontal menmbah data sebanyak 695 data, sehingga data hasil augmentasi yang didapatkan adalah 973 data. Data tersebut kemudian ditambahkan dengan data asli sebanyak 139 data sehingga total dalam satu *dataset* untuk *training* adalah 1112 data.

Gambar 4.1. menunjukkan hasil proses augmentasi, dimana Gambar 4.1 (a) adalah *height shift* sebesar 0.1, Gambar 4.1(b) adalah *width shift* dengan *range* 0.1, Gambar 4.2 adalah hasil horizontal *flip*. Hasil augmentasi data dengan penambahan *noise* dapat dilihat pada Gambar 4.3(a) yang merupakan hasil augmentasi data yang ditambahkan dengan *Gaussian noise* dengan standar deviasi sebesar 0.01, dan Gambar 4.3(b) adalah hasil penambahan *noise salt and pepper*

dengan persebaran 0.05. Hasil augmentasi data ini kemudia di *pre-process* menggunakan metode median filter, dan CLAHE.

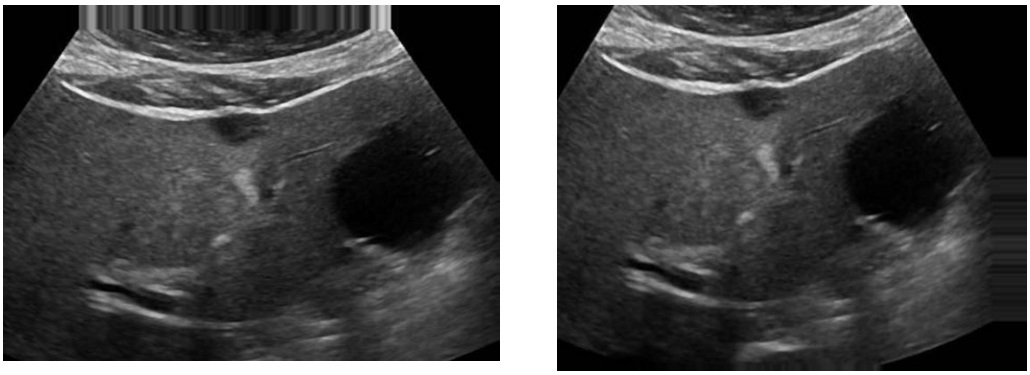

(a) (b)

Gambar 4. 1. Hasil augmentasi data geometris (a) *width shift*, (b) *height shift*

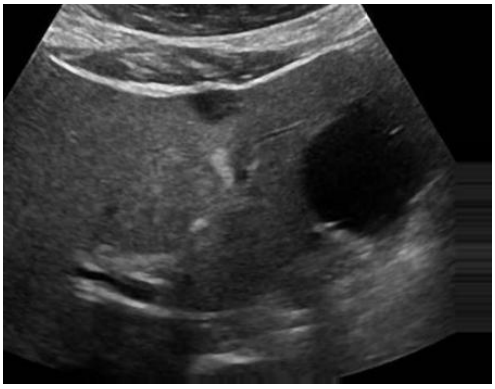

Gambar 4. 2. Hasil augmentasi data horizontal *flip*

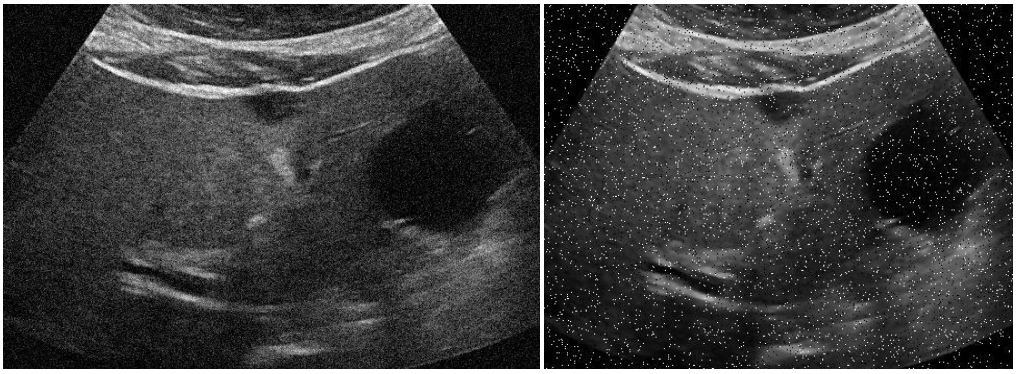

(a) (b)

Gambar 4. 3. Hasil augmentasi data *noise* (a) *Gaussian Noise*, (b) *Salt and pepper noise*

4.2. *Image Pre-processing*

Terdapat beberapa tahap *pre-processing* yang dilakukan, yaitu mengubah citra menjadi *grayscale*, dan dilakukan proses *resize* agar semua ukuran citra menjadi ukuran 350 × 450. Kemudian *pre-processing* dilanjutkan dengan menerapkan proses *filtering* untuk mengurangi *noise* menggunakan median filter, dan peningkatan kontras citra menggunakan *Clip Limited Adaptive Histogram Equalization* (CLAHE). Tahap *image pre-processing* ini dilakukan dengan menggunakan *library* yang disediakan oleh Python yaitu OpenCV, dan *scikit-image.*

4.2.1. Median Filter

Median filter digunakan untuk mereduksi *noise*. Median filter dilakukan pada program *python* menggunakan *library* OpenCV. Gambar 4.4 menunjukkan data sebelum diproses menggunakan median filter. Gambar 4.5 menunjukkan hasil filter dengan menggunakan ukuran *window* 3 × 3, sedangkan Gambar 4.5 merupakan hasil filter median filter dengan ukuran *window* sebesar 5 × 5, Gambar 4.6 adalah hasil filter menggunakan *window* 7 × 7. Dari hasil median filter, dapat terlihat bahwa median filter memberi efek *blurring* pada citranya. Semakin besar *window* atau *kernel* yang digunakan, maka efek *blurring* yang dihasilkan semakin besar. Masing-masing hasil filter kemudian dihitung nilai *Peak Signal-to-Noise Ratio* (PSNR) yang merepresentasikan perbadingan atau rasio antara *noise* dengan sinyal yang terdapat pada citra. Perhitungan PSNR dilakukan menggunakan Persamaan (2.2).

Hasil yang didapatkan adalah, filter dengan *window* 3 × 3 memiliki PSNR tertinggi yaitu dengan nilai 34.929 dB, sedangkan untuk filter dengan *window* 5 × 5 memiliki nilai PSNR sebesar 30.566 dB, dan filter dengan *window* 7 × 7 memiliki PSNR sebesar 20.882 dB. Karena filter dengan *window* 3×3 memiliki nilai PSNR paling tinggi, maka hasil data dengan fitler tersebut digunakan untuk di proses menggunakan CLAHE untuk tahap peningkatan kontras.

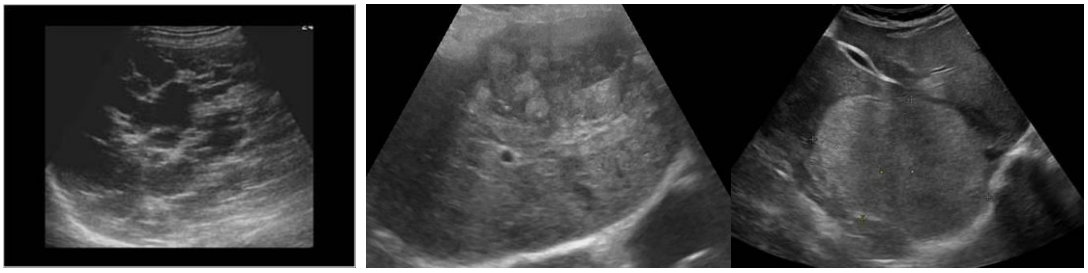

(a) (b) (c)

Gambar 4. 4. Gambar sebelum dilakukan *pre-processing* (a) Kista, (b) HCC, (c) *hemangioma*

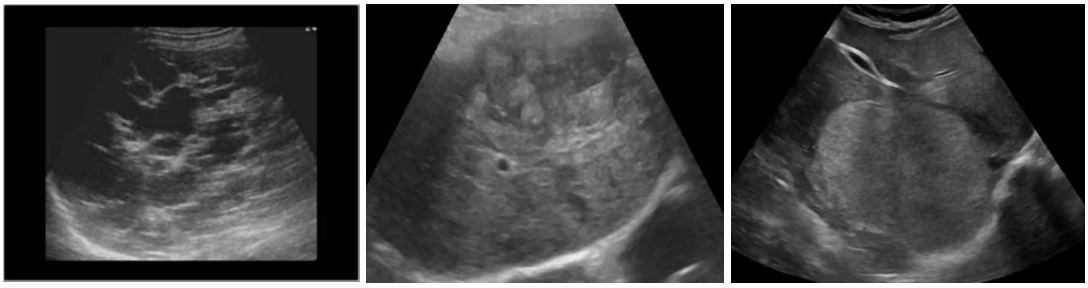

(a) (b) (c)

Gambar 4. 5. Hasil median filter dengan *window* 3 × 3 (a) Kista, (b) HCC, (c) *Hemangioma*

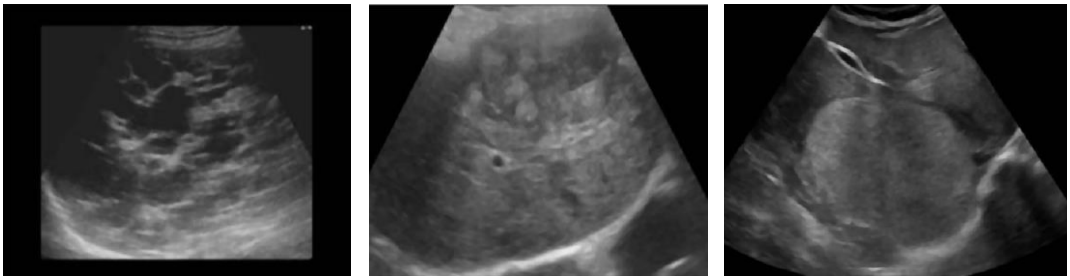

(a) (b) (c)

Gambar 4. 6, Hasil median filter dengan *window* 5 × 5 (a) Kista, (b) HCC, (c) *Hemangioma*

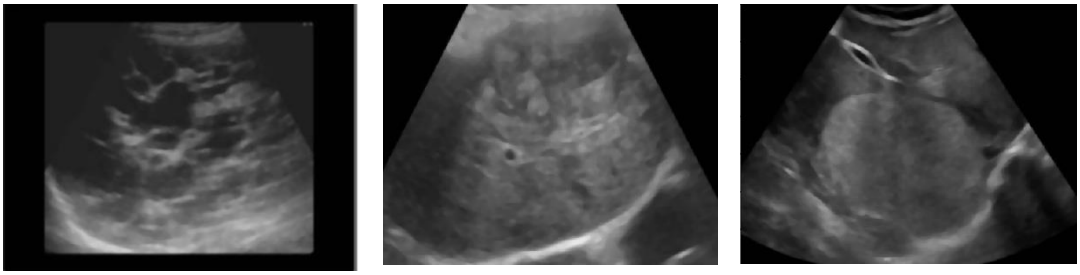

(a) (b) (c)

Gambar 4. 7. Hasil median filter dengan *window* 7 × 7 (a) Kista, (b) HCC, (c) *Hemangioma*

4.2.2. *Contrast Limited Adaptive Histogram Equalization* (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) digunakan untuk peningkatan kualitas kontras untuk memperjelas tepi dan mempertajam kontras antara lesi dengan jaringan di sekitarnya. Program untuk proses CLAHE ini dilakukan menggunakan *library* yang disediakan python yaitu *scikit-image*.

