

BAB II

TINJAUAN PUSTAKA

2.1 Kajian Pustaka

Dalam melaksanakan penelitian tentunya diperlukan kajian terhadap penelitian-penelitian terdahulu. Dengan melakukan kajian pada penelitian-penelitian terdahulu tersebut, poin-poin penting yang perlu dilakukan dalam melaksanakan penelitian dapat diketahui. Pada sub bab ini, dilakukan kajian penelitian terhadap penelitian-penelitian terdahulu yang memiliki keterkaitan dengan penelitian yang dilakukan.

Adapun penelitian-penelitian terdahulu tersebut membahas mengenai tema yang memiliki keterkaitan dalam penggunaan *Convolutional Neural Network* (CNN), dan penggunaan *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Berikut merupakan 8 referensi jurnal terdahulu.

1. IMPLEMENTASI CNN DAN SVM UNTUK IDENTIFIKASI PENYAKIT TOMAT VIA DAUN [13].

Penelitian ini bertujuan untuk mengidentifikasi penyakit pada tanaman tomat melalui daun. Penelitian tersebut menerapkan penggunaan CNN dan *Support Vector Machine* (SVM) untuk melakukan klasifikasi penyakit pada daun tomat. Dimana citra yang akan diklasifikasi dilakukan proses transformasi dari *Red Green Blue* (RGB) ke *Hue Saturation Value* (HSV), lalu dari HSV ke *Grayscale*, dan kemudian dilakukan proses ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM). Data hasil proses tersebut selanjutnya diterapkan pada SVM dan CNN.

Hasil yang diperoleh pada penelitian ini menunjukkan metode CNN memperoleh nilai rata-rata *accuracy* 97,5%, *precision* 95,45%, *recall* 95% dan *error* 5%, sedangkan SVM memperoleh nilai rata-rata *accuracy* 95%, *precision* 90,83%, *recall* 90% dan *error* 10%. Persamaan penelitian ini dengan penelitian penulis yaitu pada penggunaan CNN untuk melakukan klasifikasi penyakit. Kemudian perbedaan penelitian tersebut dengan penelitian penulis

yaitu objek yang diteliti berbeda. Penulis meneliti objek citra *x-ray* toraks, sedangkan penelitian tersebut meneliti objek daun tomat. Selain itu penulis menerapkan CLAHE sedangkan penelitian tersebut tidak.

2. KLASIFIKASI KLON TEH BERBASIS DEEP CNN DENGAN RESIDUAL DAN DENSELY CONNECTIONS [14].

Penelitian ini mengusulkan sistem identifikasi klon teh berbasis *deep* CNN dengan menerapkan *skip connection*, yaitu *residual connections* dan *densely connections*. Penelitian ini dilakukan karena klon teh memiliki kemiripan yang sulit dibedakan sehingga menyulitkan non pakar dalam melakukan identifikasi penyediaan dan penanaman bahan tanam pada perkebunan yang memiliki area yang luas. Selain itu penelitian ini menerapkan penggunaan *learning rate* dan *optimizer* pada masing-masing model arsitektur CNN yang digunakan. Model arsitektur DenseNet menggunakan *optimizer* Adam, sedangkan model arsitektur ResNet menggunakan *optimizer* SGD dengan masing-masing *learning rate* yang digunakan sebesar 0,0001.

Hasil yang diperoleh dari penelitian tersebut adalah kinerja sistem dipengaruhi oleh pengaturan *hyperparameter* dan metode penggabungan peta fitur yang diperkenalkan kembali ke lapisan berikutnya melalui koneksi, dimana metode *concatenation* pada *densely connected network* dapat mencapai performa yang lebih baik dibandingkan metode penjumlahan pada *residual connected networks*. Selain itu pada perolehan tingkat akurasi, model arsitektur DenseNet dengan menggunakan *optimizer* Adam memperoleh akurasi lebih tinggi yaitu sebesar 93,28%, sedangkan model arsitektur ResNet dengan menggunakan *optimizer* SGD memperoleh akurasi lebih rendah sebesar 82,69%. Persamaan penelitian tersebut dengan penelitian penulis adalah pada penggunaan CNN untuk melakukan klasifikasi. Kemudian perbedaan penelitian tersebut dengan penelitian penulis yaitu pada fokus penelitian dan metode yang digunakan, dimana penelitian tersebut berfokus pada klasifikasi daun klon teh dengan menggunakan CNN sedangkan penulis

berfokus pada klasifikasi citra *x-ray* toraks dengan menggunakan CLAHE dan CNN.

3. AN EFFICIENT DEEP LEARNING APPROACH TO PNEUMONIA CLASSIFICATION IN HEALTHCARE [15].

Penelitian ini mengusulkan metode untuk melakukan klasifikasi pada citra *x-ray* dada (toraks) yang bertujuan untuk menentukan apakah seseorang terinfeksi pneumonia atau tidak. Penelitian ini kemudian melakukan augmentasi pada data dan menerapkan data tersebut kedalam model arsitektur CNN yang telah dibuat dengan menggunakan citra dengan beberapa ukuran yang berbeda.

Hasil dari penelitian tersebut adalah CNN berhasil memperoleh akurasi *training* tertinggi sebesar 95% dan akurasi validasi tertinggi sebesar 93% dengan menggunakan data citra berukuran 200x200px. Persamaan penelitian tersebut dengan penelitian penulis yaitu pada penggunaan CNN untuk mengklasifikasikan pneumonia pada citra *x-ray* toraks. Kemudian perbedaan penelitian tersebut dengan penelitian penulis adalah pada metode yang digunakan, dimana penelitian tersebut hanya menggunakan CNN untuk melakukan klasifikasi, sedangkan penulis menerapkan CLAHE sebelum dilakukan klasifikasi menggunakan CNN.

