

BAB II

TINJAUAN PUSTAKA

2.1 Paru-Paru

Paru-paru merupakan organ respirasi (pernapasan) yang berhubungan dengan sistem pernapasan dan sirkulasi (peredaran darah) dalam tubuh vertebrata yang bernapas dengan udara. Fungsinya adalah menukar oksigen dari udara dengan karbon dioksida dari darah. Jika paru-paru terganggu fungsinya, maka kesehatan tubuh manusia bisa terpengaruh secara keseluruhan (Alina Bradford, 2018). Jaringan penyusun organ paru-paru yang utama adalah pleura. Pleura merupakan salah satu jenis jaringan tipis yang melapisi dinding organ paru-paru. Lapisan pleura yang tipis dan licin ini berguna sebagai pelumas sehingga paru-paru dapat lebih mudah bergerak (mengembang dan mengempis) saat sedang mengembang dan berkontraksi. Lapisan ini menjaga organ paru-paru supaya tidak terluka atau mengalami kerusakan (Tim Konten Medis, 2024).

Ada beberapa gejala yang dapat timbul saat mengalami gangguan paru-paru seperti sesak napas, batuk, dan mengi. Dan ada juga penyakit paling umum yang menyerang pada organ paru-paru diantaranya

a. Pneumonia

Pneumonia adalah peradangan paru-paru yang disebabkan oleh infeksi. Pneumonia bisa menimbulkan gejala yang ringan hingga berat. Beberapa gejala yang umum dialami penderita pneumonia adalah batuk berdahak, demam, dan sesak napas. Pneumonia juga dikenal dengan istilah paru-paru basah. Pada kondisi ini, infeksi menyebabkan peradangan pada kantong-kantong udara (alveoli) di salah satu atau kedua paru-paru. Akibatnya, alveoli

dipenuhi cairan atau nanah sehingga membuat penderitanya sulit bernapas (dr. Pittara, 2022).

b. Tuberkulosis (TBC)

Tuberkulosis adalah infeksi bakteri yang disebabkan oleh *Mycobacterium tuberculosis* yang menyerang dan merusak jaringan tubuh. Bakteri dapat ditularkan melalui saluran udara. TBC umumnya akan menyerang paru-paru, tetapi juga berisiko menyebar ke kelenjar getah bening, tulang, sistem saraf pusat, jantung, dan organ lainnya (dr. Fadhli Rizal Makarim, 2023)

c. *Coronavirus Disease-19* (Covid-19)

Coronavirus merupakan keluarga besar virus yang menyebabkan penyakit pada manusia dan hewan. Pada manusia biasanya menyebabkan penyakit infeksi saluran pernapasan, mulai flu biasa hingga penyakit yang serius seperti *Middle East Respiratory Syndrome* (MERS) dan Sindrom Pernafasan Akut Berat/ *Severe Acute Respiratory Syndrome* (SARS). Coronavirus jenis baru yang ditemukan pada manusia sejak kejadian luar biasa muncul di Wuhan Cina, pada Desember 2019, kemudian diberi nama *Severe Acute Respiratory Syndrome Coronavirus 2* (SARS-COV2), dan menyebabkan penyakit *Coronavirus Disease-2019* (COVID-19) (Lu et al., 2020).

2.2 Klasifikasi

Klasifikasi adalah suatu bentuk dari analisis data yang mengekstraksi model untuk menggambarkan mengategorikan atau kelas dari data. Dalam klasifikasi, pengklasifikasian atau model yang dibangun untuk memprediksi label kelas (kategorial), misalnya sebuah cuaca hujan atau terik. Kategori-kategori ini dapat

diwakilkan oleh nilai diskrit, pengurutan antar nilai tidak mempunyai arti. Klasifikasi sendiri terdiri atas dua langkah atau dua proses, proses yang pertama adalah proses pembelajaran (proses pengklasifikasian dibangun), sedangkan proses kedua adalah proses klasifikasi (model yang dibangun digunakan untuk memprediksi label dari data yang telah diberikan) (Han et al., 2011).

2.3 Artificial Intelligence

Kecerdasan Buatan atau *Artificial Intelligence* (AI) adalah teknik yang digunakan untuk meniru kecerdasan yang dimiliki oleh makhluk hidup maupun benda mati untuk menyelesaikan sebuah persoalan. Kecerdasan buatan (*artificial intelligence*) merupakan sebuah studi tentang bagaimana membuat komputer melakukan hal-hal yang pada saat ini dilakukan lebih baik oleh manusia (Elaine et al., 2010).