Clip limit yang digunakan dalam tugas akhir ini sebesar 0.01, 0.02, dan 0.03. Gambar 4.4 menunjukkan data yang telah diproses menggunakan median filter dengan *window* 3 × 3. Data tersebut kemudian proses menggunakan CLAHE dan didapatkan hasil yang dapat dilihat pada Gambar 4.8, Gambar 4.9, dan Gambar 4.10 yang beruturt-turut menujukkan hasil peningkatan kontras pada citra untuk masing-masing penyakit HCC, *hemangioma*, dan kista dengan 3 *clip limit* yang berbeda. Hasil atau pengaruh dari proses peningkatan kontras menggunakan CLAHE ini kemudian dilihat dan dianalisa dari hasil histogramnya.

Pada grafik histogramnya, terlihat terjadinya perubahan nilai intensitas piksel dalam histogram sebelum dan setelah dilakukan proses *equalization*. Terlihat terjadinya pemotongan intensitas nilai piksel tinggi pada histogramnya, semakin tinggi nilai *clip limit* yang digunakan, semakin banyak pula nilai piksel tinggi yang terpotong. Contohnya, pada Gambar 4.11 menunjukkan histogram sebelum dilakukan proses *equalization* menggunakan CLAHE. Gambar 4.12, Gambar 4.13, dan Gambar 4.14 berturut-turut menunjukkan hasil grafik histogram dari masing-masing penyakit HCC, *hemangioma*, dan kista, dengan menggunakan 3 *clip limit* yang berbeda yaitu 0.01, 0.02, dan 0.03.

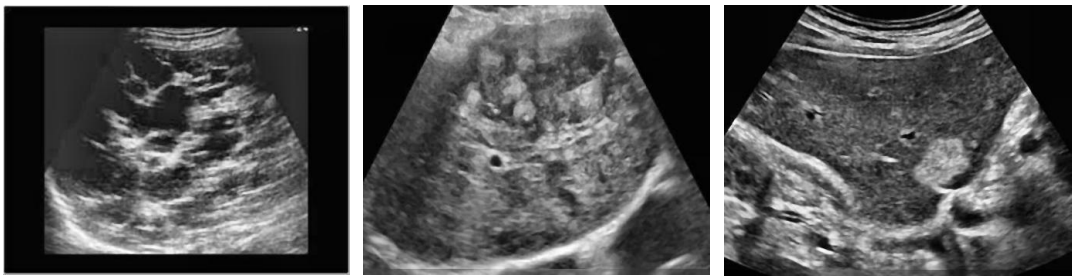

(a) (b) (c)

Gambar 4. 8. Gambar penyakit kista setelah diproses dengan CLAHE dengan *clip limit* (a) 0.01, (b) 0.02, (c) 0.03

(a) (b) (c)

Gambar 4. 9 Gambar penyakit HCC setelah diproses CLAHE dengan *clip limit* (a) 0.01, (b) 0.02, (c) 0.03

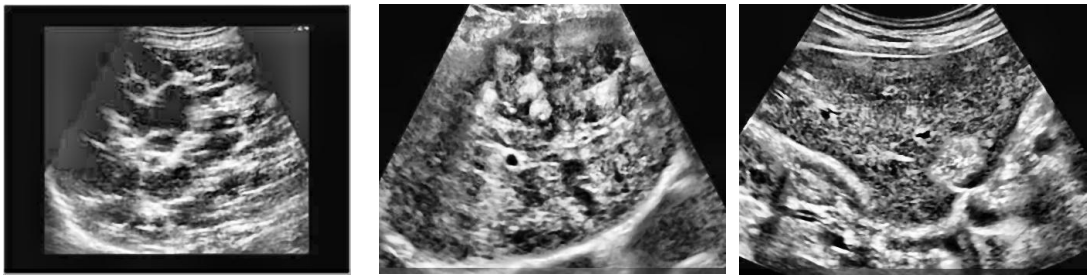

(a) (b) (c)

Gambar 4. 10. Gambar penyakit Hemangima setelah diproses CLAHE dengan *clip limit* (a) 0.01, (b) 0.02, (c) 0.03

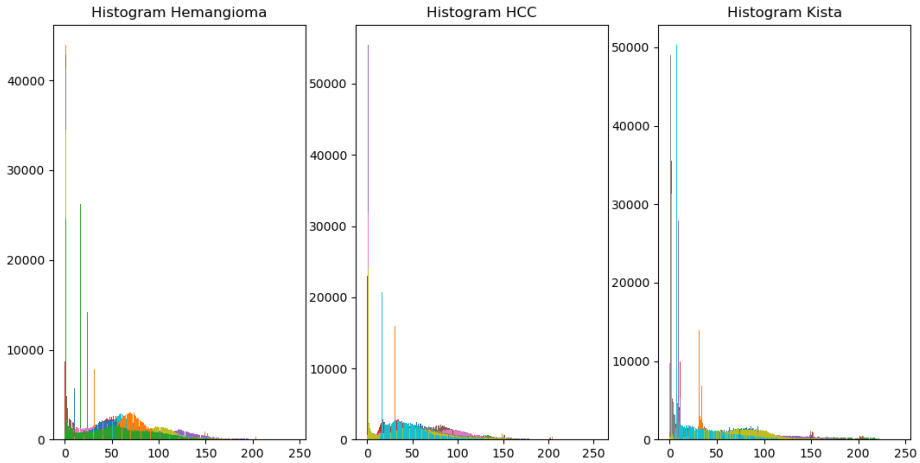

Gambar 4. 11. Histogram sebelum diproses menggunakan CLAHE

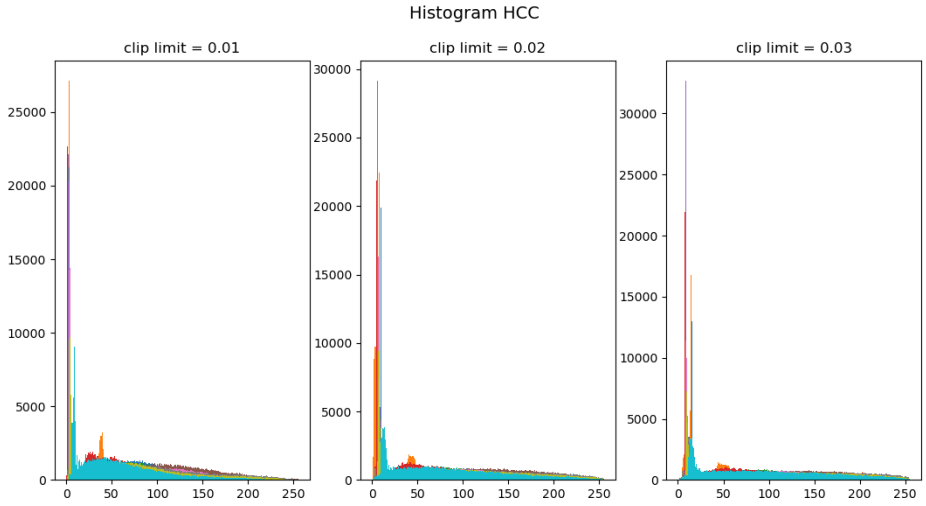

Gambar 4. 12. Histogram gambar HCC setelah diproses dengan CLAHE, dengan *clip limit* 0.01, 0.02, 0.03

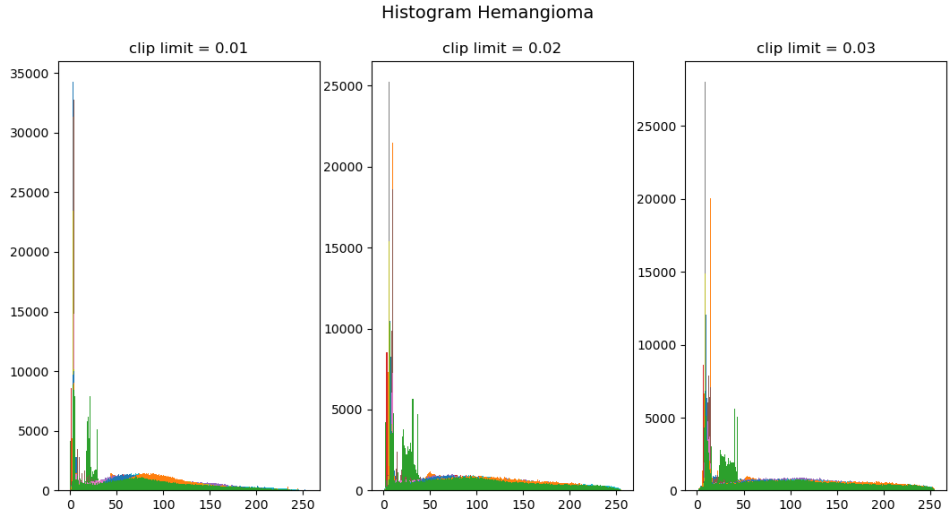

Gambar 4. 13. Histogram gambar *Hemangioma* setelah diproses dengan CLAHE, dengan *clip limit* 0.01, 0.02, 0.03

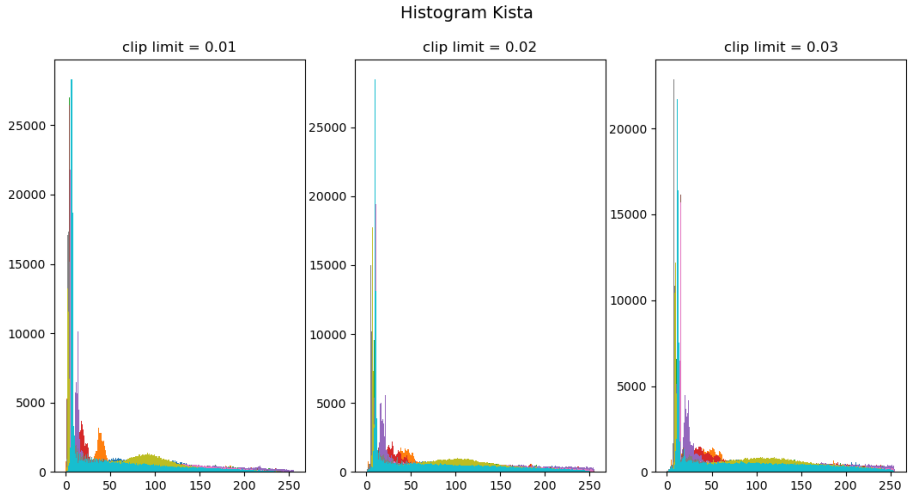

Gambar 4. 14. Histogram gambar Kista setelah diproses dengan CLAHE, dengan *clip limit* 0.01, 0.02, 0.03

4.3. CNN Untuk Klasifikasi *Focal Liver Diseases*

Semua program CNN yang digunakan pada tugas akhir ini dikerjakan menggunakan program *Google Colaboratory*, dan memanfaatkan *library* tensorflow. Program *Google Colaboratory* dipilih untuk mempercepat proses komputasi karena dalam program tersebut menyediakan GPU dan RAM yang besar.

