

BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Meninjau penelitian sebelumnya merupakan salah satu langkah penting dalam penelitian, di mana dilakukan pemeriksaan dan penelusuran hasil penelitian yang sudah ada dengan mengacu pada relevansi topik yang sedang diteliti sebagai referensi untuk mendukung penelitian ini.

Beberapa contoh penelitian terdahulu yang menjadi referensi yang pertama yaitu dari (Hwang dkk., 2021). Penelitian ini bertujuan untuk mengevaluasi kinerja sistem deteksi berbantuan komputer (CAD) berbasis *deep learning* dalam deteksi pneumonia pada CXR pasien yang memiliki suhu tubuh di atas 38,3°C berturut-turut dan mengamati apakah CAD dapat membantu mempercepat diagnostik dokter radiologi ketika digunakan sebagai pembaca kedua. Pada penelitian ini metode yang digunakan adalah *deep learning* murni atau *deep neural network*.

Selain itu pada penelitian (Showkati dkk., 2022) memiliki tujuan untuk mengembangkan dan membandingkan metode baru dalam mendeteksi penyakit tuberkulosis (TB) secara otomatis dari citra radiografi toraks untuk meningkatkan akurasi dalam diagnosis TB dan mengurangi kesalahan yang dapat muncul dalam interpretasi citra radiografi toraks. Penelitian ini membandingkan kinerja model *deep learning* dengan teknik *transfer learning* yang menggunakan model-model CNN untuk melatih model jaringan saraf tiruan yang mampu secara otomatis mengidentifikasi TB dari citra radiografi toraks.

Penelitian yang dilakukan oleh (Dalvi dkk., 2023) juga menyoroti keunggulan model DenseNet-169 dibandingkan model lain seperti AlexNet, ResNet-50, VGG-16, dan VGG-19 untuk mendiagnosis COVID-19 dari citra radiografi toraks. Studi ini menggunakan pembelajaran transfer dengan model DenseNet-169 yang telah dilatih sebelumnya, bersama dengan teknik augmentasi data untuk meningkatkan kumpulan data. Hal ini menggarisbawahi potensi citra radiografi toraks sebagai alternatif yang hemat biaya dan efisien untuk diagnosis COVID-19, terutama mengingat keterbatasan pengujian RT-PCR.

Penelitian lain dari (Park dkk., 2019) juga mengeksplorasi penerapan model *deep learning* untuk analisis citra radiografi toraks. Studi ini membandingkan kinerja model berbasis pembelajaran kurikulum dengan model dasar untuk klasifikasi kelainan paru otomatis pada citra radiografi toraks. Hasilnya menunjukkan peningkatan akurasi dan pengurangan *loss* dalam mendeteksi penyakit toraks seperti nodul, konsolidasi, opasitas interstisial, efusi pleura, dan pneumotoraks. Secara keseluruhan, sistem diagnostik berbantuan komputer (CAD) ini menunjukkan potensi untuk deteksi dan klasifikasi simultan dari beberapa pola penyakit pada citra radiografi toraks, meskipun tantangan tetap ada dalam variasi lesi dan perluasan kumpulan data.

Terakhir pada penelitian (Luo dkk., 2022), dikembangkan model *deep learning* untuk membantu ahli radiologi dalam mendeteksi penyakit pneumonia karena COVID-19 lalu hasil diagnosis dari model *deep learning* dibandingkan dengan diagnosis dari radiologis. U-Net dan ResNet-50 digunakan sebagai arsitektur metode CNN untuk melatih model *deep learning* pada pasien normal, CAP, dan COVID-19.

Berdasarkan contoh penelitian terdahulu, banyak penelitian yang membahas tentang sistem pendeteksi penyakit pada dada yang menggunakan metode CNN karena CNN merupakan model *deep learning* yang paling baik untuk mengklasifikasi penyakit pada dada (Monshi dkk., 2019), namun demikian masih belum ada penelitian yang secara eksplisit membahas tentang sistem pendeteksi penyakit pneumotoraks dari citra radiografi toraks menggunakan metode CNN. Oleh karena itu penelitian ini akan membahas secara eksplisit tentang sistem pendeteksi penyakit pneumotoraks dari citra radiografi toraks menggunakan metode CNN.