4. ANALISIS KOMPARASI METODE PERBAIKAN KONTRAS BERBASIS HISTOGRAM EQUALIZATION PADA CITRA MEDIS [16].

Penelitian ini melakukan perbaikan kontras untuk memunculkan bagian yang tidak terlihat (*hidden feature*) pada citra. Hal tersebut dikarenakan citra dari rontgen tidak selalu memiliki kualitas citra yang baik. Contohnya pada citra *x-ray* yang terlalu gelap atau terdapat bagian tulang yang terlihat samar sehingga citra tidak terlihat jelas. Penelitian ini kemudian melakukan peningkatan kualitas citra dengan melakukan perbaikan kontras menggunakan

metode *Histogram Equalization* (HE), *Adaptive Histogram Equalization* (AHE), dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE).

Hasil dari penelitian tersebut adalah diperoleh nilai pengukuran *Mean Square Error* (MSE) pada HE dengan nilai rata-rata sebesar 759,340, kemudian AHE sebesar 596,900, dan CLAHE sebesar 339,126. Berdasarkan hal tersebut diketahui bahwa CLAHE memperoleh nilai *Mean Square Error* terkecil. Persamaan penelitian tersebut dengan penelitian penulis adalah pada penggunaan CLAHE untuk memperbaiki kualitas citra. Kemudian perbedaan penelitian tersebut dengan penelitian penulis adalah pada fokus penelitian. Penelitian tersebut melakukan komparasi optimasi metode HE, AHE, dan CLAHE pada citra medis, sedangkan penulis melakukan klasifikasi pada citra *x-ray* toraks menggunakan CLAHE dan CNN.

5. PENINGKATAN KUALITAS CITRA X-RAY PARU-PARU MENGGUNAKAN CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION DAN GAUSSIAN FILTER [17].

Penelitian ini melakukan perbaikan citra menggunakan CLAHE pada citra *x-ray* paru-paru. Penelitian ini dilakukan karena pada beberapa kasus kanker paru-paru tidak dapat dideteksi karena tertutup oleh struktur anatomi ataupun karena rendahnya kualitas citra. Untuk menangani kualitas citra yang rendah tersebut dilakukan perbaikan citra, dimana pada tahap awal CLAHE diterapkan pada citra kemudian pada tahap ke dua dilakukan *filtering* dengan menggunakan *Gaussian Filter*. Selain itu penelitian ini juga melakukan perbandingan hasil metode CLAHE dan *Gaussian Filter* dengan metode *Histogram Equalization* (HE) dan *Median filter*.

Hasil yang diperoleh dari penelitian tersebut adalah HE memperoleh nilai *Mean Square Error* (MSE) sebesar 5930,676 dan *Peak Signal to Noise Ratio* (PSNR) sebesar 10,650. Kemudian *Median Filter* memperoleh nilai MSE sebesar 2,0308 dan PSNR sebesar 46,06714. Selanjutnya CLAHE memperoleh nilai MSE sebesar 1189,766 dan PSNR sebesar 17,527. Berikutnya *Gaussian Filter* memperoleh nilai MSE sebesar 0,342405 dan PSNR sebesar 53,23304.

Penelitian tersebut juga secara kualitatif menunjukkan citra hasil peningkatan lebih jelas dan mudah untuk diinterpretasi oleh radiolog. Selain itu hasil yang diperoleh juga menunjukkan bahwa CLAHE dan *Gaussian Filter* lebih baik dalam meningkatkan kualitas citra dibandingkan HE dan *Median Filter*. Persamaan penelitian tersebut dengan penelitian penulis yaitu pada penggunaan CLAHE. Kemudian perbedaan penelitian tersebut dengan penelitian penulis yaitu memiliki fokus penelitian yang berbeda, dimana penelitian penulis melakukan klasifikasi pada citra *x-ray* toraks dengan menerapkan CLAHE dan CNN sedangkan penelitian tersebut berfokus pada peningkatan kualitas citra *x-ray* paru-paru menggunakan CLAHE dan *Gaussian Filter* serta HE dan *Median Filter*.

6. PERBANDINGAN METODE CONTRAST ENHANCEMENT PADA CITRA CT-SCAN KANKER PARU-PARU [18].

Penelitian ini melakukan perbandingan metode *contrast enhancement* pada citra *CT-Scan* kanker paru-paru dengan menggunakan *Histogram Equalization* (HE) dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) serta menerapkan *Median Filter* untuk mereduksi derau. *CT-Scan* merupakan salah satu cara mendiagnosis kanker paru-paru, dimana *CT-Scan* mampu menghasilkan gambaran secara detail pada setiap bagian tubuh manusia. Namun, pada beberapa kasus nodul kanker sering tidak ditemukan karena tertutupi oleh struktur anatomi atau akibat rendahnya kualitas citra. Oleh karena itu penelitian ini memperbaiki kualitas citra dengan meningkatkan kontras citra dan mengurangi tingkat derau untuk membantu dalam mendiagnosis kanker pada citra *CT-Scan*.