Proses pengujian untuk CNN dilakukan secara bertahap. Proses ini dilakukan secara bertahap karena terdapat beberapa parameter yang harus ditentukan, dan dianalisa hingga didapatkan parameter yang paling baik, dan dapat menghasilkan model CNN yang paling baik. Secara umum, parameter-parameter tersebut adalah, jumlah data, dan nilai *epoch*. Kedua variabel atau parameter ini dapat mempengaruhi kinerja dari model. Model CNN yang diharapkan, adalah model yang memiliki akurasi baik, dan *overfitting* yang terjadi tidak terlalu parah.

Cara paling umum yang digunakan untuk mengurangi *overfitting* adalah dengan proses penambahan data dengan cara augmentasi data. Augmentasi data yang dilakukan pada tugas akhir ini telah dijelaskan pada subbab 4.1. Pegujian pertama, dilakukan untuk melihat pengaruh augmentasi data pada proses *training* CNN. Karena pada umumnya, proses *learning* menggunakan metode CNN membutuhkan data yang cukup banyak. Tetapi, pada tugas akhir ini, data untuk proses *learning* atau *training* hanya sejumlah 139 data dengan rata-rata data per kelas sebanyak 50 data, sehingga secara teori, data ini terlalu kecil. Penggunaan data yang terlalu kecil dapat menyebabkan *overfitting*. Sehingga untuk

mengurangi *overfitting* tersebut, data diperbanyak menggunakan augmentasi data seperti yang telah dijelaskan pada subbab 4.1.

Hasil proses *training* dengan dua kondisi data yang berbeda yang didapatkan adalah:

1. Data yang tidak diaugmentasi

   Pada data yang tidak diaugmentasi ini, *dataset* yang digunakan untuk proses *training* adalah sebanyak 139 data, dan data validasi sebanyak 33 data. Grafik *training* menunjukkan bahwa penggunaan data yang tidak diaugmentasi ini menyebabkan hasil CNN menjadi *overfitting* yang cukup besar. Pada Gambar 4.15 terlihat jarak antara akurasi *training* dan validasi memiliki *gap* yang cukup besar hingga mencapai sekitar 20%, grafik akurasi *training* menunjukkan nilai akurasi yang lebih tinggi dibandingkan dengan akurasi validasi, hal ini merupakan indikasi *overfitting*. Selain itu, dilihat dari grafik *loss* nya (Gambar 4.16), terlihat juga jarak antara dan *loss training* dan validasi menunjukkan jarak yang cukup besar. Garfik *loss* sendiri menunjukkan *error* hasil *training*, dan validasi, sehingga semakin tinggi *error* validasi, dan semakin rendah error *training*, maka model tersebut mengalami *overfitting*.

2. Data yang di Augmentasi

   Data yang digunakan diambil dari hasil augmentasi *dataset* yang sudah dijelaskan pada subbab 3.2.2 dengan data total sebanyak setelah proses augmentasi data dari 139 menjadi data *training* total 1112, dan data validasi sebesar 33 data. Data validasi sengaja tidak diaugmentasi karena ingin didapatkan hasil validasi klasifikasi yang semirip mungkin dengan data asli. Gambar 4.17 menunjukkan hasil grafik akurasi, dan Gambar 4.18 menunjukkan grafik *loss* dari proses *training*, dan validasi. Dari hasil yang didapatkan, terlihat jelas bahwa terjadinya penurunan jarak antara grafik *training*, dan validasi, baik pada grafik akurasi, dan *loss*. Pada grafik akurasinya, terlihat jarak antara *train* dan validasi sangat kecil, hanya sekitar 5-10% pada beberapa *epoch*. Sedangkan pada grafik *loss* terlihat validasi *loss* tidak terlalu tinggi dibandingkan dengan grafik *loss* proses *training*.

Selain masalah perancangan arsitektur, dan data yang terlalu sedikit, nilai *epoch* yang menentukan jalannya proses *training* juga berpengaruh terhadap *overfitting*. Penggunaan *epoch* yang terlalu besar dapat menyebabakan *overfitting* yang terlalu parah, tetapi penggunaan *epoch* yang terlalu kecil juga dapat menghasilkan akurasi yang kecil sehingga terdapat kemungkinan proses *training* yang dilakukan belum maksimal (Gambar 4.17). Pada tugas akhir ini, digunakan *epoch* sebesar 50 karena *overfitting* yang dihasilkan tidak terlalu parah, dan akurasi nya juga tidak terlalu rendah yaitu sekitar 60-80%.

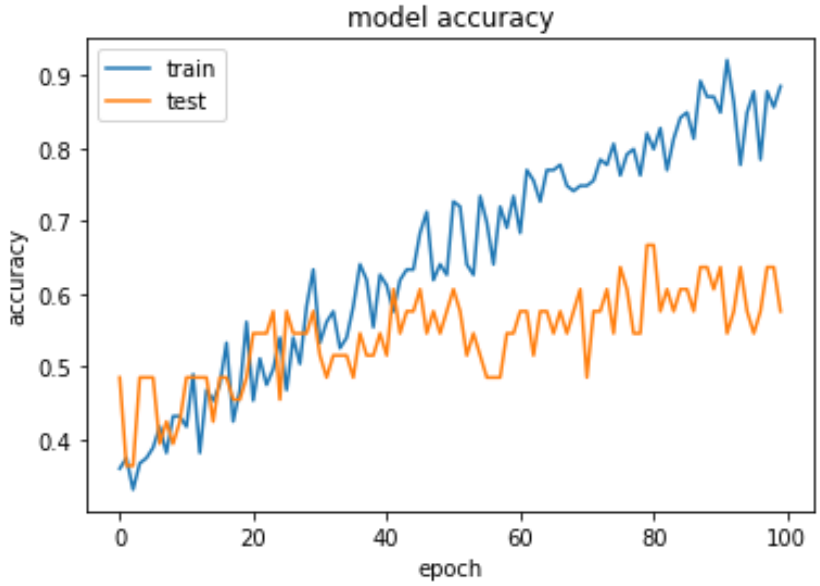

Gambar 4. 15. Hasil grafik akurasi *training* dan validasi untuk data yang tidak diaugmentasi

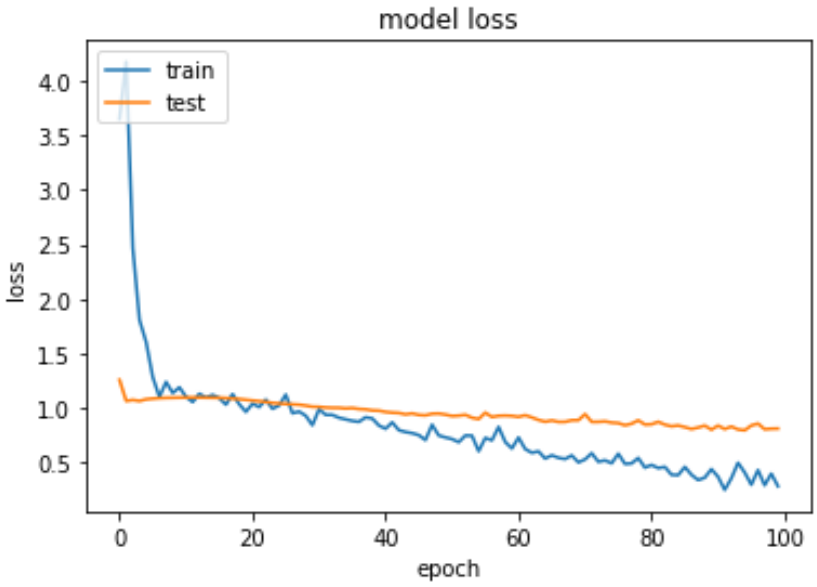

Gambar 4. 16. Hasil grafik *loss* atau *error training* dan validasi untuk data yang tidak diaugmentasi

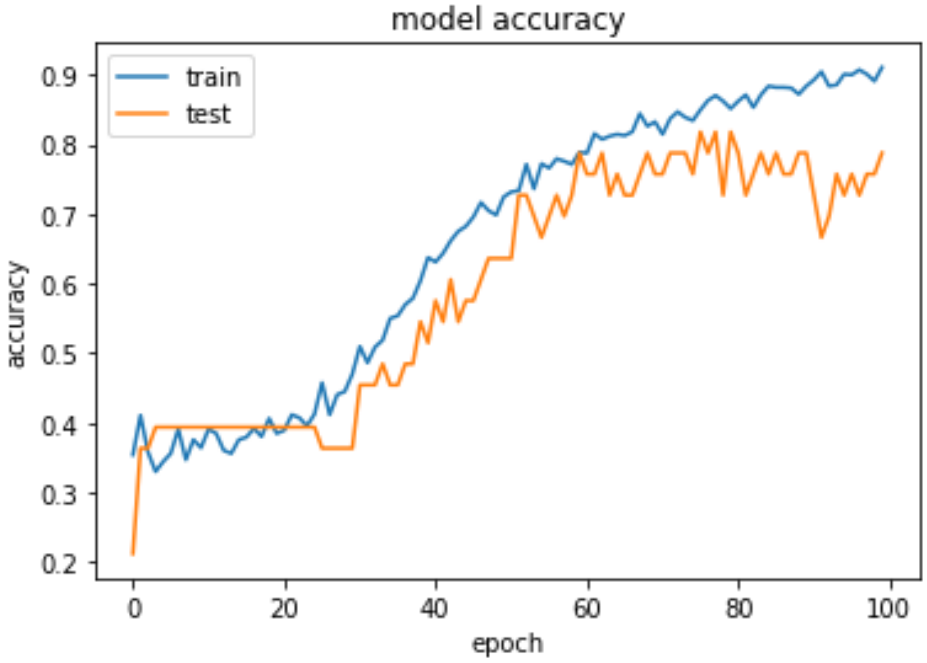

Gambar 4. 17. Hasil grafik akurasi *training* dan validasi untuk data yang diaugmentasi