2.2 Dasar Teori


2.2.1 Penyakit paru-paru

Paru-paru merupakan organ vital yang rentan terhadap berbagai penyakit, baik yang bersifat infeksius maupun non-infeksius yang dapat memengaruhi fungsi

pernapasan dan kualitas hidup penderitanya, penyakit paru-paru dijelaskan sebagai berikut.

A. Pneumotoraks

Pneumotoraks merupakan kondisi ketika terdapat udara di dalam ruang antara lapisan-lapisan tipis jaringan di dada yang disebut pleura (Gilday dkk., 2021). Pada keadaan normal, rongga pleura dipenuhi oleh paru-paru saat menarik napas karena adanya tekanan negatif di rongga pleura, namun adanya udara pada rongga di antara pleura visceral dan pleura parietal menyebabkan paru-paru terdesak sesuai dengan jumlah udara yang masuk kedalam rongga pleura tersebut, semakin banyak udara yang masuk kedalam rongga pleura akan menyebabkan paru-paru menjadi kolaps karena terdesak tekanan udara pada intrapleura (Wibowo, 2023). Gambaran pneumotoraks ditunjukkan pada Gambar 2.1.



Gambar 2.1 Gambaran pneumotoraks (Wibowo, 2023)

Pneumotoraks diklasifikasikan menjadi beberapa jenis berdasarkan etiologi atau penyebabnya, yaitu spontan (dapat terjadi tanpa penyebab yang jelas, dibagi lagi menjadi primer dan sekunder), atau didapat (disebabkan oleh cedera atau tindakan medis, dibagi lagi menjadi traumatis dan iatrogenik), serta berdasarkan patofisiologi atau cara terjadinya (apakah terdapat

hubungan dengan luar atau tidak, serta seberapa parah kondisinya) (Gilday dkk., 2021).

Pneumotoraks spontan primer (PSP) terjadi tanpa adanya penyakit paru yang mendasarinya dan biasanya diakibatkan oleh pecahnya bleb atau bula subpleural, sedangkan pneumotoraks spontan sekunder (SSP) terjadi pada pasien sebagai akibat dari penyakit parenkim paru fokal atau difus (Gilday dkk., 2021) (Louw E H, 2021).

Pneumotoraks spontan primer (PSP) paling umum terjadi pada remaja dan orang dewasa muda, dengan kejadian tahunan berkisar antara 15,5 hingga 22,7 per 100.000 orang dan dengan rasio wanita/pria berkisar antara 1:3,3 hingga 1:5 (Mendogni dkk., 2020). Penelitian lain mengatakan angka kejadian pneumotoraks per 100.000 individu dilaporkan berkisar antara 1,2 hingga 9,8 pada wanita dan antara 7,4 hingga 24,0 pada pria; angka kejadian pneumotoraks yang memerlukan perawatan di rumah sakit per 100.000 individu sekitar 17–22 pada pria, 6–7 pada wanita, dan secara keseluruhan sekitar 14–23 (D. Kim dkk., 2019). Kejadian tertinggi pneumotoraks spontan primer terjadi pada usia 35 tahun, sedangkan pneumotoraks spontan sekunder terjadi lebih tua pada usia 53 tahun (Louw E H, 2021).

Orang yang mengalami pneumotoraks cenderung memiliki postur tubuh tinggi dengan indeks massa tubuh rendah, namun untuk pneumotoraks spontan primer (PSP) biasanya memiliki kebiasaan merokok tembakau (Louw E H, 2021). Merokok ganja, tinggal di tempat yang tinggi, dan polusi udara adalah faktor risiko tambahan (Louw E H, 2021). Meskipun pneumotoraks spontan primer (PSP) terjadi pada pasien tanpa penyakit paru yang jelas secara klinis, sebagian besar pasien PSP memiliki perubahan mirip emfisema dalam jaringan paru-paru (Mendogni dkk., 2020). Selain itu, pasien dengan pneumotoraks mungkin berisiko tinggi mengalami stres (D. Kim dkk., 2019).