Hasil yang diperoleh adalah HE memperoleh nilai rata-rata akurasi MSE sebesar 949,960 dan PSNR sebesar 198,853, kemudian CLAHE memperoleh nilai rata-rata akurasi MSE sebesar 653,434 dan PSNR sebesar 245,547. Secara kualitatif dan kuantitatif metode CLAHE lebih baik dibandingkan metode HE dalam melakukan peningkatan kualitas citra untuk mendeteksi nodul kanker paru-paru. Persamaan penelitian tersebut dengan penelitian

penulis adalah pada penggunaan CLAHE untuk meningkatkan kualitas citra. Kemudian perbedaan penelitian tersebut dengan penelitian penulis adalah pada fokus penelitian dan metode lain yang digunakan. Penulis berfokus pada melakukan klasifikasi pada citra *x-ray* toraks dengan menggunakan CLAHE dan CNN, sedangkan penelitian tersebut berfokus pada peningkatan kualitas citra *CT-Scan* kanker paru-paru dengan menggunakan HE, CLAHE, dan *Median Filter*.

7. THREE-CLASS MAMMOGRAM CLASSIFICATION BASED ON DESCRIPTIVE CNN FEATURES [19].

Penelitian ini mengusulkan metode untuk mengklasifikasikan kanker payudara kedalam 3 kelas, yaitu normal, ganas, dan jinak. Selain itu penelitian ini menerapkan kombinasi *Convolutional Neural Network-Discrete Wavelet* (CNN-DW) dan *Convolutional Neural Network-Curvelet Transform* (CNN-CT) untuk melakukan klasifikasi. Kemudian untuk meningkatkan kontras pada citra, CLAHE diterapkan pada dataset.

Hasil penelitian tersebut adalah CNN-DW memperoleh akurasi 81,83% dan CNN-CT memperoleh akurasi 83,74%, dimana hal tersebut menunjukkan bahwa penerapan CLAHE dan CNN-CT mampu memperoleh akurasi klasifikasi yang baik. Persamaan penelitian tersebut dengan penelitian penulis yaitu pada penerapan CLAHE dan CNN. Kemudian perbedaan penelitian tersebut dengan penulis adalah pada metode dan objek yang diteliti. Pada penelitian tersebut peneliti menggunakan kombinasi CNN-DW dan CNN-CT untuk melakukan klasifikasi pada data yang telah dilakukan perbaikan citra menggunakan CLAHE pada citra mammogram sedangkan penulis menggunakan CNN pada citra yang telah dilakukan perbaikan citra menggunakan CLAHE pada citra *x-ray* toraks.

8. CLASSIFICATION OF BREAST MICROSCOPIC IMAGING USING HYBRID CLAHE-CNN DEEP ARCHITECTURE [20].

Penelitian ini melakukan klasifikasi kanker pada citra mikroskop payudara menggunakan CNN dan CLAHE. Pada penelitian tersebut peneliti mengklasifikasikan kanker payudara kedalam 2 kelas, yaitu jinak atau ganas. Penelitian ini dilakukan karena pemeriksaan kanker payudara memakan cukup waktu dan memerlukan pemindaian jaringan dengan berbagai tingkat pembesaran untuk memperoleh diagnosis yang akurat. Penelitian ini kemudian melakukan klasifikasi citra kedalam arsitektur dengan menggunakan 2 metode. Metode pertama adalah menerapkan citra kedalam model CNN tanpa menerapkan *preprocessing*. Selanjutnya metode kedua adalah menerapkan citra kedalam model CNN dengan menerapkan *preprocessing* dengan menggunakan CLAHE dan *Watershed*.

Hasil dari penelitian tersebut adalah model CNN tanpa dilakukan *preprocessing* memperoleh tingkat akurasi sebesar 86,24%, dan model CNN dengan dilakukan *preprocessing* memperoleh tingkat akurasi sebesar 90,39%. Berdasarkan hal tersebut dapat diketahui bahwa penerapan *preprocessing* dengan menggunakan CLAHE dan *Watershed* mampu meningkatkan akurasi perolehan yang diperoleh sebesar 3%. Persamaan penelitian tersebut dengan penelitian penulis yaitu pada penerapan CLAHE dan CNN. Kemudian perbedaan penelitian tersebut dengan penelitian penulis yaitu pada objek yang diteliti, dimana penulis melakukan klasifikasi pada citra *x-ray* toraks sedangkan penelitian tersebut melakukan klasifikasi pada citra mikroskop payudara.

Penelitian-penelitian diatas merupakan penelitian-penelitian yang dijadikan referensi pada penelitian ini. Ringkasan penelitian terdahulu tersebut dapat dilihat pada tabel 2.1 sebagai berikut.

Tabel 2.1 Penelitian-Penelitian Terdahulu.

Judul	Tujuan	Metode	Hasil	Keterangan
IMPLEMENTASI CNN DAN SVM	Mengidentifikasi penyakit	<i>Convolutional Neural</i>	Hasil pengujian menunjukkan	CNN memperoleh