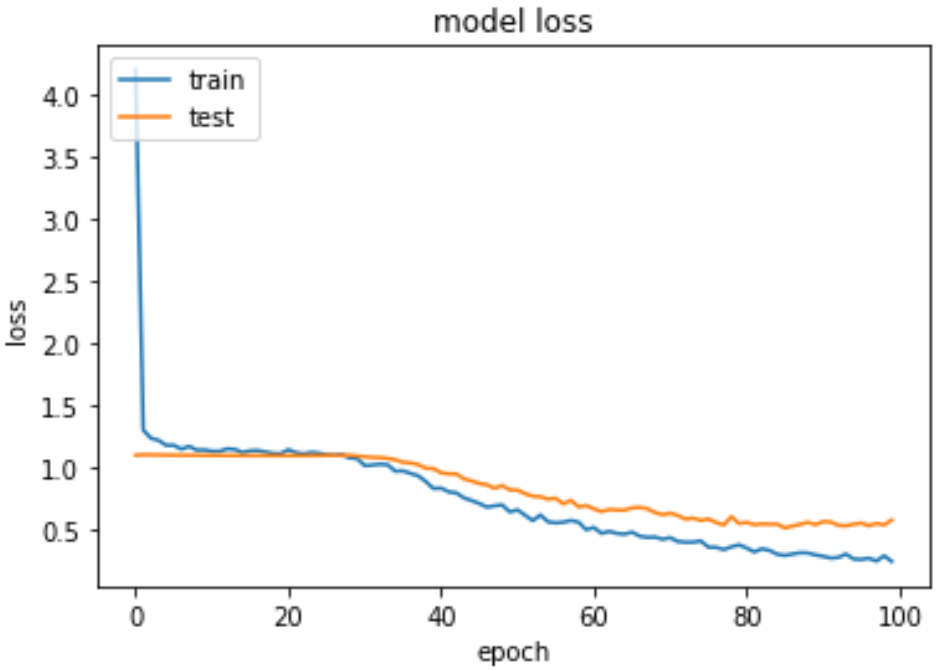

Gambar 4. 18. Hasil grafik *loss* atau *error training* dan validasi untuk data yang diaugmentasi

4.4. CNN Untuk Data Hasil Pemrosesan dengan CLAHE

Setelah didapatkan jumlah data, dan parameter-parameter model CNN yang memiliki akurasi tertinggi, yaitu dengan data yang diaugmentasi, dan menggunakan *epoch* sebesar 50, proses *learning* dilanjutkan untuk data yang ditambahkan proses *image per-processing*. Proses *learning* dilakukan sebanyak 4 kali yaitu untuk klasifikasi data yang tidak melewati proses *image enhacement*, dan untuk klasifikasi data yang di *ecnhance* terlebih dahulu menggunakan CLAHE dengan *clip limit* 0.01, kemudian dengan *clip limit* 0.02, dan *clip limit* 0.03. Proses *learning* ini dilakukan untuk melihat pengaruh penggunaan metode CLAHE pada proses *pre-processing* terhadap hasil klasifikasi CNN. Selain itu, proses ini juga dilakukan untuk mendapatkan nilai *clip limit* dari CLAHE yang paling efektif untuk setiap penyakitnya. Maksud dari *clip limit* efektif ini adalah nilai *clip limit* yang dapat menglasifikasikan penyakit tersebut secara benar, ketika dilihat dengan nilai *true positive* (TP) paling tinggi di *confusion matrix*.

Hasil proses *learning* dan validasi dari CNN memiliki akurasi untuk data yang tidak melewati proses *image enhancement* memiliki akurasi validasi sebesar 69.70%. Sedangkan untuk data yang melewati proses *image enhancement* dengan CLAHE yang menggunakan *clip limit* 0.01 memiliki akurasi yang sama yaitu 69.70%, dan untuk *clip limit* 0.02 memiliki akurasi validasi sebesar 60.61%, dan dengan *clip limit* 0.03 memiliki akurasi validasi sebesar 66.67%.

Untuk melihat hasil pengujian dari data validasi, dibuatlah *confusion matrix*. *Confusion matrix* menunjukkan data yang terklasifikasikan pada masing-masing kelas. Terdapat 4 *confusion matrix*, dari masing-masing hasil proses *learning*, yaitu untuk data yang tidak diproses dengan CLAHE, kemudian data yang diproses menggunakan CLAHE dengan *clip limit* 0.01, 0,02, dan 0.03. Keterangan dari *confusion matrix* tersebut adalah untuk label 0, adalah penyakit kista, dan label 1 adalah penyakit *hemangioma*, dan label 2 adalah penyakit HCC. Gambar 4.19 menunjukkan hasil *confusion matrix* untuk data yang tidak ditingkatkan kontrasnya terlebih dahulu. Dari data tersebut dihitung akurasinya dengan Persamaan 3.3 dan hasilnya validasi yang didapatkan sebesar yaitu 69.70%. Kemudian untuk Gambar 4.20 adalah hasil dari CNN dengan data yang ditingkatkan kontrasnya dengan CLAHE dengan *clip limit* 0.01, akurasi yang didapatkan adalah 69.70%. Gambar 4.21 adalah hasil CNN dengan data yang di CLAHE dengan *clip limit* 0.02, dengan akurasi sebesar 60.61%, dan Gambar 4.22 adalah hasil confusion matriks dari data yang di CLAHE dengan *clip limit* 0.03 dengan akurasi yang didapatkan sebesar 66.67%. Meskipun nilai akurasi ketika data di proses menggunakan CLAHE dengan *clip limit* 0.01 memiliki akurasi yang sama dengan ketika data tidak di proses menggunakan CLAHE yaitu sebesar 69.70%, tetapi terlihat adanya peningkatan jumlah hasil klasifikasi pada kista, dan penurunan pada *hemangioma*, sehingga penggunaan *clip limit* ini memiliki pengaruh yang berbeda-beda pada hasil klasifikasi pada masing-masing penyakit.

Tabel 4.1 menunjukkan hasil perhitungan spesifisitas dan presisi pada masing-masing penyakit yang dihitung menggunakan Persamaan 3.4 untuk presisi, dan Persamaan 3.5 untuk spesifisitas. Dari hasil tersebut didapatkan rata-rata presisi untuk penyakit *hemangioma* sebesar 0.653, dan spesifisitas sebesar 0.75925. Untuk penyakit kista didapatkan rata-rata presisi sebesar 0.975 dan spesifisitas sebesar 0.986, sedangkan pada penyakit HCC memiliki rata-rata presisi sebesar 0.375, dan spesifisitas 0.763.

Gambar 4. 19 *Confusion matrix* CNN untuk data yang tidak diproses dengan CLAHE, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC)

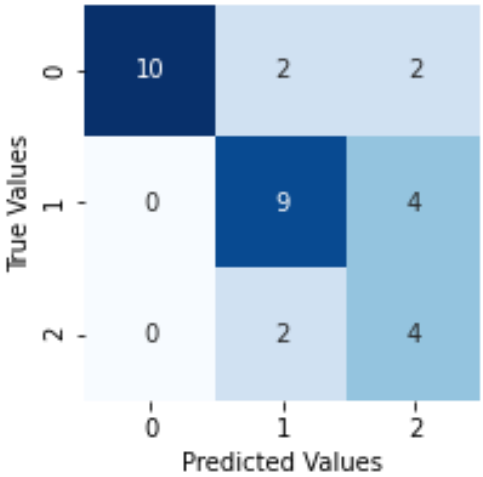

Gambar 4. 20. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE, dengan *clip limit* 0.01, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC)

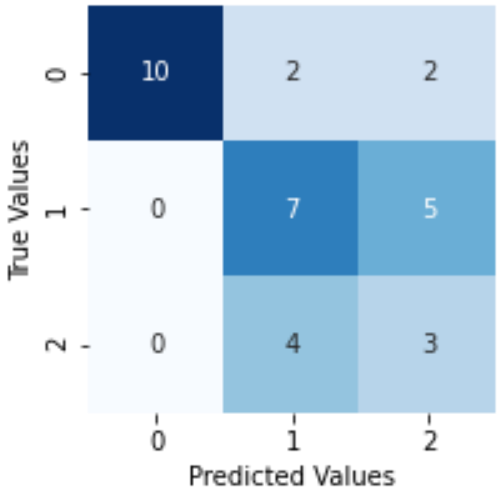

Gambar 4. 21. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE, dengan *clip limit* 0.02, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC)

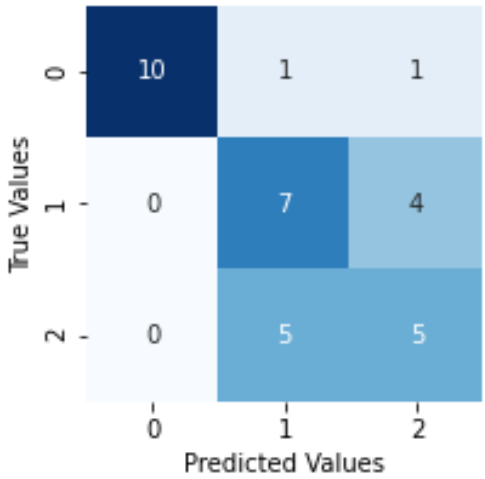

Gambar 4. 22. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE, dengan *clip limit* 0.03, (Keterangan: 0 = Kista, 1 = *Hemangioma*, 2 = HCC)

Pada hasil *confusion matrix*, dan hasil perhitungan nilai presisi, dan spesifisitas, terlihat adanya penagruh nilai *clip limit* yang digunakan terhadap hasil klasifikasi masing-masing penyakit. Setelah dilakukan analisa untuk pengaruh *clip limit* dari CLAHE terhadap hasil klasifikasi CNN yang dijelaskan pada subbab 5.4. Proses *training* kemudian dilakukan kembali untuk data dengan masing-masing penyakit yang ditingkatkan kontrasnya dengan *clip limit* paling efektif per masing-masing penyakit. Dari hasil *confusion matrix* (Gambar 4.20, Gambar 4.21, dan Gambar 4.22) menunjukkan bahwa untuk penyakit kista, memiliki hasil klasifikasi paling baik dengan *clip limit* paling baik adalah antara

Tabel 4. 1. Tabel presisi dan spesifisitas per penyakit

Penyakit	***Clip limit* CLAHE**	***Precision***	***Specificity***
Kista	-	0.9	0.9473
	0.01	1.0	1.0
	0.02	1.0	1.0
	0.03	1.0	1.0
Rata-rata		**0.975**	**0.986**
HCC	-	0.3	0.7667
	0.01	0.4	0.778
	0.02	0.3	0.727
	0.03	0.5	0.782
Rata-rata		**0.375**	**0.763**
Hemangioma	-	0.846	0.882
	0.01	0.6923	0.8
	0.02	0.538	0.625
	0.03	0.538	0.73
Rata-rata		**0.653**	**0.75925**

0.01 - 0.03, sedangkan untuk penyakit HCC *clip limit* efektifnya yang paling baik adalah 0.03 (Gambar 4.22), dan untuk penyakit *hemangioma* lebih baik tidak diproses menggunkan CLAHE (Gambar 4.19).