Penyakit ini sering kali muncul sebagai keadaan darurat yang mengancam jiwa yang memerlukan pengenalan dan pengobatan segera (Gilday dkk., 2021). Saat ini, dalam praktik klinis, pengobatan PSP dilakukan oleh dokter

dengan spektrum yang luas: dokter umum, dokter ruang gawat darurat dan perawatan intensif, ahli bedah umum, ahli bedah toraks, dan ahli paru (Mendogni dkk., 2020). Pneumotoraks didiagnosis melalui foto rontgen dada atau dengan cara menyedot udara menggunakan jarum (Yun & Ang, 2023). Ciri citra pneumothorax pada radiografi tampak garis pleura viseralis, lurus atau cembung terhadap dinding dada dan terpisah dari garis pleura parietalis (Wibowo, 2023). Celah antara kedua garis pleura tersebut tampak lusens karena berisi kumpulan udara dan tidak didapatkan corakan vascular pada daerah tersebut (Wibowo, 2023).

B. Tuberkulosis

Tuberkulosis (TB) adalah penyakit menular yang disebabkan oleh bakteri *Mycobacterium Tuberculosis* (Mtb) (Coussens dkk., 2024). TB biasanya menyerang paru-paru, tetapi juga dapat menyerang organ lain dalam tubuh seperti ginjal, tulang belakang, dan otak (Coussens dkk., 2024). Infeksi akibat penyakit ini dapat menyebabkan kerusakan pada jaringan organ yang terinfeksi dan menimbulkan berbagai gejala tergantung pada organ yang terlibat (Coussens dkk., 2024). Manifestasi klinis TB dapat bervariasi, tetapi umumnya gejala seperti batuk yang berlangsung lebih dari tiga minggu, nyeri dada, batuk berdarah atau sputum, kelemahan atau kelelahan, penurunan berat badan, demam, dan berkeringat di malam hari (Coussens dkk., 2024). Pada TB aktif, hasil gambaran radiologis paru sering menunjukkan area infeksi, tetapi pada TB laten biasanya tidak terlihat jelas di rontgen (Coussens dkk., 2024).

C. Pneumonia

Pneumonia adalah penyakit yang heterogen baik secara klinis maupun epidemiologis (Dueck dkk., 2021). Pneumonia diklasifikasikan ke dalam tiga subkelompok berdasarkan kondisi klinis saat pasien mengalami gejala infeksi: pneumonia yang didapat dari komunitas, pneumonia yang didapat

dari rumah sakit, dan pneumonia yang terkait dengan penggunaan ventilator (Dueck dkk., 2021).

Pneumonia yang didapat dari komunitas disebabkan oleh mikroorganisme umum seperti *streptococcus pneumoniae*, *Haemophilus influenzae*, *staphylococcus aureus* (Dueck dkk., 2021). Pneumonia yang didapat dari komunitas memiliki manifestasi klinis berupa demam, batuk kering, nyeri dada pleuritik, dan kesulitan bernapas (Dueck dkk., 2021). Penderita juga dapat mengalami gejala sistemik seperti kelelahan, mialgia atau nyeri otot, dan sakit kepala (Dueck dkk., 2021).

Pneumonia yang didapat dari rumah sakit dan pneumonia yang terkait dengan penggunaan ventilator biasanya disebabkan oleh bakteri gram negatif seperti *Pseudomonas aeruginosa*, *Klebsiella pneumoniae*, dan *Acinetobacter species*, serta bakteri gram positif seperti *Staphylococcus aureus* (Dueck dkk., 2021). Pneumonia yang didapat dari rumah sakit memiliki manifestasi klinis mirip dengan CAP, seperti demam, peningkatan produksi dahak, batuk, dan kesulitan bernapas namun lebih parah (Dueck dkk., 2021). Sehingga pasien dengan pneumonia yang didapat dari rumah sakit mungkin menunjukkan tanda-tanda infeksi sistemik seperti leukositosis dan peningkatan kebutuhan oksigen (Dueck dkk., 2021). Sedangkan pneumonia yang terkait dengan penggunaan ventilator memiliki manifestasi klinis berupa demam, leukositosis atau sel darah putih dalam darah meningkat dikarenakan melawan infeksi, peningkatan sekresi trakeobronkial, infiltrat baru atau progresif pada radiografi dada dan penurunan oksigenasi dan peningkatan kebutuhan ventilator (Dueck dkk., 2021).