UNTUK IDENTIFIKASI PENYAKIT TOMAT VIA DAUN, 2019, [13].	pada tanaman tomat melalui daun	<i>Network (CNN)</i> dan <i>Support Vector Machine (SVM)</i> .	metode CNN memperoleh nilai rata-rata <i>accuracy</i> 97,5%, <i>precision</i> 95,45%, <i>recall</i> 95% dan <i>error</i> 5%, sedangkan SVM memperoleh nilai rata-rata <i>accuracy</i> 95%, <i>precision</i> 90,83%, <i>recall</i> 90% dan <i>error</i> 10%.	tingkat rata-rata akurasi yang lebih tinggi dari pada tingkat rata-rata akurasi yang diperoleh SVM.
KLASIFIKASI KLON TEH BERBASIS DEEP CNN DENGAN RESIDUAL DAN DENSELY CONNECTIONS, 2020, [14].	Mengusulkan sistem identifikasi klon teh berbasis <i>deep CNN</i>	<i>Convolutional Neural Network (CNN)</i> dengan menerapkan <i>Skip Connection</i>	Studi yang dilakukan menunjukkan bahwa kinerja sistem dipengaruhi oleh pengaturan <i>hyperparameter</i> dan metode penggabungan peta fitur yang diperkenalkan kembali ke lapisan berikutnya melalui koneksi, dimana metode <i>concatenation</i> pada <i>densely connected network</i> dapat mencapai performa yang lebih baik dibandingkan metode penjumlahan pada <i>residual connected networks</i> .	Dengan masing-masing model menggunakan <i>learning rate</i> sebesar 0,0001. DenseNet dengan <i>optimizer Adam</i> memperoleh akurasi lebih tinggi yaitu sebesar 93,28%, dari pada ResNet dengan <i>optimizer SGD</i> yang memperoleh akurasi lebih rendah sebesar 82,69%.
AN EFFICIENT DEEP LEARNING APPROACH TO PNEUMONIA CLASSIFICATION IN HEALTHCARE, 2019, [15].	Melakukan klasifikasi pneumonia pada citra <i>x-ray</i> dada	<i>Convolutional Neural Network (CNN)</i> .	Model arsitektur CNN memperoleh akurasi <i>training</i> tertinggi sebesar 95% dan akurasi validasi tertinggi sebesar 93% dengan menggunakan data citra berukuran 200x200px.	CNN mampu memperoleh tingkat akurasi terbaik pada gambar dengan ukuran 200x200px
ANALISIS KOMPARASI METODE PERBAIKAN KONTRAS BERBASIS	Melakukan perbaikan kontras untuk memunculkan bagian yang tidak terlihat	<i>Histogram Equalization (HE)</i> , <i>Adaptive Histogram Equalization</i>	Setelah dilakukan pengukuran MSE, diperoleh nilai rata-rata MSE HE sebesar 759,340, AHE sebesar	CLAHE memperoleh nilai <i>Mean Square Error</i> terkecil dibandingkan metode lainnya.

HISTOGRAM EQUALIZATION PADA CITRA MEDIS, 2017, [16].	(<i>hidden feature</i>) pada citra	(AHE), dan <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE)	596,900, dan CLAHE sebesar 339,126.	
PENINGKATAN KUALITAS CITRA X-RAY PARU-PARU MENGGUNAKAN CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION DAN GAUSSIAN FILTER, 2016, [17]	Melakukan perbaikan citra menggunakan CLAHE pada citra <i>x-ray</i> paru-paru	<i>Histogram Equalization</i> dan <i>Median Filter</i> , serta <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE) dan <i>Gaussian Filter</i>	HE memperoleh nilai MSE sebesar 5930,676 dan PSNR sebesar 10,650. <i>Median Filter</i> memperoleh nilai MSE sebesar 2,0308 dan PSNR sebesar 46,06714. CLAHE memperoleh nilai MSE sebesar 1189,766 dan PSNR sebesar 17,527. <i>Gaussian Filter</i> memperoleh nilai MSE sebesar 0,342405 dan PSNR sebesar 53,23304.	CLAHE dan <i>Gaussian Filter</i> mampu meningkatkan kualitas citra dengan lebih baik dibandingkan HE dan <i>Median Filter</i> . Selain itu citra hasil peningkatkan lebih jelas serta mudah untuk diinterpretasi oleh radiolog.
PERBANDINGAN METODE CONTRAST ENHANCEMENT PADA CITRA CT-SCAN KANKER PARU-PARU, 2020, [18].	Melakukan perbandingan metode <i>contrast enhancement</i> pada citra <i>CT-Scan</i> kanker paru-paru	<i>Histogram Equalization</i> (HE), <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE), dan <i>Median filter</i>	HE memperoleh nilai rata-rata akurasi MSE sebesar 949,960 dan PSNR sebesar 198,853, kemudian CLAHE memperoleh nilai rata-rata akurasi MSE sebesar 653,434 dan PSNR sebesar 245,547.	Secara kualitatif dan kuantitatif, metode CLAHE lebih baik dibandingkan metode HE dalam melakukan peningkatan kualitas citra untuk mendeteksi nodul kanker paru-paru.
THREE-CLASS MAMMOGRAM CLASSIFICATION BASED ON DESCRIPTIVE CNN FEATURES, 2017, [19].	Mengklasifikasi kanker payudara kedalam 3 kelas, yaitu normal, ganas, dan jinak	<i>Convolutional Neural Network-Discr ete Wavelet</i> (CNN-DW), <i>Convolutional Neural Network-Curvelet Transform</i> (CNN-CT), dan <i>Contrast Limited Adaptive Histogram</i>	Setelah dilakukan pengujian CNN-DW memperoleh tingkat rata-rata akurasi sebesar 81,83% dan CNN-CT memperoleh tingkat rata-rata akurasi sebesar 83,74%	Penerapan CLAHE dan CNN-CT mampu memperoleh akurasi klasifikasi yang baik

		<i>Equalization (CLAHE).</i>		
CLASSIFICATION OF BREAST MICROSCOPIC IMAGING USING HYBRID CLAHE-CNN DEEP ARCHITECTURE, 2019, [20].	Melakukan klasifikasi kanker pada citra mikroskop payudara	<i>Contrast Limited Adaptive Histogram Equalization (CLAHE), Watershed, dan Convolutional Neural Network (CNN).</i>	Model CNN tanpa dilakukan <i>preprocessing</i> memperoleh tingkat akurasi sebesar 86,24%, dan Model CNN dengan dilakukan <i>preprocessing</i> menggunakan CLAHE memperoleh tingkat akurasi sebesar 90,39%.	Model CNN dengan menerapkan <i>preprocessing</i> menggunakan CLAHE dan <i>Watershed</i> memperoleh tingkat akurasi yang lebih tinggi sebesar 3%