Gambar 4.23, dan Gambar 2.24 merupakan hasil grafik akurasi dan *loss* dari proses *training* dengan data yang memiliki nilai *clip limit* yang berbeda. Dalam grafik tersebut didapatkan nilai akurasi yang lebih tinggi yaitu 0.9394, atau 93.94% dibandingkan dengan *training-training* yang menggunakan *clip limit* yang sama pada setiap penyakitnya. Kemudian untuk melihat hasil pengujian data validasi, *confusion matrix* (Gambar 4.25) dibuat untuk melihat hasil klasifikasi per penyakit, dan dihitung nilai spesifisitas, dan presisinya (Tabel 4.2). Nilai spesifisitas yang didapatkan cukup tinggi yaitu sebesar 0.9733, sedangkan akurasinya juga mencapai angka 0.9090.

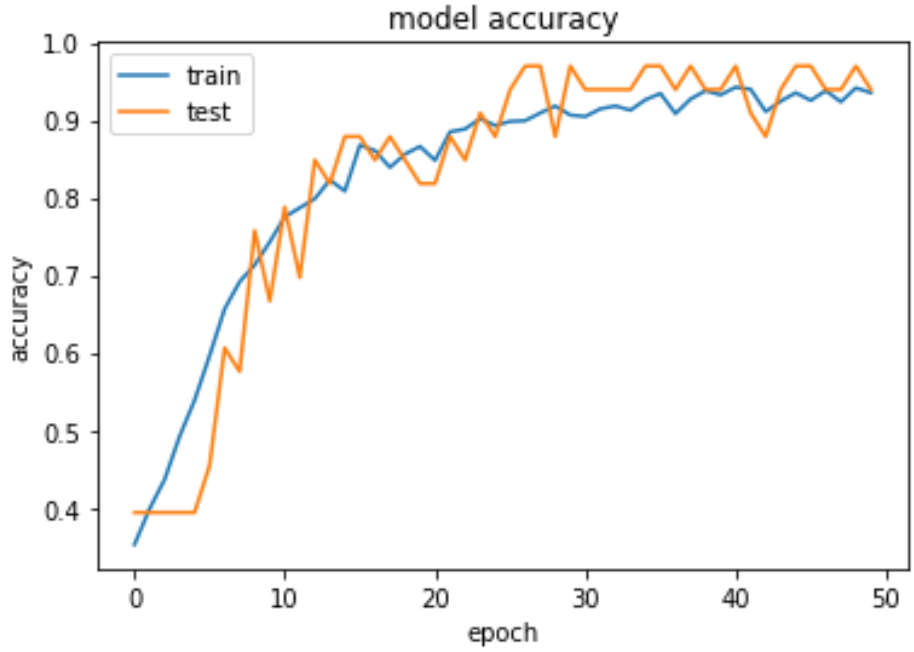

Gambar 4. 23. Hasil grafik akurasi *training* dan validasi untuk data yang diproses menggunakan *clip limit* efektif CLAHE

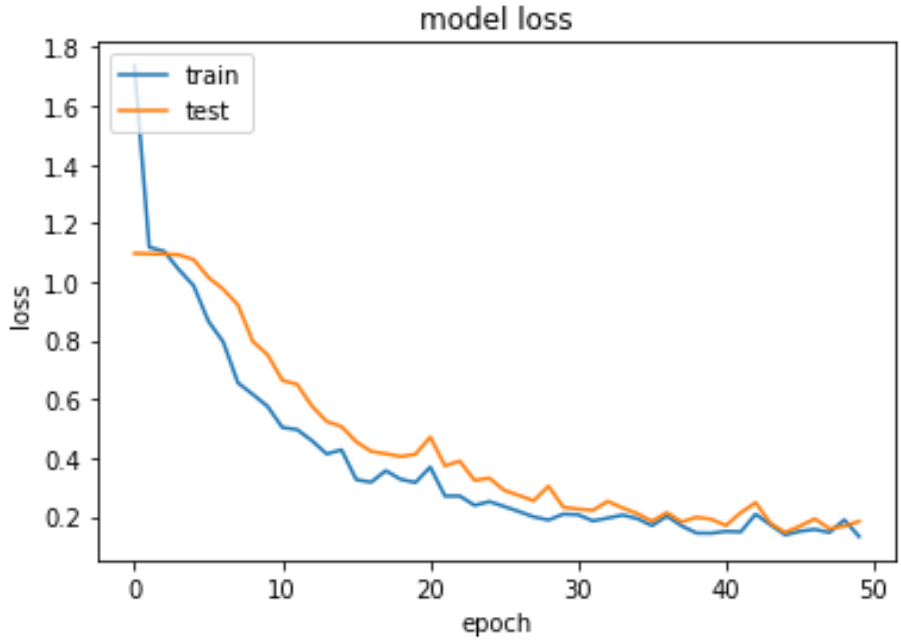

Gambar 4. 24. Hasil grafik *loss* atau *error training* dan validasi untuk data yang diprocess menggunakan *clip limit* efektif CLAHE

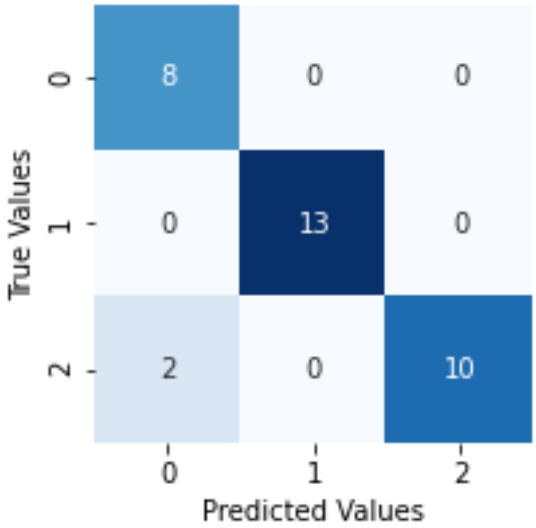

Gambar 4. 25. *Confusion matrix* CNN untuk data yang diproses dengan CLAHE dengan *clip limit* berbeda-beda , (Keterangan: 0 = Kista, *clip limit* 0.01, 1 = *Hemangioma*, *clip limit* 0, 2 = HCC, *clip limit* 0.03)

Tabel 4. 2. Tabel presisi dan spesifisitas hasil *training* dengan *clip limit* efektif

Penyakit	***Clip limit* CLAHE**	**Presisi**	**Spesifisitas**
Kista	0.01	0.7272	0.92
HCC	0.03	1.0	1.0
Hemangioma	-	1.0	1.0
Rata-rata		**0.9090**	**0.9733**

BAB V PEMBAHASAN

5.1. Augmentasi Data

Augmentasi data merupakan salah satu metode untuk mengatasi data yang tidak imbang, dan memperbanyak data. Dalam penggunaannya di metode CNN untuk klasifikasi, karena pada proses *training* membutuhkan data yang banyak dan kompleks dalam segi variasinya agar dapat merepresentasikan data yang semirip mungkin dan sangat bervariasi dengan keadaan nyatanya, penggunaan data augmentasi ini memiliki peran yang sangat penting. Karena *dataset* yang didapatkan hanya memiliki total 139 gambar untuk *training*, dan dalam data tersebut memiliki variasi yang kurang karena beberapa gambar diambil dari satu pasien yang sama. Setelah penerapan data augmentasi data yang didapatkan menjadi 1112, dan proses tersebut memberikan efek sesuai dengan fungsinya sehingga data yang digunakan lebih bervariasi. Penambahan proses augmentasi ini dapat mengurangi *overfitting*. Hal ini terbukti pada saat sebelum di lakukan augmentasi, hasil grafik *training* nya memiliki jarak atau *gap* antara *train* dan validasi yang cukup besar, tetapi pada saat data diperbanyak dengan diaugmentasi, *gap* tersebut turun. Meskipun *overfitting* nya kecil, tetapi hal ini dapat diperbaiki lagi dengan menambah jumlah data lebih banyak lagi, namum penggunaan augmentasi data yang terlalu besar juga dapat menyebabkan kebalikan dan *overfitting*, yaitu underfitting.

Banyak teknik-teknik augmentasi yang disedikan seperti transformarsi geometris, transformasi *color space*, *kernel filters*, dan lain-lain untuk membantu proses penambahan data. Pada tugas akhir transfromasi geometris berupa *width shift*, dan *height shift*, dan horizontal *flip*. Selain itu, augmentasi data lain yang digunakan adalah penambahan *noise* berupa *Gaussian noise*, dan *salt and pepper noise*.

Penggunaan transformasi geomteris berupa horizontal *flip*, *width shift* dan *height shift* dilakukan berdasarkan penelitian yang mengenai penggunaan teknik augmentasi data pada *medical image* [17]. Penelitian tersebut menunjukkan bahwa penggunaan teknik-teknik augmentasi tersebut memiliki akurasi yang cukup tinggi. Metode augmentasi ini memiliki *high mutual information* tehadap data aslinya, sehingga informasi secara bentuk dan / atau fitur dari data asli tidak banyak berubah, dan dapat merepresentasikan data dengan baik. Penggunaan augmentasi geomteris lain, seperti rotasi, biasanya menghasilkan artefak yang dapat menghilangkan informasi atau memotong inti dari data tersebut yaitu lesinya. Gambar 5.1 menunjukkan percobaan penggunaan augmentasi data dengan rotasi yang cukup besar. Hasil tersebut menunjukkan adanya perubahan pada data yang menghilangkan atau memotong lesi dari penyakit, sehingga augmentasi tersebut kurang relevan, atau tidak dapat merepresentasikan data aslinya dengan

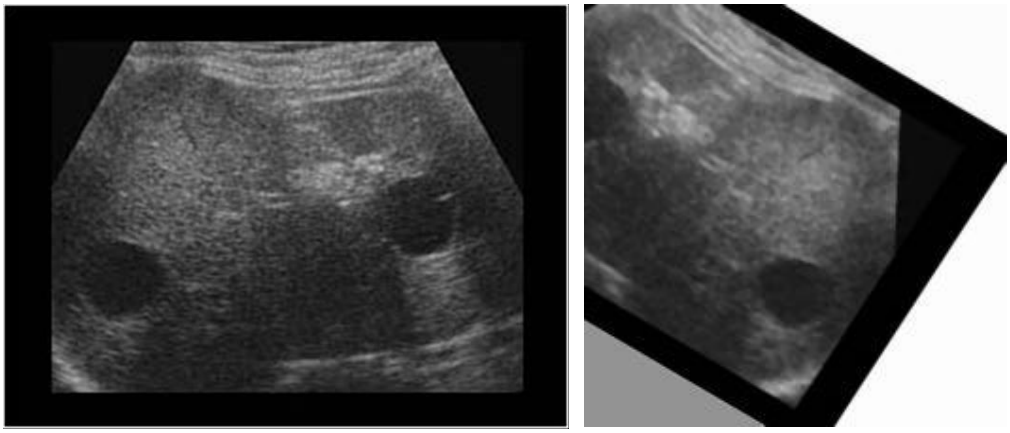

Gambar 5. 1. Perbandingan (a) data asli dengan (b) hasil rotasi dengan sudut 40 derajat

baik. Penggunaan rotasi sendiri juga dapat megubah bentuk data *ultrasound*. Data *ultrasound* terbentuk dari hasil *beam* yang dipancarkan sesuai dengan *probe* yang digunakan. Ketika dilakukan penggunaan augmentasi rotasi, dapat dilihat hasil yang didapatkan mengubah bentuk *beam*, sehingga gambar teresebut tidak merepresentasikan gambar hasil *ultrasound*. Penggunaan penambahan *noise* dilakukan karena, selain tidak mengubah banyak fitur dan informasi dari data, penambahan *noise* pada data *training* dapat membuat model CNN menjadi lebih *robust*. Pada prosesnya, penambahan *noise* ini dilakukan setelah proses *image pre-processing*, karena *image pre-processing* dilakukan untuk mengurangi *noise*, tetapi *noise* tersebut merupakan *noise* asli yang dihasilkan saat proses *imaging*, sedangkan *noise* pada augmentasi data ini merupakan *noise* buatan.