Gambaran pneumonia pada pemeriksaan paru bisa berbeda tergantung penyebabnya. Beberapa ciri yang sering terlihat adalah area buram pada paru-paru, bercak kecil atau bagian paru yang tampak lebih padat (Dueck dkk., 2021).

D. Asma

Asma adalah kondisi pernapasan kronis yang disebabkan oleh sensitisasi alergi atau riwayat keluarga yang kuat terhadap asma, selain itu paparan asap rokok, polusi udara lingkungan, dan obesitas juga menjadi penyebab penyakit asma (Chung dkk., 2022). Manifestasi klinis penyakit asma ditandai dengan gejala seperti sesak napas yang tidak stabil, mengi, dan batuk (Chung dkk., 2022). Gambaran radiologis penderita asma biasanya menunjukkan dinding saluran napas bisa menebal, hal ini menunjukkan adanya peradangan kronis (Chung dkk., 2022). Selain itu, beberapa saluran napas bisa tampak melebar, yang menandakan kesulitan udara keluar-masuk paru-paru (Chung dkk., 2022). Pada kasus yang lebih parah, ada kemungkinan terbentuknya pelebaran permanen saluran napas (Chung dkk., 2022).

E. Efusi Pleura

Efusi pleura atau paru-paru basah adalah kondisi di mana terdapat penumpukan cairan berlebih di ruang pleura atau ruang antara paru-paru dan dinding dada (Pou dkk., 2023). Cairan ini bisa berupa transudat atau eksudat yang disebabkan oleh berbagai kondisi medis, seperti gagal jantung, infeksi, atau penyakit sistemik seperti amiloidosis (Pou dkk., 2023). Manifestasi klinis dari efusi pleura dapat bervariasi tergantung pada jumlah cairan yang terkumpul dan penyebab dasarnya (Pou dkk., 2023). Gejala umum efusi pleura meliputi sesak napas, nyeri dada saat bernapas dalam atau batuk, dan batuk kering (Pou dkk., 2023). Pada beberapa kasus, efusi pleura dapat menyebabkan gejala sistemik seperti demam dan malaise atau merasa lelah, tidak nyaman, atau kurang sehat tanpa penyebab yang jelas jika disebabkan oleh infeksi atau kondisi inflamasi (Pou dkk., 2023). Gambaran efusi pleura pada radiologi terlihat sebagai penumpukan cairan di ruang antara paru-paru dan dinding dada (Pou dkk., 2023). Pada rontgen dada, cairan ini biasanya tampak sebagai bayangan putih di bagian bawah paru dengan garis batas melengkung (Pou dkk., 2023).

2.2.2 Radiografi dada (Citra Radiografi Toraks)

Radiografi dada (CXR) atau dalam bahasa sehari-hari dikenal sebagai *rontgen* dada adalah teknologi pencitraan yang paling umum digunakan untuk mendeteksi, mendiagnosis, dan penatalaksanaan berbagai penyakit yang mengancam nyawa (Gang dkk., 2019). CXR merupakan pemeriksaan yang non-invasif dan relatif murah (Kundu dkk., 2021). Alat ini juga memiliki keuntungan lain karena pemeriksaannya berdosisi rendah, terutama bila dibandingkan dengan *Computed Tomography* (CT) (Haber dkk., 2020).

CXR termasuk salah satu jenis pemeriksaan radiologi yang paling sering digunakan untuk mendeteksi penyakit pada dada (Allaouzi dan Ben Ahmed, 2019). Terutama penyakit pada paru-paru seperti pneumotoraks, tuberkulosis, kanker, dan sebagainya (Gang dkk., 2019). CXR mengambil bayangan paru-paru, jantung, mediastinum, dan tulang (Wang dkk., 2021).