Menurut (Zaharchuk et al., 2018) salah satu definisi untuk *Artificial Intelligence* adalah setiap metode komputer yang melakukan tugas-tugas yang biasanya membutuhkan kecerdasan manusia. *Machine Learning* adalah salah satu jenis kecerdasan buatan yang mengembangkan algoritma untuk memungkinkan komputer belajar dari data yang ada tanpa pemrograman eksplisit.

Sistem kecerdasan buatan dapat melibatkan penggunaan algoritma kompleks, jaringan saraf tiruan, dan teknik pembelajaran mesin untuk menganalisis data, mengenali pola, dan membuat keputusan. Dengan demikian, kecerdasan buatan memiliki potensi untuk mengeksekusi tugas-tugas seperti pengenalan wajah, pemrosesan bahasa alami, pengambilan keputusan. Sistem kecerdasan komputer ini

bisa dilatih atau dilakukan pembelajaran terhadap komputer itu sendiri atau biasa disebut dengan *machine learning*.

2.3.1 *Deep Learning*

Deep Learning merupakan bagian dari *machine learning* dengan banyak lapisan untuk membentuk tumpukan. Lapisan ini adalah algoritma atau metode yang digunakan untuk memproses data sehingga mendapatkan hasil terbaik (Darma Nurfitra & Ariyanto, 2018).

Dalam *deep learning*, jaringan saraf tiruan terdiri dari banyak lapisan (layer) yang saling terhubung. Setiap lapisan memiliki neuron atau nodus yang menerima input, melakukan operasi matematika, dan menghasilkan output. Proses ini membentuk representasi hierarki dari data, memungkinkan model untuk secara otomatis memahami fitur-fitur yang semakin kompleks. Algoritma ini dapat digunakan untuk memecahkan permasalahan yang perlu pengawasan (*supervised*), dan tanpa pengawasan (*unsupervised*), dalam berbagai aplikasi seperti pengenalan citra, pengenalan suara, klasifikasi teks, dan sebagainya. Berdasarkan hal itulah *Deep Learning* dapat digunakan untuk memecahkan masalah kompleks yang lebih rumit dan terdiri dari sejumlah besar lapisan transformasi non-linier (Lecun et al., 2015).

1. *Supervised Learning*

Supervised learning adalah salah satu teknik pembelajaran mesin yang menggunakan kumpulan data berlabel untuk melatih model.

Kumpulan data berlabel adalah kumpulan data yang setiap datanya memiliki label yang sesuai.

2. *Unsupervised Learning*

Unsupervised learning adalah salah satu teknik pembelajaran mesin yang menggunakan kumpulan data tidak berlabel untuk melatih model. Kumpulan data tidak berlabel adalah kumpulan data yang tidak memiliki label yang sesuai.


2.3.2 *Machine Learning*

Machine Learning merupakan sekumpulan teknik yang berfungsi untuk menangani dan memprediksi sekumpulan data dengan cara merepresentasikan data-data tersebut dengan algoritma untuk pembelajaran. Dengan adanya *machine learning*, komputer dapat melakukan pembelajaran secara mandiri dari data-data yang telah diberikan (Danukusumo, 2017).

Konsep dasar *Machine Learning* melibatkan identifikasi pola, pengembangan model matematis, dan penggunaan algoritma untuk memungkinkan komputer untuk membuat prediksi atau keputusan berdasarkan data yang diberikan. *Machine Learning* memiliki berbagai aplikasi, mulai dari klasifikasi dan prediksi, hingga pengenalan pola, *clustering*, dan pemrosesan bahasa alami.

2.3.3 Convolution Neutral Network

Convolution Neutral Network adalah perkembangan metode dari *Multi Layer Perception* (MLP). Namun, CNN memiliki jumlah dimensi yang lebih banyak dibandingkan dengan MLP. CNN memiliki masukan (input) *array* mulai dari dua dimensi hingga lebih.



Gambar 2. 1 Arsitektur Convolution Neutral Network (Springer Cham, 2021)

Convolutional Neural Network menggabungkan tiga pokok arsitektur, yaitu *local receptive fields*, *Shared weight* yang berupa filter, dan *spatial subsampling* yang berupa *Pooling* (Abhirawa et al., 2017). Konvolusi atau yang biasa disebut dengan *Convolution* merupakan matriks yang berfungsi untuk melakukan filter. CNN memiliki akurasi tinggi karena memiliki jumlah ekstraksi fitur yang dihasilkan oleh konvolusi dan jumlah neuron, serta penggabungan setiap neuron dengan menggunakan bobot yang diperbarui pada iterasi tertentu. Kombinasi terbaik akan menghasilkan akurasi tinggi.