5.2. *Image Pre-processing*

Pada tahap *image pre-processing* ini, terdapat beberapa metode *pre-processing* yang dilakukan, yaitu median filter untuk menghilangkan *noise*, dan *Clip limited Adaptive Histogram Equalization* (CLAHE) untuk proses peningkatan kontras citra.

5.2.1. Median Filter

Median filter merupakan salah satu teknik pengurangan *noise* dalam citra *ultrasound*. Filter ini sangat baik dalam proses pengurangan *nosie salt and paper*. Hasil dari filter median ini adalah gambar menjadi lebih *blur*, dan semakin besar nilai *window* yang digunakan, tingkat *blurringnya* juga semakin tinggi. Hal ini dijelaskan pada penelitian sebelumnya [18] yang menyebutkan bahwa karena nilai piksel diubah menjadi nilai mediannya, resolusinya menjadi turun, tanpa mengurangi kejelasan dari tepi gambar, tetapi hasilnya menyebabkan adanya efek *blurring*. Sehingga semakin besar nilai *window* yang digunakan efek *blurring* nya semakin besar karena nilai median yang diambil mengambil nilai piksel yang lebih banyak dan hanya diambil satu nilai yaitu nilai mediannya untuk dipakai.

Dari hasil perhitungan PSNR, menunjukkan bahwa nilai PSNR tertinggi didapatkan dengan window 3 × 3. PSNR yang tinggi menunjukkan perbandingan *noise* dan sinyal atau gambar semakin besar.

5.2.2. *Contrast Limited Adaptive Histogram Equalization* (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan metode peningkatan kontras secara adaptif. *Clip limit* yang digunakan sebesar 0.01, 0.02, dan 0.03. CLAHE bekerja dengan cara memotong intensitas yang melebihi dari *clip limit*, dan meratakan lebihan dari *clip limit* ke bawah, dan intensitas dibawah ditambahkan dengan hasil pemotongan intensitas, sehingga kontras naik.

Analisa pengaruh CLAHE dilakukan menggunakan histogramnya karena cara kerja CLAHE mempengaruhi intensitas piksel pada setiap nilai piksel. Nilai intensitas ini dapat dilihat dari histogramnya. Gambar 4.8, Gambar 4.9, dan 4.10 menunjukkan hasil peningkatan kontras citra HCC, *Hemangioma*, dan kista. Sesuai dengan cara kerja CLAHE yang merupakan salah satu metode *equalization*, ketika diterapkan metode CLAHE pada data, dapat terlihat pada histogram adanya pemerataan. Meskipun CLAHE dari namanya adalah *equalization* yang artinya untuk pemerataan, CLAHE dapat digunakan untuk meningkatkan kontras. Karena penggunaan CLAHE ini meratakan hasil pemotongan nilai intensitas piksel yang di atas *clip limit*, atau didistribusikan ke semua *bin* secara rata, sehingga terdapat penambahan intensitas piksel. Penambahan intensitas piksel ini artinya adanya peningkatan kontras pada beberapa nilai piksel. Meskipun dapat meningkatkan kontras, nilai *clip limit* yang digunakan memiliki efek yang berbeda-beda pada hasil klasifikasi *focal liver diseases* ini. Hal ini dibahas pada subbab 5.4. Penggunaan *clip limit* ini, membantu untuk menentukan seberapa besar tingkat kontras dinaikkan, atau dipotong, kemudian diratakan.

Hasil dari pengujian CLAHE ini menunjukkan bahwa semakin tinggi *clip limit* yang digunakan, intensitas piksel yang terpotong semakin besar, dan pemerataan piksel serta peningkatan kontrasnya juga semakin tinggi. Pada Gambar 4.12 – 4.14 menunjukkan pemotongan intensitas, dan pemerataan pada intensitas piksel nya. Karena kegunaannya sebagai pemerata atau *equalizer*. Semakin tinggi *clip limit* yang digunakan maka *level* intensitas yang terpotong juga semakin banyak, dan proses pemerataannya juga semakin tinggi. Ketika dilakukan proses *equalization*, terlihat adanya penurunan intensitas piksel ketika menggunakan clip limit 0.01 dari intensitas sebesar 35000 turun menjadi sekitar 25000 ketika digunakan *clip limit* 0.02, dan pada penggunaan *clip limit* 0.03, intensitasnya turun hingga kurang dari 25000 (Gambar 4.13).

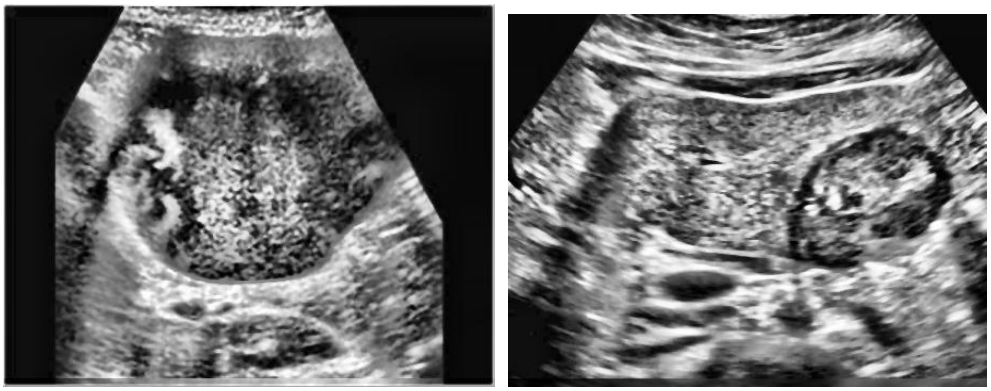

Gambar 5. 2. Gambar kista yang menyerupai HCC, (a) gambar kista yang kontrasnya ditingkatkan terlalu tinggi (*clip limit* = 0.03) sehingga mirip dengan HCC, (b) Gambar HCC

Selain pemotongan intensitas tinggi pada nilai piksel, terjadi peningkatan intensitas pada nilai piksel yang tidak terlalu tinggi, atau terjadi peningkatan kontras. Kontras tersebut dapat naik karena adanya pemerataan yang dilakukan karena hasil pemotongan intensitas yang tinggi. Pada hasil Gambar 4.8, Gambar 4.9, dan Gambar 4.10 juga terlihat jelas adanya peningkatan kontras pada masing-masing penyakit. Namun penggunaan *clip limit* yang terlalu besar dapat menyebabkan adanya *excess* yang keluar, contohnya pada Gambar 4.10(a) pada penggunaan *clip limit* 0.03. Sehingga, pada tugas akhir nilai *clip limit* yang digunakan hanya dibatasi hingga 0.03. Karena semakin tinggi *clip limit* yang digunakan menyebabkan *excess* semakin besar, dan dapat mempengaruhi kualitas kontras dari lesi penyakit. Contoh lain yang menunjukkan *excess* yang dapat membuat lesi dari kista menjadi mirip dengan lesi HCC, Gambar 5.2 menunjukkan hasil peningkatan kontras dari data kista yang menghasilkan *excess* sehingga pada inti lesinya memiliki *echogenity* seperti HCC. Hal ini dapat berpengaruh pada klasifikasi karena dapat menyebabkan lesi dari penyakit malah menjadi mirip satu sama lain terutama untuk *hemangioma*, dan HCC yang terkadang memiliki *echogenity* yang mirip. Peningkatan yang terlalu tinggi ini dapat menimbulkan kerancuan, dan dapat mempengaruhi hasil klasifikasi, sehingga pada klasifikasinya digunakan *clip limit* paling efektif yang dapat menglasifikasikan penyakit dengan baik, dan hal ini dijelaskan pada subbab 5.4

5.3. CNN untuk Klasifikasi *Focal Liver Diseases*

Arsitektur CNN yang digunakan pada tugas akhir ini kecil atau tidak dalam, karena data yang digunakan sangat sedikit. Arsitektur yang kecil artinya parameter yang diambil tidak terlalu banyak, dan model arsitektur ini tidak terlalu dalam. Penggunaan arsitektur yang tidak terlalu dalam ini karena *dataset* yang digunakan sangat kecil, dan data antar kelas terkadang memiliki fitur yang hamper mirip. Pengambilan parameter yang terlalu banyak memperbanyak fitur yang

diambil, dan fitur-fitur yang didapatkan terlalu detail, sehingga model kesulitan dalam proses validasinya, karena fitur-fitur pada data sangat mirip satu sama lain. Penggunaan arsitektur yang terlalu dalam dapat membuat data cepat *overfitting*.

Hasil grafik akurasi dari CNN pada Gambar 4.10 dan Gambar 4.11 menunjukkan hasil grafik akurasi yang terkadang nilai akurasi *training* dan validasi yang naik turun, kemudian terlihat jelas *gap* antara *train accuracy* dan *validation accuracy.* Hal tersebut menunjukkan model CNN yang *overfitting*. *Overfitting* adalah hal yang menunjukkan bahwa hasil model CNN mengalami *high variance*, dan *low bias*. *High variance* artinya ketidakmampuan model untuk men-generalisasi data baru. Penambahan jumlah data dengan metode augmentasi data, dan penambahan regularisasi data seperti *dropout* pada penelitian sebelumnya [13] dapat membantu mengatasi *overfitting*. Perbandingan grafik akurasi dari *training* dan validasi untuk data yang tidak diaugmentasi terlebih dahulu memiliki jarak yang cukup besar, Tetapi, setelah dilakukan proses augmentasi data, didapatkan *gap* yang semakin kecil tetapi tetap mengalami *overfitting*.