CXR pada umumnya diambil menggunakan sistem radiografi tetap atau sistem radiografi bergerak, tergantung pada kondisi pasien (Hwang dkk., 2021). Foto rontgen dada dari sistem radiografi tetap diambil dalam posisi berdiri dengan proyeksi posteroanterior, sedangkan foto rontgen dada dari pemindai radiografi bergerak diambil dalam posisi berbaring atau duduk dengan proyeksi anteroposterior (Hwang dkk., 2021).

Dalam banyak sistem layanan kesehatan, radiografi dada masih menjadi uji pertama dalam diagnosis pneumotoraks bagi pasien yang menunjukkan gejala (Bradley dkk., 2021). Seiring berjalannya waktu semakin banyak bukti yang menunjukkan keakuratan CXR dalam menentukan apakah seseorang dapat bertahan dari pneumotoraks (Bradley dkk., 2021).

2.2.3 Computer-Aided Detection (CAD)

CAD adalah teknologi kecerdasan buatan (AI) yang digunakan dalam bidang kedokteran untuk membantu dokter radiologi dalam menemukan bagian-bagian yang mencurigakan pada citra radiografi agar dokter radiologi dapat melihatnya (Katzen dan Dodelzon, 2018).

Secara umum, CAD dirancang untuk mendeteksi kelainan radiografi, termasuk nodul atau massa paru, infiltrat paru, dan pneumotoraks pada satu foto toraks frontal yang diduga pneumotoraks pada CXR (Hwang dkk., 2021). Sistem ini belajar dari berbagai citra radiografi dan memiliki langkah-langkah seperti langkah-langkah pra-pengolahan, segmentasi anatomi, ekstraksi ciri, dan klasifikasi (Katzen dan Dodelzon, 2018).

Kecerdasan buatan (AI) dalam bentuk sistem CAD digunakan untuk membantu dan mengurangi beban kerja dokter radiologi (Balkenende dkk., 2022). Langkah pertama dalam sistem CAD dengan mempersiapkan citra radiografi untuk digunakan sebagai bahan acuan, langkah ini meliputi normalisasi, penghilangan gangguan, penyelarasan kontras, dan penyelarasan ukuran citra (Katzen dan Dodelzon, 2018).

Segmentasi anatomi memungkinkan sistem untuk lebih mudah mengidentifikasi lesi mencurigakan dalam tubuh, sedangkan ekstraksi ciri melatih sistem untuk mendeteksi lesi mencurigakan dalam tubuh yang sama seperti yang dievaluasi oleh seorang dokter radiologi (Katzen dan Dodelzon, 2018). Klasifikasi adalah langkah terakhir untuk melatih sistem dalam mengklasifikasikan lesi sebagai jinak atau ganas (Katzen dan Dodelzon, 2018).

2.2.4 Deep Learning

Deep learning adalah suatu metode pembelajaran representasi dimana arsitektur jaringan saraf *multi*-lapisan yang kompleks belajar merepresentasikan data secara otomatis dengan mengubah informasi masukan ke dalam berbagai tingkat abstraksi (Chan dkk., 2020).

Deep learning merupakan bagian dari *machine learning* yang dapat menangani data citra, sehingga dapat menentukan (mempelajari) ciri yang sesuai tanpa campur tangan manusia (Balkenende dkk., 2022). *Deep learning* menggunakan jaringan saraf tiruan untuk mengekstrak ciri yang bersifat non-linear, terkait, dan representatif dari data yang besar dan berdimensi tinggi (Tran dkk., 2021). Dengan menggunakan berbagai lapisan arsitektur jaringan saraf dan sejumlah besar data yang sudah diberi label, model dapat dilatih dan dapat

melakukan klasifikasi berdasarkan citra, teks, atau suara (Mahoro dan Akhloufi, 2022).

Melalui proses pembelajaran otomatis, *deep learning* dapat dengan mudah menganalisis ribuan atau jutaan kasus yang mungkin bahkan tidak dapat dilihat dan diingat oleh dokter sepanjang hidup mereka (Chan dkk., 2020). Oleh karena itu, *deep learning* dapat menjadi solusi terhadap berbagai variasi ciri antar kelas yang berbeda yang perlu dibedakan, selama set pelatihan cukup besar dan beragam untuk dianalisis (Chan dkk., 2020).