2.3.4 Convolution Layer

Convolutional Layer adalah salah satu komponen kunci dalam arsitektur jaringan saraf konvolusional (*Convolutional Neural Network*) pada bidang *deep learning*. *Convolutional Layer* berfungsi untuk mengekstrak fitur-

fitur penting dari data input, seperti gambar, dengan menggunakan operasi konvolusi. Tujuan utama konvolusi dalam kaitannya dengan *ConvNet* adalah untuk mengekstraksi fitur dari gambar yang dimasukkan (Pujari et al., 2018). Secara khusus, operasi konvolusi dapat ditulis dengan rumus :

$$s(t) = (x * w)(t) \quad (1.1)$$

Fungsi $s(t)$ memberikan output tunggal yaitu *feature maps*, argumen pertama yaitu input yang merupakan x dan argumen kedua w sebagai kernel atau filter. Jika dilihat input sebagai gambar dua dimensi, maka dapat diasumsikan bahwa t sebagai piksel dan menggantinya dengan i dan j . Maka dari itu, operasi untuk konvolusi ke dalam input lebih dari satu dimensi dapat ditulis sebagai:

$$S_{(i,j)} = (I * K)_{(i,j)} = \sum_m \sum_n I_{(i-m,j-n)} K_{(m,n)} \quad (1.2)$$

Terdapat dua komponen penting lainnya dalam *convolutional layer* diantaranya :

1. *Padding*

Padding adalah suatu teknik dalam pengolahan citra dan jaringan saraf konvolusional yang melibatkan penambahan nilai-nilai tambahan di sekitar batas gambar atau input data. Tujuannya adalah untuk memperluas ukuran input dan menghindari kehilangan informasi di tepi citra atau dalam proses konvolusi.

2. *Strides*

Strides adalah jarak yang ditempuh oleh filter (kernel) saat menyaring (*convolution*) data input dalam *convolutional layer*. *Strides* menentukan

ukuran output dari *convolutional layer*. Semakin besar *strides*, semakin kecil ukuran output. Jika nilai *strides* adalah 1, filter akan digeser satu piksel pada setiap langkah, sehingga tumpang tindih antara area yang tercakup oleh satu filter dan area yang tercakup oleh filter berikutnya. Sebaliknya, jika nilai *strides* adalah lebih besar dari 1, filter akan melompati beberapa piksel setiap langkahnya, sehingga mengurangi tumpang tindih dan mengurangi dimensi output.

2.3.4 *Pooling Layer*

Pooling layer adalah lapisan atau layer yang mengolah output dari *Activation ReLU layer* dengan berbagai macam operasi statistika berdasarkan nilai piksel terdekat. *Pooling layer* dapat mengendalikan *overfitting* dengan cara mengurangi ukuran volume output pada *feature map* secara progresif (Kim, 2017).

Dalam *Pooling Layer*, operasi pooling, seperti *Max Pooling* atau *Average Pooling*, diterapkan pada *subregion* (pembagian kecil) dari *feature map*. *Max Pooling*, sebagai contoh, mengambil nilai maksimum dari setiap *subregion*, sementara *average pooling* mengambil rata-rata nilai. Langkah-langkah *pooling* diaplikasikan dengan interval tertentu yang disebut *stride*, menentukan seberapa sering operasi *pooling* diterapkan pada *feature map*. *Pooling* membantu mengatasi masalah *overfitting* dan mengurangi dimensi data, sehingga meningkatkan efisiensi komputasi dan memungkinkan jaringan untuk lebih cepat beradaptasi dengan pola-pola umum dalam data

2.3.5 *Fully Connected Layer*

Fully connected layer adalah lapisan yang berisikan kumpulan dari proses *convolution* atau konvulsi (Hijazi et al., 2015). Neuron pada lapisan ini terhubung dengan semua neuron pada lapisan sebelumnya (Albelwi & Mahmood, 2017). Rumus *Fully-Connected Layer* ditunjukkan sebagai :

$$y_j = b_j + \sum w_{i,j} x_i \quad (1.3)$$


Di mana y_j merupakan output dari *Fully-Connected layer* ke-j, b_j sebagai bias, $w_{(i,j)}$ sebagai bobot jaringan dan x_i sebagai input yang diperoleh dari proses learning feature.