Meskipun tidak ada ukuran yang menentukan berapa banyak data yang harus digunakan dalam CNN, jumlah data dan variasi sangat mempengaruhi kinerja CNN. Penggunaan *dataset* yang kecil, dan data yang mirip satu sama lain karena beberapa data yang diambil merupakan data satu pasien yang sama, sehingga variasinya sangat kurang ini memperbesar kemungkinan model CNN untuk selalu *overfitting*. Penggunaan augmentasi dapat membantu mengurangi *overfitting* dan menambah variasi data, namun hasil yang didapatkan akan lebih baik lagi apabila data asli yang digunakan jumlahnya lebih banyak, karena fitur-fitur dan parameter yang didapatkan akan menjadi sangat berbeda dan sehingga setiap kelas dan data memiliki keunikan masing-masing. Diperlukannya data-data yang lebih banyak, dan teknik-teknik pengolahan data yang lebih baik agar model yang didapatkan bisa lebih baik lagi. Data yang lebih banyak dan lebih bervariasi akan dapat merepresentasikan data yang lebih sesuai dengan keadaan nyata. Penggunaan *dataset* yang lebih baik, dapat menghasilkan model yang lebih *realiable* nantinya ketika digunakan pada data lain. Selain itu, diperlukannya asistensi dengan tenaga ahli medis yang lebih memahami mengenai data penyakit-penyakit ini untuk membentuk suatu *dataset* yang lebih baik.

Selain penggunaan augmentasi data, penggunaan nilai *epoch* yang baik juga dapat dilakukan untuk menghindari *overfitting*. Sehingga, tahap selanjutnya yang dilakukan adalah menganalisa dan menentukan nilai *epoch* yang baik, agar model yang didapatkan tidak mengalami *overfitting* yang terlalu parah. Penentuan nilai *epoch* ini dapat dilihat dari hasil grafik akurasi dan *loss* saat proses *training*. Dalam Gambar 4.18 menunjukkan bahwa penggunaan *epoch* antara 40 hingga 60 memiliki nilai akurasi yang cukup baik dan tidak mengalami *overfitting* yang terlalu parah. Pada hasil grafik ini terlihat *overfitting* sudah terjadi bahkan ketika

epoch masih bernilai kecil sekitar 20. Namun, semakin besar nilai *epoch* yang digunakan semakin besar pula *overfitting* yang terjadi . Dapat dilihat, bahwa pada *epoch* 60 hingga 100 terlihat akurasi dari data validasi sudah tidak bias untuk naik, sedangkan akurasi *training* masih menunjukkan *trend* naik, sehingga menyebabkan adanya jarak atau *gap* yang cukup besar. Namun ketika *epoch* yang digunakan terlalu kecil, dalam hal ini nilai *epoch* antara 1 hingga 40, akurasi yang didapatkan kurang maksimal, atau akurasi yang didapatkan masih bisa naik, sehingga untuk proses *training* selanjutnya, digunakan nilai *epoch* sebesar 50, dimana pada nilai *epoch* tersebut hasil akurasi yang didapatkan sudah cukup tinggi, dan tidak mengalami *overfitting* yang terlalu parah.

5.4. Pengaruh *Clip limit* CLAHE Terhadap Masing-masing Hasil Klasifikasi Penyakit

Pada hasil *confusion matrix* dengan 4 kondisi berbeda yaitu tanpa CLAHE, menggunakan CLAHE dengan *clip limit* 0.01, 0.02 dan 0.03, terlihat jelas bahwa CLAHE memiliki pengaruh yang berbeda-beda pada setiap penyakit. Dari hasil tersebut didapatkan rata-rata presisi untuk penyakit *hemangioma* sebesar 0.653, dan spesifisitas sebesar 0.75925. Untuk penyakit kista didapatkan rata-rata presisi sebesar 0.975 dan spesifisitas sebesar 0.986, sedangkan pada penyakit HCC memiliki rata-rata presisi sebesar 0.375, dan spesifisitas 0.763. Dari Tabel 4.1 terlihat bahwa rata-rata nilai spesifisitas pada masing-masing penyakit mencapai lebih dari 0.70. Spesifisitas yang tinggi dapat membantu dalam penegakan diagnosis, namun presisi yang didapatkan masih cukup rendah terutama pada penyakit HCC.

Pada penyakit *Hemangioma*, terlihat jelas bahwa semakin tinggi nilai *clip limit* yang digunakan, semakin kecil pula penyakit tersebut dapat terklasifikasikan dengan baik. Untuk penyakit kista, dengan menggunakan nilai *clip limit* antara 0.01 – 0.03, dari total 10 data kista, semua data tersebut terklasifikasikan dengan benar, tetapi dengan menggunakan *clip limit* 0.03. Pada Tabel 4.1, dapat dilihat untuk *clip limit* 0.01 - 0.03, nilai presisi dan spesifisitas nya mencapai angka 1. Sedangkan untuk penyakit HCC sendiri, data yang di tingkatkan kontras nya memiliki jumlah data yang terklasifikasikan dengan benar didapatkan saat menggunakan *clip limit* 0.03. Untuk penyakit hemangioma, data yang digunakan lebih baik tidak ditingkatkan kontrasnya. Sehingga penggunaan CLAHE ini memiliki efek yang berbeda-beda sehingga setiap penyakit terklasifikasikan dengan baik pada nilai-nilai *clip limit* tertentu. *Clip limit* yang dapat menghasilkan klasifikasi paling baik untuk penyakit kista adalah 0.01 – 0.03, dan untuk penyakit HCC ditingkatkan kontrasnya menggunakan *clip limit* 0.03, dan *Hemangioma* lebih baik untuk tidak di *pre-process* dengan CLAHE.

Setelah dapat dilihat pengaruh nilai *clip limit* pada masing-masing penyakit, dengan menerapkan nilai *clip limit* paling efektif pada masing-masing penyakit,

dilakukan proses *training* kembali. Dari hasil *training* data didapatkan hasil pengujian yang dapat dilihat Gambar 4.17 berupa *confusion matrix*. Dari hasil pengujian ini didapatkan hasil klasifikasi dengan akurasi yang lebih tinggi yaitu 93.94%, dan spesifitas yang didapatkan juga cukup tinggi yaitu 0.9773 (Tabel 4.2). Spesifitas tinggi ini dapat menunjukkan kemampuan program untuk tidak salah klasifikasi antara penyakit satu dengan yang lainnya, seperti kemungkinan penyakit *hemangioma* terklasifikasikan menjadi HCC, atau kista, dan sebaliknya. Sehingga dalam proses penegakan diagnosis, program ini dapat membantu dalam proses penegakan diagnosis, karena menekan kemungkinan *false positive* terjadi. Namun, pada penggunaannya untuk klasifikasi oleh orang awam, lebih baik digunakan data yang diproses menggunakan *clip limit* yang sama yaitu 0.01, karena memiliki akurasi paling tinggi yaitu 69.70%, dan juga ketika tidak diproses dengan CLAHE. Selain itu, hasil ini juga perlu ditinjau ulang, dan diperbaiki melihat kondisi bahwa nilai presisi kista yang didapatkan masih rendah yaitu 0.7272, hal ini karena model yang digunakan masih *overfitting,* dan dibutuhkan metode *pre-process* yang lebih baik. Selain itu karena model yang digunakan masih *overfitting*, hal ini dapat menyebabkan nilai *clip limit* efektif yang didapatkan pada data yang digunakan pada tugas akhir ini dapat berubah ketika menggunakan *dataset* lain.

5.5. Perbandingan Dengan Penelitian Sebelumnya

Perbandingan tugas akhir ini dengan penelitian sebelumnya adalah, pada penelitian sebelumnya [4], dari 10 penyakit yang diklasifikasikan, antara diantara *focal liver diseases* menunjukkan bahwa klasifikasi antara HCC, dan kista, serta *hemangioma* memiliki akurasi sebesar 73% dengan menggunakan hasil ekstraksi fitur GLCM, dan *fractal features*, sedangkan dengan menggunakan metode ANN didapatkan akurasi sebesar 80%. Penelitian yang melakukan klasifikasi terhadap tiga penyakit yang digunakan pada tugas akhir ini yaitu HCC, *hemangioma*, dan kista dilakukan oleh Yoo Na Hwang et al [19]. Penelitian tersebut melakukan klasifikasi untuk ketiga penyakit tersebut, namun klasifikasinya dilakukan antar masing-masing penyakit yaitu kista terhadap *hemangioma*, *hemangioma* terhadap *malignant* (HCC), dan *malignant* (HCC) terhadap kista. Dalam penelitian tersebut didapatkan hasil klasifikasi dengan rata-rata sebesar 96% dengan menggunakan metode ANN dan diambil fitur tekstural *hybrid* yang didapatkan dari hasil pemilihan ROI. Namun klasfikasi tersebut tidak bisa dilakukan untuk ketiga penyakit sekaligus. Sehingga perbedaan tugas akhir ini dengan penelitian sebelumnya adalah, metode yang digunakan dapat menglasifikasikan ketiga penyakit yaitu HCC, kista, dan hemangioma secara bersamaan, dan tidak perlu dilakukan proses pemilihan ROI dan ekstraksi fitur, sehingga lebih mudah dalam proses klasifikasinya. Akurasi yang didapatkan juga tidak terlalu jauh yaitu

sebesar 93.94%. Hasil ini dapat ditingkatkan dengan menambahkan data yang lebih banyak., dan perancangan arsitektur CNN yang lebih baik.

5.6. Kontribusi dan Ruang Pengembangan

Pada tugas akhir ini, diusulkan metode klasifikasi citra *ultrasound* dari *focal liver disesases* dengan menggunakan *Convolutional Neural Network*. Tugas akhir ini juga mengusulkan peningkatan kualitas kontras dari citra *ultrasound focal liver diseases* dengan menggunakan metode *Clip limited Adaptive Histogram Equalization* (CLAHE). CLAHE digunakan untuk meningkatkan kualitas kontras dari citra [3] agar dapat memperjelas tepi lesi, dan memperjelas perbedaan antara lesi antara penyakit-penyakit *liver* yang digunakan yaitu *Hemangioma*, HCC, dan kista. Hasil citra yang sudah ditingkatkan kontrasnya ini kemudian digunakan sebagai data latih untuk klasifikasi. Proses klasifikasi dilakukan dengan menggunakan metode CNN. Berbeda dengan penelitian sebelumnya [4][19], peneliti menggunakan metode SVM untuk menglasifikasikan citra *ultrasound* dari *focal liver diseases.*

Tugas akhir ini memiliki beberapa ruang untuk pengembangan di penelitian selanjutnya. Pertama, pada tugas akhir ini digunakan arsitektur yang telah dijelaskan pada subbab 3.3.3 masih mengalami *overfitting*, sehingga peneliti selanjutnya dapat mengembangkan arsitektur tersebut agar tidak mengalami *overfitting* untuk meningkatkan performa CNN sehingga bisa didapatkan akurasi yang lebih baik lagi, dan program CNN tersebut menjadi program klasifikasi yang lebih *reliable*. Peneliti selanjutnya dapat mengembangkan aristektur dengan mengubah jumlah *layer*, penambahan nilai *epoch*, penggunaan *early stopping*, dan penggunaan *batch normalization layer* sebagai teknik regularisasi, dan juga menggunakan metode *transfer learning*, agar model yang digunakan tidak mengalami *overfitting*.