Penelitian yang dijadikan acuan utama dalam mengembangkan penelitian ini adalah penelitian [15] dan [19], dimana metode-metode yang digunakan pada kedua penelitian tersebut dijadikan referensi oleh penulis dalam mengembangkan skema penelitian yang dilakukan. Pada penelitian [15], salah satu metode yang dijadikan acuan dalam mengembangkan penelitian adalah pada penerapan CNN dengan menggunakan beberapa ukuran kecil ke dalam model arsitektur yang digunakan. Hal tersebut dikarenakan dengan menerapkan metode tersebut dapat diketahui bahwa model dapat memperoleh hasil terbaik dengan ukuran gambar tertentu. Namun meskipun penelitian [15] memiliki kesamaan pada tema dan metode yang digunakan pada penelitian ini, metode penelitian yang digunakan tidak sepenuhnya sama. Penelitian [15] tidak menggunakan penerapan CLAHE sedangkan penelitian ini menggunakan penerapan CLAHE dalam melakukan penelitian.


Kemudian pada penelitian [19], salah satu metode yang dijadikan acuan dalam mengembangkan penelitian adalah pada penggunaan *Confusion Matrix* untuk menghitung akurasi yang diperoleh model dalam melakukan klasifikasi. Penelitian [19] juga menerapkan penggunaan CNN dan CLAHE dalam melakukan klasifikasi, dimana metode tersebut juga digunakan pada penelitian ini. Namun walaupun penelitian [19] juga menggunakan metode penelitian yang sama dengan penelitian ini, metode penelitian yang dilakukan tidak sepenuhnya sama dan terdapat perbedaan pada tema penelitian yang dilakukan. Penelitian tersebut

berfokus pada mengklasifikasikan kanker payudara pada citra mammogram, sedangkan penelitian ini berfokus pada mengklasifikasikan pneumonia pada citra *x-ray* toraks. Oleh karena itu penelitian [15] dan [19] dipilih sebagai acuan utama dalam mengembangkan skema penelitian yang dilakukan dikarenakan kedua penelitian tersebut memiliki keterkaitan dengan penelitian.

2.2 Dasar Teori

2.2.1. Pneumonia

Pneumonia merupakan suatu bentuk infeksi pernapasan akut yang menyerang paru-paru. Paru-paru terdiri dari kantung-kantung kecil yang disebut alveoli dan akan dipenuhi udara ketika seseorang bernapas. Tetapi ketika seseorang menderita pneumonia, alveoli akan dipenuhi dengan nanah dan cairan. Hal tersebut menyebabkan penderita merasakan nyeri saat bernapas dan asupan oksigen terbatas [3]. Contoh pneumonia pada paru-paru dapat dilihat pada gambar 2.1 berikut.



Gambar 2.1 Pneumonia Pada Paru-Paru [21].

2.2.1.1 Gejala-Gejala

Gejala pneumonia dapat bervariasi dari sangat ringan sampai sangat parah. Gejala-gejala pneumonia diantaranya adalah sebagai berikut:

1. Batuk
2. Demam

3. Sesak napas
4. Nafas cepat dan pendek
5. Nyeri dada
6. Tidak nafsu makan, lesu, dan kelelahan
7. Pusing [22].

2.2.1.2 Diagnosis

Ketika seseorang dicurigai menderita pneumonia, maka akan dilakukan berbagai tes diagnostik untuk memastikan diagnosis. Tes diagnostik ini diantaranya adalah sebagai berikut:

1. Tes darah untuk mengidentifikasi infeksi dan kuman penyebab penyakit.
2. Rontgen dada (toraks) untuk menemukan lokasi dan luasnya peradangan pada paru-paru.
3. Pulse oksimetri untuk mengukur tingkat oksigen dalam darah.
4. Tes dahak pada sampel lendir yang diambil setelah batuk untuk menemukan sumber infeksi.
5. *CT Scan* dada untuk memperoleh gambaran paru-paru yang lebih baik serta mencari abses maupun komplikasi lainnya [22].

2.2.2 Citra Digital

Citra merupakan suatu representasi, atau imitasi dari suatu objek. Citra sendiri terbagi menjadi 2 jenis, yaitu citra digital dan citra analog. Citra digital merupakan citra yang dapat diolah oleh komputer, sedangkan citra analog merupakan citra yang memiliki sifat kontinu [23].

2.2.2.1 Elemen-Elemen Citra Digital

a. Kecerahan

Kecerahan adalah tingkat intensitas cahaya yang dipancarkan oleh piksel dari citra yang dapat ditangkap oleh sistem penglihatan.

Kecerahan pada piksel didalam citra tersebut merupakan intensitas rata-rata dari suatu area yang melingkupinya.

b. Kontras

Kontras menunjukkan suatu sebaran terang dan gelap pada sebuah citra. Citra yang baik merupakan citra yang memiliki komposisi gelap dan terang yang tersebar secara merata.

c. Warna

Warna adalah persepsi yang ditangkap sistem visual terhadap panjang gelombang cahaya yang dipantulkan oleh objek.

d. Bentuk


Bentuk merupakan suatu properti intrinsik dari objek 3D, dengan pengertian bahwa bentuk adalah suatu properti intrinsik utama bagi sistem visual manusia.

e. Tekstur

Tekstur merupakan suatu keteraturan pola-pola tertentu yang terbentuk dari susunan piksel-piksel yang terdapat dalam citra digital [23].