Pada penelitian ini, metode CNN digunakan sebagai model *deep learning* dalam mempelajari data citra radiografi toraks untuk mendeteksi adanya tanda-tanda pneumotoraks.

2.2.5 Prapengolahan

Prapengolahan adalah beberapa tahapan yang dilakukan pada data mentah atau asli sebelum data tersebut dianalisis lebih lanjut atau pengembangan model prediksi (Gede dkk., 2024). Prapengolahan data memiliki tujuan utama untuk meningkatkan kualitas dan kerapihan data, memastikan keakuratan hasil analisis, dan mengatasi masalah atau kekurangan yang mungkin muncul dalam data mentah (Gede dkk., 2024).

Komponen utama dari pra pengolahan data antara lain adalah (1) transformasi data, yaitu dengan standarisasi data untuk menyesuaikan ukuran dan skala data, (2) normalisasi data, yaitu dengan mentransformasi nilai intensitas piksel citra guna meningkatkan Performa Algoritma, (3) *feature scaling*, yaitu dengan menyesuaikan skala dan distribusi ciri agar lebih konsisten sehingga algoritma pembelajaran mesin dapat bekerja lebih optimal, (4) pelabelan, yaitu dengan memisahkan dan mengelompokkan data berdasarkan kategorinya (Gede dkk., 2024).

Teknik normalisasi ada berbagai macam, salah satunya adalah normalisasi Min-Max. normalisasi Min-Max yaitu dengan merubah nilai-nilai intensitas piksel dalam sebuah citra untuk disesuaikan ke dalam rentang tertentu, biasanya dari 0 hingga 1. Normalisasi Min-Max yang umumnya digunakan dalam konteks citra

agar memiliki persamaan sederhana dan sesuai untuk model DenseNet (Liang dkk., 2021):

$$m = \frac{[m - \min(v)] \times [new_{\max(v)} - new_{\min(v)}]}{[\max(v) - \min(v)] + new_{\min(v)}} \quad (2.1)$$

Persamaan (2.1) merupakan rumus persamaan normalisasi Min-Max, $\min(v)$ merupakan nilai minimum dari atribut, dan $\max(v)$ merupakan nilai maksimum dari atribut (Liang dkk., 2021).

Dengan melakukan pra pengolahan data dengan baik, analisis data menjadi lebih efektif dan hasil prediksi yang dihasilkan menjadi lebih dapat dipercaya (Gede dkk., 2024). Data yang bersih, terstruktur, dan relevan, analisis atau model akan menghasilkan informasi yang lebih dapat diandalkan (Gede dkk., 2024).

2.2.6 Pembagian dan Pelabelan data

Pembagian data dan pelabelan data adalah Langkah penting untuk dilakukan dengan memisahkan data berdasarkan tujuan dan labelnya, hal ini dilakukan untuk mendukung proses pelatihan dan evaluasi model secara efektif. Partisi data yang tepat sangat penting untuk keberhasilan pembelajaran mendalam (Ebid dkk., 2024), karena memberikan distribusi data yang tepat untuk setiap tahap pengembangan model.

Partisi data biasanya terdiri dari tiga subset spesifik, yaitu data pelatihan, yang digunakan untuk melatih model agar mengenali pola dari dataset yang ada; data validasi, yang digunakan untuk mengevaluasi model selama proses pelatihan agar dapat menghindari *overfitting* dan mengoptimalkan hiperparameter; serta data pengujian, yang digunakan untuk mengukur performa model pada data yang tidak pernah dilihat sebelumnya, memberikan gambaran akurat tentang bagaimana model akan bekerja dalam penerapan dunia nyata (Ebid dkk., 2024). Pembagian ini juga penting untuk memastikan bahwa model memiliki kemampuan generalisasi yang baik dan dapat diterapkan dengan efektif pada kasus-kasus di luar data pelatihan.