2.3.6 *Fungsi Aktivasi ReLU (Rectified Linear Units)*

Activation ReLU layer merupakan layer yang berfungsi sebagai pengubah nilai piksel pada citra menjadi nol, jika terdapat nilai piksel yang kurang dari nol. Perubahan tersebut bertujuan untuk meningkatkan kualitas citra untuk meminimalisir kesalahan (Hanin et al., 2021). Persamaan dari fungsi aktivasi ini dapat ditulis sebagai :

$$f(x) = \max(0, x) \quad (1.4)$$

Pada persamaan di atas menunjukkan, jika x bernilai kurang dari nol atau bernilai negatif maka nilai $f(x)$ dinyatakan sebagai nol. Jika x bernilai lebih dari atau sama dengan nol maka nilai $f(x)$ sama dengan nilai x . berikut contoh grafik dari ReLU :



Gambar 2. 2 Grafik dari ReLU

2.3.7 Softmax Layer

Softmax adalah fungsi aktivasi yang melakukan normalisasi dari *vektor* suatu nilai tertentu ke dalam distribusi probabilitas. *Softmax* memiliki nilai antara 0 dan 1. *Softmax* dapat digunakan untuk menentukan seberapa yakin model dalam mengenali image dan melakukan klasifikasi.

$$p_j(x) = \frac{e^{x_j}}{\sum_{i=1}^k e^{x_i}} \quad (1.5)$$

Di mana, $p_j(x)$ merupakan peluang atau probabilitas dari x_j yang dihasilkan dari eksponensial x_j dibagi dengan total dari penjumlahan eksponensial x_i pada k (banyaknya kelas). *Softmax* memungkinkan kita untuk menghitung probabilitas untuk semua label. Dari label yang ada akan diambil sebuah vektor nilai bernilai riil dan merubahnya menjadi *vektor* dengan nilai antara nol dan satu yang bila semua dijumlahkan bernilai satu.

2.4 *Optimizer*

Algoritma optimasi berperan penting dalam meningkatkan kinerja model *machine learning* dengan mencari kombinasi bobot yang menghasilkan prediksi paling akurat. Proses ini melibatkan perubahan berulang pada bobot model berdasarkan *loss function*, yang mengukur seberapa baik model memprediksi data. Namun, tantangannya terletak pada menentukan kapan dan seberapa besar perubahan bobot yang harus dilakukan. Di sinilah peran *optimizer* menjadi penting. *Optimizer* seperti *Adam*, *SGDM*, dan *RMSProp* yang digunakan dalam penelitian ini, bekerja dengan menggabungkan informasi bobot model dan *loss function* untuk secara cerdas memperbarui bobot, sehingga model secara bertahap mencapai tingkat akurasi yang optimal.

2.4.1 *Adaptive Moment Estimation (ADAM)*

Adam Optimizer merupakan suatu *Optimizer Deep Learning* pengembangan dari *stochastic gradient descent*. *Adam* merupakan singkatan dari *adaptive moment estimation* (Kingma & Ba, 2014). *Adam Optimizer* menggabungkan kelebihan dari dua algoritma optimasi populer, yaitu *AdaGrad* dan *RMSProp*. Mirip dengan *AdaGrad*, *Adam* mempertahankan learning rate yang berbeda untuk setiap parameter, sehingga meningkatkan performa model secara keseluruhan. Selain itu, *Adam* juga mengadopsi pendekatan *RMSProp* dengan menyesuaikan *learning rate* berdasarkan rata-rata magnitudo gradien bobot model. Kombinasi kedua strategi ini memungkinkan *Adam* untuk mencapai konvergensi yang lebih cepat dan hasil yang lebih baik dalam pelatihan model.

2.4.2 *Stochastic Gradient Descent with Momentum (SGDM)*

SGDM Optimizer merupakan salah satu *Optimizer* hasil pengembangan dari *stochastic gradient descent* (SGD). *SGDM* memperkenalkan momentum orde pertama berdasarkan SGD (Jiang Haichen et al., 2020). Momentum tradisional, diperkenalkan oleh Polyak pada tahun 1964, merupakan teknik klasik yang digunakan untuk mempercepat proses penurunan gradien dalam optimasi model. Dalam metode ini, pembaruan parameter bobot tidak hanya bergantung pada gradien saat ini, tetapi juga mempertimbangkan rata-rata pergerakan eksponensial dari gradien saat ini dan sebelumnya. Dengan demikian, momentum membantu memandu arah perubahan bobot menuju titik minimum fungsi tujuan secara lebih efisien.

2.4.3 *Root Mean Square Propagation (RMSProp)*

RMSProp Optimizer merupakan singkatan dari *Root Mean Square Propagation* yang dikembangkan agar hasilnya lebih baik dan tidak mengurangi *learning rate* untuk mencegah terjadinya konvergensi. *RMSProp* merupakan pengembangan dari algoritma AdaGrad yang dirancang untuk menangani data yang lebih kompleks dan tidak konvensional. Keunggulan *RMSProp* terletak pada penggunaan "moving average eksponensial" dalam perhitungan gradien, yang memungkinkannya beradaptasi lebih baik terhadap perubahan data yang terjadi (Soydaner, 2020).