2.2.2.2 Jenis Citra Digital


2.2.2.2.1 Citra Biner (Monokrom)



Gambar 2.2 Citra Biner [24].

Citra biner merupakan citra yang setiap pikselnya dinyatakan hanya dari dua nilai kemungkinan, yaitu 0 dan 1. Nilai 0 menyatakan warna hitam sedangkan nilai 1 menyatakan warna putih [25]. Contoh citra biner dapat dilihat pada gambar 2.2 diatas.

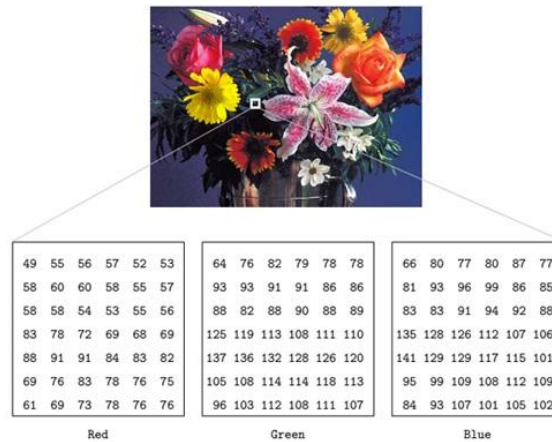
2.2.2.2.2 Citra *Grayscale* (Skala Keabuan)



Gambar 2.3 Citra *Grayscale* [24].

Citra *grayscale* merupakan citra yang menangani gradiasi warna hitam dan putih yang mana menghasilkan efek warna abu-abu. Seperti yang dapat dilihat pada gambar 2.3, warna pada citra jenis ini dinyatakan dengan intensitas. Intensitas tersebut memiliki rentang antara 0 sampai dengan 255, dimana nilai 0 menyatakan warna hitam dan nilai 255 menyatakan warna putih [25].


2.2.2.2.3 Citra Berwarna (*True Color*)



Gambar 2.4 Citra RGB [24].

Citra berwarna atau bisa disebut juga *true color* merupakan citra yang memiliki 3 buah kanal warna didalamnya. Pada umumnya jenis citra tersebut terbentuk dari komponen warna merah (*Red*), hijau (*Green*), dan biru (*Blue*) yang dimodelkan kedalam ruang warna RGB [26] seperti yang dapat dilihat pada gambar 2.4 diatas. Namun, selain ruang warna RGB terdapat juga ruang warna lain pada citra berwarna. Contohnya adalah ruang warna Lab.

2.2.2.2.3.1 Ruang Warna Lab



Gambar 2.5 Ruang Warna Lab [27].

Ruang warna Lab memiliki 3 komponen warna, dimana L menyatakan *luminance* (cahaya), sedangkan a dan b menyatakan dimensi warna yang berlawanan. Pada gambar 2.5 diatas dapat dilihat bahwa intensitas warna ditentukan dengan koordinat L, +a, -a, +b, dan -b. Notasi L: 0 (hitam), dan L: 100 (putih) menyatakan cahaya pantul yang menghasilkan warna akromatik putih, abu-abu, dan hitam.

Kemudian notasi a menunjukkan warna kromatik campuran merah-hijau dengan +a dari rentang nilai 0 sampai dengan +80 menyatakan warna merah, dan -a dari rentang nilai 0 sampai dengan -80 menyatakan warna hijau.

Selanjutnya notasi b menunjukkan warna kromatik campuran biru-kuning dengan +b dari rentang nilai 0 sampai dengan +70 menyatakan warna kuning, dan -b dari rentang nilai 0 sampai dengan -70 menyatakan warna biru [28].

2.2.3 Perbaikan Citra

2.2.3.1 *Histogram Equalization (HE)*

Histogram merupakan suatu representasi grafik yang menyatakan distribusi intensitas piksel atau nilai-nilai warna pada citra. *Histogram Equalization* bertujuan untuk meratakan histogram sehingga derajat keabuan yang terdapat pada citra memiliki jumlah piksel yang relatif sama. *Histogram Equalization* sendiri merupakan sebuah proses dimana distribusi tingkat keabuan pada sebuah citra dirubah merata [29]. Rumus umum *Histogram Equalization* adalah sebagai berikut.

$$h(v) = \text{round} \left(\frac{CDF(v) - CDF_{\min}}{(M \times N) - CDF_{\min}} \times (L - 1) \right) \dots\dots\dots (2.1)$$

Keterangan:

v : nilai piksel yang dicari.

Round : operasi pembulatan nilai.

CDF (v) : fungsi distribusi kumulatif nilai v .

CDF min : nilai minimum distribusi kumulatif.

$M \times N$: jumlah total piksel gambar.

L : jumlah tingkat keabuan yang digunakan (256) [30].

2.2.3.2 Adaptive Histogram Equalization (AHE)

Adaptive Histogram Equalization merupakan suatu metode perbaikan kontras pada citra dengan melakukan peningkatan kontras secara lokal pada citra [31]. Berbeda dari *Histogram Equalization* yang hanya menggunakan satu histogram terhadap keseluruhan gambar, *Adaptive Histogram Equalization* membagi citra kedalam beberapa blok (*tiles*) berukuran $n \times n$. Kemudian melakukan *Histogram Equalization* pada masing masing blok tersebut. Selain itu ukuran blok dapat bervariasi dan setiap ukuran akan memberikan hasil yang berbeda-beda [32] [33]. Rumus *Adaptive Histogram Equalization* adalah sebagai berikut.

$$K_0 = \text{round} \left(\frac{C_i \times (2^k - 1)}{M \times N} \right) \dots\dots\dots(2.2)$$

Keterangan:

C_i : nilai kumulatif skala abu-abu i dari gambar.