2.2.7 Augmentasi

Augmentasi data adalah teknik yang digunakan untuk memperbanyak jumlah dan variasi data latih yang akan dipelajari model dengan cara menghasilkan variasi baru dengan cara mentransformasikan data dari data yang sudah ada. Teknik ini sangat penting dalam konteks *deep learning* karena dapat mengatasi keterbatasan jumlah data yang tersedia sehingga dapat menyeimbangkan jumlah data antar kelas yang dipelajari oleh model. Transformasi yang digunakan meliputi penyesuaian kecerahan, memper besar gambar, dan membalik gambar secara horizontal.

Augmentasi data merupakan teknik utama dalam pembelajaran mendalam yang secara signifikan meningkatkan kinerja dan generalisasi model (Islam dkk., 2024). Augmentasi data digunakan untuk memperluas set data pelatihan guna meningkatkan kinerja generalisasi dan akurasi klasifikasi CNN (Tang dkk., 2020).

2.2.8 Cross Validation

Cross Validation (Validasi Silang) adalah serangkaian teknik pengambilan sampel yang digunakan untuk membagi kumpulan data secara berulang-ulang ke dalam kelompok-kelompok yang berbeda untuk pelatihan dan pengujian (Bradshaw dkk., 2023). Bentuk paling dasar dari validasi silang adalah validasi silang k-fold, di mana data dibagi menjadi beberapa bagian terpisah dengan ukuran yang kira-kira sama (Wainer & Cawley, 2021).

Cross validation akan membagi data menjadi lima bagian yang sama seperti dalam penelitian Z. A. Sejuti dan M. S. Islam (Sejuti & Islam, 2023). Setelah data dibagi, model akan dilatih terhadap empat bagian sementara satu bagian sisanya digunakan untuk validasi pelatihan, dan proses ini diulang lima kali dengan merubah bagian data validasi (Nguyen dkk., 2021). Pendekatan ini membantu dalam memberikan evaluasi yang lebih komprehensif tentang kinerja model dengan memastikannya digeneralisasi dengan baik ke data yang tidak terlihat (Rai dkk., 2021).

2.2.9 Hiperparameter

Hiperparameter adalah parameter yang mengendalikan proses pelatihan dan struktur model pembelajaran mendalam (A Ilemobayo dkk., 2024). Pengaturan hiperparameter dilakukan dengan menentukan nilai pada beberapa parameter-parameter untuk mengoptimalkan model *deep learning*. Tidak seperti parameter model yang dipelajari selama pelatihan, hiperparameter ditentukan sebelum pelatihan dimulai dan memiliki peran penting dalam memengaruhi kinerja model (A Ilemobayo dkk., 2024). Tujuan akhirnya adalah menghasilkan konfigurasi yang tepat dan efisien agar dapat diandalkan dalam tugas pendeteksi pneumotoraks dari citra radiografi toraks.

2.2.10 Metode CNN

Metode CNN merupakan model *deep learning* yang paling baik untuk mengklasifikasi penyakit pada dada (Monshi dkk., 2019). Metode ini menjadi populer dalam untuk masalah segmentasi karena metode ini mampu mempelajari secara langsung dari data masukan (Abbas dkk., 2019). Metode ini menghadirkan terobosan yang signifikan dalam bidang *computer vision* dengan meningkatkan kemampuan representasi yang merupakan kunci utama dalam merancang arsitektur jaringan untuk menangani tugas-tugas kompleks seperti analisis citra (Fang dkk., 2019).

Metode CNN terdiri dari lapisan masukan, lapisan keluaran, dan beberapa lapisan tersembunyi yang dapat dikelompokkan menjadi lapisan konvolusi, lapisan penggabungan, lapisan ReLU, dan lapisan terhubung penuh (Xie dan Li, 2019). Berdasarkan lapisan tersebut, CNN dapat mempelajari ciri secara implisit (Soebroto, 2019). Metode CNN menghasilkan ekstraksi filter yang dilatih untuk tujuan tertentu, contohnya seperti pada lapisan pertama bisa difokuskan untuk identifikasi tepian, kemudian lapisan kedua bisa difokuskan ke identifikasi bentuk, dan filter lapisan berikutnya bisa lebih diarahkan untuk mempelajari bagian-bagian parsial dari objek, baik yang terlihat sedikit maupun yang terlihat cukup banyak serta lapisan terakhir digunakan untuk mengidentifikasi objek (Soebroto, 2019). Ketersediaan arsitektur modifikasi pada CNN seperti AlexNet, VGGNet, Xception,

ResNet, dan DenseNet sangat membantu dalam proses ekstraksi ciri yang signifikan (Varshni dkk., 2019). Dibandingkan dengan jaringan saraf tradisional, CNN memiliki tiga ciri utama: pola konektivitas lokal, pembagian bobot, dan penggunaan kernel konvolusi ganda (Xie dan Li, 2019).