2.5 *Hyperparameter*

Hyperparameter merupakan parameter yang nilainya ditetapkan sebelum proses pelatihan dimulai dan berperan dalam mengendalikan proses pembelajaran pada algoritma *machine learning*. Berbeda dengan parameter model yang diperoleh melalui proses pelatihan, *hyperparameter* tetap konstan selama pelatihan berlangsung. *Variable* dalam *hyperparameter* menentukan bagaimana sebuah jaringan dilatih (Rima Dias Ramadhani et al., 2021). *Hyperparameter* yang digunakan meliputi *epoch*, *mini batch size*, dan *Optimizer*. *Epoch* menentukan jumlah iterasi pelatihan pada seluruh dataset, *mini batch size* mengatur jumlah sampel data yang digunakan dalam setiap iterasi, dan *Optimizer* menentukan algoritma yang digunakan untuk memperbarui bobot dan bias model berdasarkan error yang dihasilkan.

2.6 State of The Art Penelitian

State of the art adalah pencapaian tertinggi dalam sebuah proses pengembangan sebuah penelitian. Dibawah ini ada beberapa penelitian terkait yang sesuai dengan penelitian penulis.

Tabel 2. 1 SOTA Penelitian

No	Nama Pengarang	Tahun	Judul	Masalah	Solusi
1.	Budi Nugroho, Eva Yulia Puspaningrum	2019	Kinerja Metode Cnn Untuk Klasifikasi Pneumonia Dengan Variasi Ukuran Citra Input	Belum adanya penelitian yang menjelaskan secara detail sejauh mana pengaruh ukuran citra input yang diperkecil terhadap kinerja klasifikasi pneumonia menggunakan CNN.	Penelitian ini melakukan eksperimen dengan menggunakan berbagai ukuran citra input (100x100, 200x200, 300x300, 400x400, dan 500x500 piksel) pada model CNN dan CNN-ELM. Hal ini dilakukan untuk mengetahui pengaruh ukuran citra terhadap kinerja klasifikasi

					pneumonia. Penelitian ini tidak hanya menggunakan arsitektur CNN standar, tetapi juga memodifikasinya dengan menggabungkan Extreme Learning Machine (ELM) pada bagian klasifikasi (CNN-ELM). Tujuannya adalah untuk melihat apakah penggabungan ELM dapat meningkatkan kinerja klasifikasi dibandingkan dengan CNN standar.
2.	Chandra Wijaya, Hafiz Irsyad, Wijang Widhiarso	2020	Klasifikasi Pneumonia Menggunakan Metode KNearest Neighbor	Masalah yang diangkat dalam penelitian ini adalah bagaimana mengklasifikasikan citra rontgen paru-paru untuk	Untuk mengatasi masalah klasifikasi pneumonia secara cepat dan akurat, penelitian ini menggunakan metode K-Nearest Neighbor (KNN) dengan

			Dengan Ekstraksi GLCM	mendeteksi pneumonia secara cepat dan akurat. Pneumonia adalah penyakit radang parenkim paru-paru yang disebabkan oleh berbagai mikroorganisme. Deteksi dini pneumonia sangat penting untuk penanganan yang efektif.	ekstraksi fitur Gray Level Co-Occurrence Matrix (GLCM) pada dataset 1.400 citra rontgen paru-paru normal dan pneumonia (bakteri dan virus) dari Kaggle.
3.	Risha Ambar Wati, Hafiz Irsyad, M Ezar Al Rivan	2020	Klasifikasi Pneumonia Menggunakan Metode Support Vector Machine	Bagaimana mengklasifikasikan citra hasil rontgen paru-paru untuk mendeteksi pneumonia secara akurat. Pneumonia adalah penyakit radang paru-paru yang disebabkan oleh	Untuk mengatasi masalah klasifikasi pneumonia, penelitian ini menggunakan metode Support Vector Machine (SVM) dengan ekstraksi fitur Gray Level Co-Occurrence Matrix (GLCM) pada dataset 3140

				berbagai mikroorganisme seperti bakteri, virus, jamur, atau parasit. Deteksi dini pneumonia sangat penting untuk penanganan yang efektif. Salah satu cara untuk mendiagnosis pneumonia adalah dengan menganalisis citra rontgen paru-paru.	citra rontgen paru-paru normal dan pneumonia dari Kaggle.
4.	Muhammad Nuchfi Fadlurrahman, Agus Eko	2023	Klasifikasi COVID-19 Menggunakan Algoritma CNN	Penelitian ini bertujuan untuk mengklasifikasikan apakah seseorang terjangkit COVID-19 atau tidak melalui citra sinar-X. Masalah yang diangkat dalam	Solusi yang diusulkan dalam penelitian ini adalah mengklasifikasikan citra sinar-X menggunakan algoritma <i>Convolutional Neural Network</i>