K_0 : nilai skala abu-abu hasil *histogram equalization*.

Round : operasi pembulatan nilai.

k : jumlah bit skala citra.

M : tinggi citra.

N : lebar citra [33].

2.2.3.3 Contrast Limited Adaptive Histogram Equalization (CLAHE)

Contrast Limited Adaptive Histogram Equalization merupakan generalisasi dari metode *Adaptive Histogram Equalization* [17]. Metode ini melakukan perbaikan kontras citra dengan meningkatkan kontras lokal citra. Lokal citra tersebut diperoleh dengan membentuk grid simetris pada citra yang disebut *region size*. Selain itu permasalahan peningkatan kontras yang berlebihan dapat diatasi dengan menggunakan CLAHE, yaitu dengan memberikan nilai batas pada histogram. Nilai batas ini disebut dengan *clip limit* yang menyatakan tinggi maksimum dari sebuah histogram [33]. Rumus CLAHE adalah sebagai berikut.

$$\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (S_{\max} - 1) \right) \dots \dots \dots (2.3)$$

Keterangan:

M : luas *region size*

N : nilai *grayscale* (256)

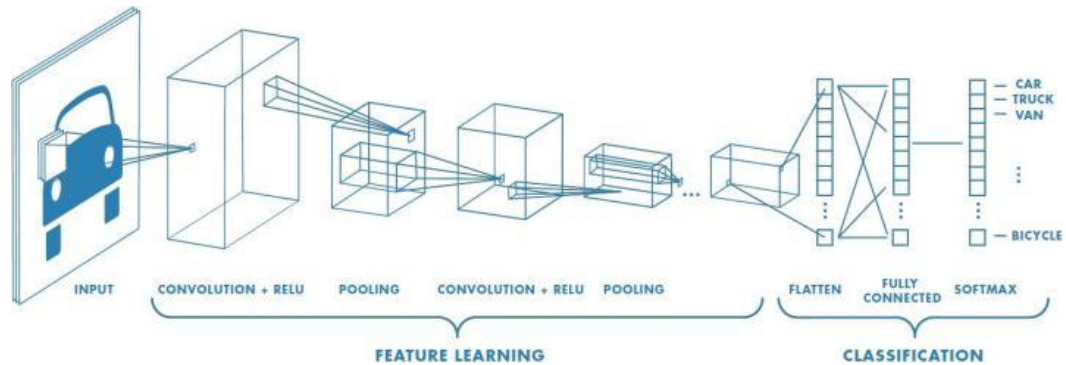
S_{max} : kemiringan maksimum.

α : *clip factor* [30][33].

2.2.4 Convolutional Neural Network (CNN)


Convolutional Neural Network merupakan struktur jaringan *multi-layer* yang terdiri dari kumpulan tumpukan jaringan *convolution neural* tunggal yang dapat dilatih. Tiap jaringan *neural* tunggal terdiri dari tiga tahap dasar, yaitu konvolusi fitur ekstraksi, aktivasi *non-linear*, dan *down-sampling*. Struktur dasar CNN umumnya terdiri dari dua *layer*. *Layer* pertama merupakan *layer* ekstraksi fitur, dan *layer* kedua merupakan *layer feature mapping* [34]. CNN sendiri merupakan pengembangan dari *Multi Layer Perceptron* (MLP) yang dirancang untuk mengolah data dua dimensi [9]. Selain itu CNN juga termasuk kedalam *Deep Neural Network* (DNN)

dikarenakan CNN memiliki jaringan yang dalam dan berlapis-lapis [10]. Proses-proses dasar pada CNN dapat dilihat pada gambar 2.6 berikut.



Gambar 2.6 Proses CNN [35].

2.2.4.1 Convolution Layer




Gambar 2.7 Convolution Layer [36].

Convolutional Layer merupakan blok bangunan inti *convolutional network* dimana sebagian besar komputasi berat dilakukan. Tujuan utama *convolution layer* adalah untuk mengekstrak fitur dari data *input* yang berupa citra. *Convolution* mempertahankan hubungan spasial antar piksel dengan mempelajari fitur citra menggunakan kotak kecil dari citra *input*. Citra *input* dilakukan konvolusi dengan menggunakan sekumpulan *neuron* yang dapat dipelajari. Hal tersebut menghasilkan *feature map* atau *activation map* pada citra *output* seperti yang dapat dilihat pada gambar 2.7, dan kemudian hasil tersebut diberikan sebagai data *input* untuk *convolution layer* selanjutnya [37].

2.2.4.2 Activation Function

Fungsi aktivasi merupakan fungsi *non-linear* yang memungkinkan sebuah jaringan syaraf tiruan untuk dapat melakukan transformasi data input menjadi dimensi yang lebih tinggi sehingga dapat dilakukan pemotongan *hyperlane* sederhana yang memungkinkan untuk dilakukan klasifikasi [9]. Terdapat beberapa fungsi aktivasi pada *neural network*, diantaranya adalah sebagai berikut.

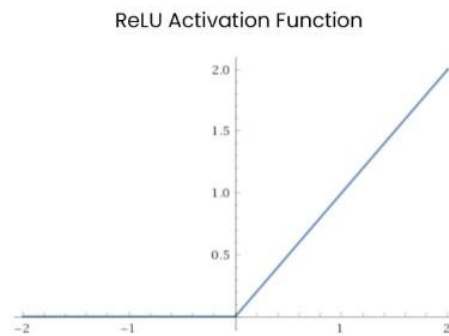
2.2.4.2.1 Fungsi Aktivasi Softmax



Gambar 2.8 Softmax [38].