Kedua adalah penggunaan atau penambahan *dataset* yang lebih bervariasi, dan lebih banyak lagi, karena jumlah data dan tingkat variasi dari data sangat mempengaruhi kinerja dari CNN. Penelitian selanjutnya juga dapat memperkaya *dataset* dengan menggunakan jenis augmentasi data lain, dan menambah jumlah data augmentasi sehingga *dataset* yang digunakan memiliki variasi yang lebih banyak. Selain itu, diperlukannya asistensi oleh tenaga ahli medis yang lebih memahami mengenai data penyakit-penyakit ini untuk membentuk suatu *dataset* yang lebih baik.

Ketiga, penelitian selanjutnya dapat menggunakan metode *image enhacement* lain. Metode yang digunakan harus memperjelas perbedaan antara lesi-lesi penyakit *focal liver diseases* ini terutama untuk *hemangioma*, HCC, dan kista sehingga data yang digunakan untuk *training* lebih baik, dan tidak menimbulkan kerancuan antar data setelah di tingkatkan kualitasnya.

BAB VI KESIMPULAN DAN SARAN

6.1. Kesimpulan

Pada tugas akhir ini, diajukan metode untuk melakukan klasifikasi citra *ultrasound* dari *focal liver diseases* yaitu *Hemangioma*, HCC, dan kista dengan menggunakan metode *Convolutional Neural Network*. Pada penelitian sebelumnya klasifikasi dilakukan dengan menggunakan metode *Support Vector Machine* (SVM). Proses pengujian baik secara unit maupun sistem menghasilkan beberapa kesimpulan. Pertama, median filter dengan *window* 3 × 3 memiliki nilai PSNR paling tinggi dibandingkan dengan *window* 5 × 5, dan 7 × 7. Kedua, augmentasi data dapat membantu menambah jumlah data, menambah variasi dari *dataset*, dan mengurangi *overfitting* model CNN. Ketiga, peningkatan kualitas kontras citra *ultrasound* untuk *focal liver diseases* dengan menggunakan metode *Clip limited Adaptive Histogram Equalization* (CLAHE) dapat meningkatkan kontras citra sehingga lesi penyakit dapat terlihat lebih jelas, tetapi penggunaan nilai *clip limit* yang paling efektif berbeda-beda pada setiap penyakitnya, untuk penyakit HCC memiliki *clip limit* efektif 0.03, untuk penyakit kista 0.01, dan *hemangioma* tidak di proses menggunakan CLAHE. Penggunaan CNN untuk klasifikasi *focal liver diseases* yaitu, penyakit HCC, *Hemangioma*, dan kista, memiliki akurasi sebesar 69.70% ketika tidak ditingkatkan kontrasnya menggunakan CLAHE, namun setelah ditingkatkan kontrasnya menggunakan CLAHE, akurasinya dapat naik hinnga 93.94%. Mekipun akurasi yang didapat bisa mencapai 93.94%, tetapi hasil ini masih dapat berubah-ubah serta nilai *clip limit* dari CLAHE juga dapat berbeda jika menggunakan *dataset* lain karena model yang digunakan masih mengalami *overfitting*.

6.2. Saran

Untuk meningkatkan akurasi CNN dibutuhkan *dataset* yang lebih besar, dan memiliki variasi yang lebih tinggi, sehingga model CNN tidak mudah mengalami *overfitting*. Disarankan juga untuk menggunakan data primer yang didapatkan dari rumah sakit agar hasil yang didapatkan dapat lebih sesuai dengan keadaan yang ada. Kemudian pada penelitian ini, arsitektur yang digunakan masih rawan untuk mengalami *overfitting* karena data jumlah data yang digunakan sedikit, dan arsitektur yang digunakan tidak terlalu dalam, sehingga saran untuk selanjutnya adalah mengembangkan arsitektur yang lebih baik lagi terutama arsitektur yang tidak memiliki model yang terlalu dalam, atau penggunaan *transfer learning* menggunakan model yang ada seperti VGG-16, VGG-19, ResNet, dll. jika *dataset* yang digunakan kecil. Perbaikan arsitektur lain yang dapat dilakukan adalah dengan menambah menggunakan *regularization technique* lain seperti penggunaan *batch normalization layer*, atau penggunaan nilai *dropout* yang lebih kecil karena penggunaan *dropout* yang terlalu besar menyebabkan model yang tidak stabil. Selain itu diperlukan metode *pre-processing* yang lebih baik lagi agar

dapat memperjelas perbedaan data per penyakit, dan tidak menurunkan akurasi hasil klasifikasi pada masing-masing penyakit, seperti penggunaan *anisotropic diffusion filter*, dan lain-lain.

DAFTAR PUSTAKA

[1] Kementrian Kesehatan Republik Indonesia, 2019, “Hari Kanker Sedunia 2019”, https://www.depkes.go.id/article/view/19020100003/hari-kanker-sedunia-2019.html, (diakses pada 9 Novermber 2019).

[2] European Association for the Study of the Liver, European Organisation for Resecarch and Treatment of Cancer, “EORTC Clinical Practice Guidelines: Management of hepatocelullar carcinoma,” Journal of Hepatology, vol. 56, pp. 908 – 943, 2012.

[3] Smriti Sahu, Maheedhar Dubey, Mohammad Imroze Khan, “Comparative Analysis of Image enhancement Techniques for Ultrasound Liver Image,” International Journal of Electrical and Computer Engineering (IJECE), vol. 2, no. 6, pp. 792 – 797, 2012

[4] Raghesh Krishnan K, Sudhakar Radhakrishnan, “Focal and diffused liver disease classification from ultrasound images based on isocontour segmentation,” IET Image Process, vol. 9, Iss. 4, pp. 261 – 270, 2015

[5] Marianna G. Mavilia, Tina Pakala, Marco Molina and George Y. Wu, “Differentiating Cystic Liver Lesions: A Review of Imaging Modalities, Diagnosis and Management,” Journal of Clinical Translational Hepatology, vol. 6, pp. 208 – 216, 2018.

[6] Lei Zhang, Haijiang Zhu, Tengfei Yang, “Deep Neural Networks for fatty liver ultrasound images classification,” 2019 Chinese Control And Decision Conference (CCDC), pp. 4641 – 4646, 2019

[7] Bajenaru N, Balaban V, Savulecu F, Campeanu, Patrascu, “Hepatic Hemangioma – review-“, Journal of Medicine and Life, vol. 8, Special Issue, pp. 4 – 11, 2015

[8] Hennedige, Tiffany, Venkatesh, Sudhakar Kundapur, “Imaging of hepatocellular carcinoma: diagnosis, staging and treatment monitoring,” Cancer Imagin, 12(3), pp. 530 – 547, 2012

[9] Deepti Mittal, Vinod Kumar, Suresg Chandra Saxnea, Niranjan Khandelwal, Naveen Kalra, “Neural network based focal liver lesion diagnosis using ultrasound images,” Computrized Medical Imaging and Graphics, 35, pp. 315 – 323, 2011

[10] Tae Kyoung Kim, Eunchae Lee, Hyun-Jung Jang, “Imaging findings of mimickers hepatocellular carcinoma,” Clinical and Molecular Hepatology, pp. 21:326 – 342, 2015

[11] X. Ke, J. Zou and Y. Niu, "End-to-End Automatic Image Annotation Based on Deep CNN and Multi-Label Data Augmentation," in IEEE Transactions on Multimedia, vol. 21, no. 8, pp. 2093-2106, Aug. 2019.

[12] Shorten, C., Khoshgoftaar, T.M. A survey on Image Data Augmentation for Deep Learning. J Big Data 6, 60 (2019).

[13] Nur Raihan Razman, Wan Mahani Hafizah Wan Mahmud, Nurul Aimi Shaharuddin, “Filtering Technique in Ultrasound for Kidney, Liver, and Pancreas Image using Matlab”, 2015 IEEE Student Conference on Research and Development, 2015.

[14] Kisuchart Pasipa, Wisuwat Sunhem, “A Comparison between Shallow and Deep Architecture Classfiers on Small Dataset”, 2016 8th International

Conference ON Technology and Electrical Engineering (ICITEE), 2016.
[15] Han, Seung & Park, Gyeong & Lim, Woohyung & Kim, Myoung & Na, Jung-Im & Park, Ilwoo & Chang, Sung, “Deep neural networks show an equivalent and often superior performance to dermatologists in onychomycosis diagnosis: Automatic construction of onychomycosis datasets by region-based convolutional deep neural network”, PLOS ONE, (2018).
[16] Ultrasound images on Hemangioma, Hepatocellular Carcinoma, and Liver Cyst, Aloka Holding Europe Ag, Switzerland [Online]. Available: http://www.Ultrasoundcases.Info.
[17] Rama, J. V. G. et al. “Image pre-processing: enhance the performance of medical image classification using various data augmentation technique.” (2019).
[18] M. Y. Jabarulla and H. Lee, "Evaluating the effect of various speckle reduction filters on ultrasound liver cancer images," 2018 International Conference on Electronics, Information, and Communication (ICEIC), Honolulu, HI, pp. 1-4, 2018.
[19] Hwang, Yoo & Lee, Ju Hwan & Kim, Ga & Jiang, Yuan & Kim, Sung-Min, “Classification of focal liver lesions on ultrasound images by extracting hybrid textural features and using an artificial neural network”, Bio-medical materials and engineering 26. pp. 1599-1611, 2015.

BIODATA PENULIS

Penulis lahir di Jombang, 3 Juli 1998. Penulis merupakan anak ketiga dari empat bersaudara. Penulis menempuh pendidikan sekolah dasar di MI Muhammadiyah 1 Jombang, kemudian meneruskan sekolah menengah pertama di SMPN 2 Jombang, dan melanjutkan ke jenjang sekolah menengah atas di SMAN 1 Jombang. Kemudian penulis menempuh pendidikan tingkat perguruan tinggi ke Departemen Teknik Biomedik Institut Teknologi Sepuluh Nopember, dan aktif sebagai asisten Laboratorium Instrumentasi dan Pengolahan Sinyal Biomedika.

E-mail : upik.rahmah16@mhs.bme.its.ac.id

BIOMEDICAL ENGINEERING ITS
2020