	Minarno, Yufis Azhar			penelitian ini adalah sulitnya membedakan hasil sinar-X pasien pneumonia dengan COVID-19 karena kemiripannya. Hal ini mempersulit tugas radiolog dalam menganalisis hasil sinar-X.	(CNN) dengan arsitektur VGG-16. Penggunaan algoritma ini diharapkan dapat membantu radiolog dalam menganalisis hasil sinar-X pasien yang diduga terjangkit COVID-19.
5.	Nanik Wuryani, Sarifah Agustiani	2021	Random Forest Classifier untuk Deteksi Penderita COVID-19 berbasis Citra CT Scan	Penelitian ini bertujuan untuk mendeteksi COVID-19 pada paru-paru melalui citra CT Scan. Masalah yang diangkat adalah sulitnya dan lamanya proses identifikasi secara	Solusi yang ditawarkan dalam penelitian ini adalah penggunaan algoritma Random Forest Classifier yang dikombinasikan dengan beberapa teknik ekstraksi fitur, yaitu Haralick, Color Histogram, dan Hu-

				manual terhadap infeksi COVID-19 yang ditunjukkan dengan adanya lesi atau kabut pada citra CT Scan.	Moments. Metode ini dipilih setelah membandingkan beberapa algoritma klasifikasi lain seperti K-Nearest Neighbor (KNN), Decision Tree, Linear Discriminant Analysis (LDA), Logistic Regression, Support Vector Machine (SVM), dan Naive Bayes.
6.	Mohd. Abdul Ghani, Fathur Fahrizal, Armin Lawi	2021	Implementasi Arsitektur Xception Untuk Klasifikasi Citra Covid-19 Radiography	Penelitian ini bertujuan untuk mengklasifikasikan citra radiografi untuk menentukan apakah pasien terinfeksi COVID-19 atau tidak. Masalah yang diangkat adalah kebutuhan akan deteksi dini	Solusi yang diusulkan adalah menggunakan arsitektur Xception dengan transfer learning untuk mengklasifikasikan citra radiografi. Metode ini melibatkan langkah-langkah pre-processing data seperti konversi citra menjadi array,

				kasus positif COVID-19 untuk mencegah penyebaran virus dan mempercepat pengobatan pasien.	pelabelan data, dan normalisasi, diikuti dengan proses training dan testing model. Penelitian ini menggunakan dataset Covid-19 Radiography Database yang berisi empat kelas, yaitu COVID, Lung_Opacity, Normal, dan Viral Pneumonia.
7.	Adhitio Satyo Bayangkari Karno, Widi Hastomo, Yasin Efendi dan Diah Ruri Irawati	2021	Arsitektur Alexnet Convolution Neural Network (CNN) Untuk Mendeteksi Covid-19 Image Chest-Xray	Penelitian ini bertujuan untuk membantu tenaga medis, terutama ahli radiologi, dalam mendiagnosis pasien COVID-19 dengan cepat dari data citra X-ray dada menggunakan	Untuk meminimalisir pekerjaan manual, maka salah satu cara yang Solusi yang ditawarkan adalah penggunaan arsitektur AlexNet, sebuah arsitektur CNN yang ringan dan cepat. Meskipun akurasi tidak

				Convolution Neural Network (CNN). Masalah yang diangkat adalah keterbatasan kinerja komputer dalam mengolah data citra medis dengan arsitektur CNN yang kompleks.	setinggi arsitektur lain, AlexNet memerlukan operasi dan waktu proses yang minim. Hasil penelitian menunjukkan bahwa AlexNet dapat mencapai akurasi 85,5% dalam mendeteksi COVID-19 pada citra X-ray dada.
8.	Vivin Vidia Nurdiansyah, Imam Cholissodin, Putra Pandu Adikara	2020	Klasifikasi Penyakit Tuberkulosis (TB) menggunakan Metode Extreme Learning Machine (ELM)	Penyakit TB merupakan salah satu penyakit dengan tingkat kematian tertinggi di dunia dan di Indonesia. Peningkatan kasus TB dari tahun ke tahun disebabkan oleh kurangnya informasi yang memadai di	Penggunaan metode Extreme Learning Machine (ELM) untuk klasifikasi penyakit TB. Metode ini dipilih karena memiliki akurasi yang tinggi, kecepatan pembelajaran yang lebih cepat dibandingkan algoritma lain seperti Backpropagation, SVM,