Fungsi aktivasi softmax merupakan fungsi yang akan melakukan perhitungan probabilitas untuk setiap kelas, dan kelas yang memiliki probabilitas tertinggi akan dijadikan sebagai hasil prediksi [39]. Selain itu softmax juga merupakan bentuk lain dari *logistic regression* yang dapat digunakan untuk mengklasifikasi lebih dari 2 kelas [40]. Grafik fungsi aktivasi softmax dapat dilihat pada gambar 2.8 diatas.


2.2.4.2.2 Fungsi Aktivasi ReLU



Gambar 2.9 ReLU [38].

Rectified Linear Unit (ReLU) merupakan fungsi aktivasi yang memiliki perhitungan sederhana dimana ketika elemen bernilai negatif maka nilainya akan dirubah menjadi 0 dan tidak menggunakan operasi eksponensial, perkalian, maupun pembagian. Berdasarkan karakteristik tersebut, ReLU memiliki kelebihan ketika dihadapi dengan jaringan yang memiliki jumlah *neuron* yang banyak sehingga waktu *training* dan *testing* dapat dikurangi dengan signifikan [41]. Grafik fungsi aktivasi ReLU dapat dilihat pada gambar 2.9.

2.2.4.3 Pooling Layer

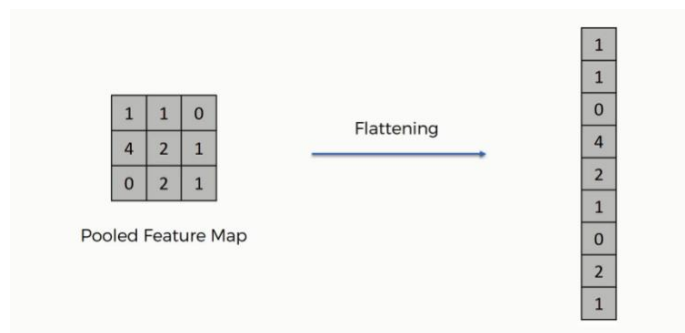


Gambar 2.10 Pooling Layer [42].

Pooling Layer mengurangi dimensi tiap *activation map* tetapi tetap memiliki informasi terpenting. Pada *pooling layer* citra input

dibagi menjadi suatu kumpulan persegi yang tidak saling tumpang tindih. Kemudian pada setiap *region* tersebut dilakukan *down-sampling* dengan menggunakan operasi *non-linear* seperti *average* atau *maximum* [37]. Seperti yang dapat dilihat pada gambar 2.10, pada operasi *average* nilai yang diambil merupakan nilai rata-rata dari tiap *region* sedangkan pada operasi *maximum* nilai yang diambil merupakan nilai terbesar dari tiap *region* [43].

2.2.4.4 Flattening



Gambar 2.11 *Flattening* [44].

Gambar 2.11 merupakan contoh dari penerapan *flattening*. *Flattening* adalah sebuah operasi membentuk ulang fitur (matriks) kedalam vektor satu dimensi. Pada proses ini *Flattening* merubah *feature map* dari *layer* sebelumnya kedalam vektor satu dimensi agar *feature map* tersebut dapat digunakan sebagai *input* dari *Fully Connected Layer* [45] [46].

2.2.4.5 Fully Connected Layer

Fully Connected Layer menunjukkan bahwa seluruh *filter* pada *layer* sebelumnya terhubung dengan seluruh *filter* pada *layer* berikutnya. Tujuan diterapkannya *Fully Connected Layer* adalah untuk mengklasifikasikan citra kedalam berbagai kelas berdasarkan data *training*. *Fully Connected Layer* dianggap sebagai *pooling layer* terakhir yang akan memberikan fitur kepada *classifier* [37].

2.2.5 Python

Python merupakan bahasa pemrograman multiguna yang dapat dengan mudah dipelajari dan bersifat *open source*. Python juga dapat berjalan pada berbagai platform sistem operasi diantaranya yaitu, *windows*, *linux*, dan *mac os* [47]. Selain itu python juga merupakan bahasa pemrograman yang mendukung model pemrograman fungsional, berorientasi objek, maupun prosedural [48].

2.2.6 Keras

Keras merupakan API *deep learning* yang ditulis dalam bahasa python yang berjalan pada platform *machine learning* tensorflow. Keras sendiri dikembangkan dengan fokus untuk memungkinkan eksperimen cepat. Selain itu Keras menyediakan abstraksi penting dan elemen penyusun untuk mengembangkan dan memberikan solusi *machine learning* dengan iterasi tinggi [49].

2.2.7 Confusion Matrix

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 2.12 *Confusion Matrix* [50].

Confusion Matrix merupakan metode yang dapat digunakan untuk melakukan pengukuran kinerja suatu metode klasifikasi. *Confusion Matrix* melakukan pengukuran kinerja dengan menggunakan 4 istilah yang mempresentasikan hasil proses klasifikasi seperti yang dapat dilihat pada gambar 2.12. 4 istilah tersebut diantaranya yaitu *True Positive* (TP), *True*

Negative (TN), *False Positive* (FP), dan *False Negative* (FN) [51]. TP merupakan jumlah data *positive* yang diprediksi *positive*, FP merupakan jumlah data *negative* yang diprediksi *positive*, TN merupakan jumlah data *negative* yang diprediksi *negative*, dan FN merupakan jumlah data *positive* yang diprediksi *negative*. Persamaan menghitung akurasi dengan menggunakan *Confusion Matrix* adalah sebagai berikut [19].

$$Akurasi = \frac{TN+TP}{FP+FN+TP+TN} \dots\dots\dots(2.4)$$