				masyarakat mengenai bahaya penyakit ini, pengobatan, dan cara pencegahannya. Selain itu, terdapat kesulitan dalam mengklasifikasikan pasien TB karena masyarakat seringkali meremehkan masalah kesehatan dan tidak menyelesaikan pengobatan TB.	dan Least Square SVM, serta lebih sederhana daripada algoritma feedforward lainnya. Penelitian ini bertujuan untuk mendapatkan hasil klasifikasi TB yang akurat menggunakan metode ELM, dengan harapan dapat meningkatkan kesadaran masyarakat terhadap penyakit TB dan membantu tenaga medis dalam mendiagnosis penyakit ini.
9.	Aida Muhdina, Ledya	2021	Klasifikasi Tuberkulosis Dengan Compressive Sensing	Masalah yang diangkat dalam penelitian ini adalah sebagian besar penelitian sebelumnya	Solusi yang diusulkan dalam artikel ini adalah merancang sistem klasifikasi bakteri tuberkulosis dari

	Novamizanti, Gelar Budiman		Dan Support Vector Machine	hanya mengklasifikasikan bakteri TBC ke dalam dua kelas (positif dan negatif) dan menggunakan metode ekstraksi ciri yang kurang efisien dalam penyimpanan memori.	citra mikroskopis dahak dengan menggunakan metode Compressive Sensing sebagai ekstraksi ciri dan Support Vector Machine (SVM) sebagai klasifikasi. Metode Compressive Sensing dipilih karena dapat merekonstruksi sinyal yang telah dikompresi dengan data hasil kompresi yang lebih sedikit, sehingga dianggap memiliki informasi deskriptif terhadap sinyal yang telah dikompresi. Sementara itu, metode SVM digunakan karena kemampuannya dalam
--	-------------------------------	--	-------------------------------	---	--

					mengklasifikasikan data dengan mencari hyperplane yang dapat memisahkan kelompok data secara optimal.
10.	Suharni, Eel Susilowati, Taufiq Muldan Hidayat	2021	Implementasi Model <i>Convolutional Neural Network</i> (Cnn) Untuk Klasifikasi Penyakit Tbc Berbasis Dekstop	Deteksi penyakit TBC (Tuberkulosis) yang masih menjadi masalah utama di negara berkembang seperti Indonesia. Deteksi penyakit TBC secara manual oleh dokter memiliki risiko kesalahan akibat keterbatasan kemampuan manusia dalam	Mengimplementasikan model <i>Convolutional Neural Network</i> (CNN) berbasis desktop untuk klasifikasi penyakit TBC. Model CNN ini diharapkan dapat membantu dokter dalam mengidentifikasi hasil rontgen paru-paru pasien, sehingga dapat diketahui apakah pasien tersebut menderita TBC atau tidak.

				menginterpretasikan hasil diagnosis secara visual.	
--	--	--	--	---	--

2.7 Matriks Penelitian

Tabel 2. 2 Matriks Penelitian

No	Nama Peneliti	Tahun	Judul	Ruang Lingkup		
				Algoritma		Objek
				Ekstraksi	Klasifikasi	
1.	Budi Nugroho, Eva Yulia Puspaningrum	2019	Kinerja Metode Cnn Untuk Klasifikasi Pneumonia Dengan Variasi Ukuran Citra Input	<i>Convolutional Neural Network</i>	<i>Convolutional Neural Network</i>	Citra Pneumonia
2.	Chandra Wijaya, Hafiz Irsyad, Wijang Widhiarso	2020	Klasifikasi Pneumonia Menggunakan Metode K- Nearest Neighbor Dengan Ekstraksi GLCM	<i>Metode K- Nearest Neighbor</i>	<i>GLCM</i>	Citra Pneumonia

3.	Risha Ambar Wati, Hafiz Irsyad, M Ezar Al Rivan	2020	Klasifikasi Pneumonia Menggunakan Metode Support Vector Machine	<i>Support Vector Machine</i>	<i>Support Vector Machine</i>	Citra Pneumonia
4.	Muhammad Nuchfi Fadlurrahman, Agus Eko Minarno, Yufis Azhar	2023	Klasifikasi COVID-19 Menggunakan Algoritma CNN	<i>Convolutional Neural Network</i>	<i>Convolutional Neural Network</i>	Citra Covid- 19
5.	Nanik Wuryani, Sarifah Agustiani	2021	Random Forest Classifier untuk Deteksi Penderita COVID-19 berbasis Citra CT Scan		<i>Random Forest Classifier</i>	Citra Covid- 19
6.	Mohd. Abdul Ghani, Fathur Fahrizal, Armin Lawi	2021	Implementasi Arsitektur Xception Untuk Klasifikasi Citra Covid-19 Radiography		<i>Xception</i>	Citra Covid- 19

7.	Adhitio Satyo Bayangkari Karno, Widi Hastomo, Yasin Efendi dan Diyah Ruri Irawati	2021	Arsitektur Alexnet Convolution Neural Network (CNN) Untuk Mendeteksi Covid-19 Image Chest-Xray	<i>Convolutional Neural Network</i>	<i>Convolutional Neural Network</i>	Citra Covid- 19
8.	Vivin Vidia Nurdiansyah, Imam Cholissodin, Putra Pandu Adikara	2020	Klasifikasi Penyakit Tuberkulosis (TB) menggunakan Metode Extreme Learning Machine (ELM)	<i>Extreme Learning Machine (ELM)</i>	<i>Extreme Learning Machine (ELM)</i>	Citra Tuberkulosis

9.	Aida Muhdina, Ledya Novamizanti, Gelar Budiman	2021	Klasifikasi Tuberkulosis Dengan Compressive Sensing Dan Support Vector Machine	<i>Compressive Sensing</i>	<i>Support Vector Machine</i>	Citra Tuberkulosis
10.	Suharni, Eel Susilowati, Taufiq Muldan Hidayat	2021	Implementasi Model <i>Convolutional Neural Network</i> (CNN) Untuk Klasifikasi Penyakit Tbc Berbasis Dekstop	<i>Convolutional Neural Network</i>	<i>Convolutional Neural Network</i>	Citra Tuberkulosis
11.	Nabil Ramadhan	2024	Klasifikasi Penyakit Paru-Paru Dengan Metode <i>Convolutional Neural Network</i> Pada Citra Rontgen	<i>Convolutional Neural Network</i>	<i>Convolutional Neural Network</i>	Citra Rontgen Paru-Paru

2.8 Relevansi Penelitian

Tabel 2. 3 Relevansi Penelitian

Usulan Penelitian	Budi Nugroho, Eva Yulia Puspaningrum (2019)	Nabil Ramadhan (2024)
Judul	Kinerja Metode CNN Untuk Klasifikasi Pneumonia Dengan Variasi Ukuran Citra Input	Klasifikasi Penyakit Paru-Paru Dengan Metode <i>Convolutional Neural Network</i> Pada Citra Rontgen
Masalah Penelitian	Belum adanya penelitian yang menjelaskan secara detail sejauh mana pengaruh ukuran citra input yang diperkecil terhadap kinerja klasifikasi pneumonia menggunakan CNN.	Pada saat ini deteksi penyakit pada paru-paru dilakukan melalui rontgen oleh para dokter ahli. Namun proses rontgen membutuhkan waktu yang lama agar terdiagnosa hasilnya dan menyesuaikan jadwal dokter untuk konsultasi hasilnya.
Objek Penelitian	Citra Pneumonia	Citra Rontgen Paru-Paru

Algoritma	Metode <i>Convolutional Neural Network</i>	<i>Convolutional Neural Network</i>
-----------	--	-------------------------------------

Penelitian ini berfokus pada klasifikasi citra rontgen paru-paru menggunakan *Convolutional Neural Network* (CNN) untuk mendeteksi Pneumonia, Tuberkulosis, dan COVID-19. Penelitian ini berbeda dengan penelitian sebelumnya yang dilakukan oleh Nugroho dan Puspaningrum (2021), yang hanya berfokus pada klasifikasi Pneumonia. Selain itu, penelitian ini juga mengeksplorasi variasi *hyperparameter* dan *Optimizer* untuk mengoptimalkan kinerja model CNN, sementara penelitian Nugroho dan Puspaningrum lebih fokus pada pengaruh variasi ukuran citra input. Hasil penelitian ini menunjukkan bahwa akurasi tertinggi mencapai 100% dengan *Optimizer RMSProp* dan *Adam*, serta *mini batch size* 8, memberikan kontribusi signifikan dalam meningkatkan akurasi klasifikasi penyakit paru-paru berbasis citra rontgen dibandingkan penelitian Nugroho dan Puspaningrum (2021) yang akurasi tertingginya mencapai 93,59%.