Pada penelitian ini, DenseNet digunakan sebagai arsitektur pada metode CNN dalam mempelajari data citra radiografi toraks untuk mendeteksi adanya tanda-tanda pneumotoraks karena memiliki sifat menghubungkan setiap lapisan ke setiap lapisan selanjutnya agar dapat menangkap informasi pada citra dalam skala yang lebih besar dibandingkan dengan metode pengolahan citra tradisional.

2.2.11 Arsitektur DenseNet

DenseNet merupakan sebuah jenis arsitektur CNN yang memiliki karakteristik menghubungkan setiap lapisan ke setiap lapisan lainnya dengan metode *feed-forward* (Tabrizchi dkk., 2021). Arsitektur ini terdiri dari 1 tahap operasi konvolusi, 1 tahap operasi *pooling*, 4 tahap operasi blok padat, 3 tahap operasi lapisan transisi, 1 lapisan tersembunyi dengan fungsi aktivasi ReLU dan *dropout*, serta lapisan keluaran softmax (Bintoro & Harjoko, 2022).

Dalam arsitektur DenseNet, setiap lapisan menerima masukan tambahan dari semua lapisan sebelumnya dan selanjutnya akan berbagi hasil cirinya kepada lapisan berikutnya (Tabrizchi dkk., 2021). Ini berarti setiap lapisan menerima hasil dari seluruh lapisan sebelumnya, menciptakan jaringan yang lebih padat dan efisien dalam hal jumlah saluran (Tabrizchi dkk., 2021). Selain itu DenseNet dapat mengurangi masalah hilangnya gradien dan telah terbukti efektif dalam mendiagnosis penyakit berdasarkan pencitraan medis (Hasan dkk., 2021).

Arsitektur DenseNet di atas terdiri dari 2 bagian yaitu lapisan ekstraksi dan lapisan klasifikasi. Lapisan masukan menggunakan matriks $224 \times 224 \times 3$. Ukuran *input* digunakan berdasarkan ukuran data citra latih yang telah diolah sebelumnya. Jumlah saluran pada lapisan masukan adalah 3. Lapisan ekstraksi pertama adalah lapisan konvolusi dengan ukuran 7×7 dengan langkah 2. Lapisan ekstraksi kedua yang digunakan pada penelitian ini adalah lapisan *max pooling*. Operasi *max pooling* digunakan untuk menghitung nilai maksimum setiap jalur dari peta ciri.

Dengan bantuan arsitektur DenseNet, metode CNN menjadi lebih canggih dan dapat menangkap informasi citra dalam skala yang lebih besar dibandingkan dengan metode pengolahan citra tradisional (Hasan dkk., 2021).

2.2.12 Confusion Matrix

Confusion matrix adalah tabel untuk mengevaluasi kinerja model dalam klasifikasi, yang memiliki kolom perbandingan antara prediksi model dan label yang sebenarnya (Xu dkk., 2020). Dalam kasus prediksi atau klasifikasi dua kelas, *confusion matrix* berbentuk tabel dengan kolom 2x2. *Confusion matrix* dapat menghitung seberapa banyak prediksi benar atau salah yang dibuat oleh model untuk setiap kelas (Xu dkk., 2020), sehingga dapat memberi pemahaman seberapa tinggi tingkat kesalahan yang keakuratan yang dibuat oleh model (Markoulidakis dkk., 2021). Bentuk *Confusion matrix* dapat dilihat pada Tabel 2.1.

Tabel 2.1 Confusion matrix

Prediksi \ Label	Positif	Negatif
Positif	TP	FP
Negatif	TN	FN

Tabel 2.1 memberikan penjelasan secara detail mengenai bagaimana model memprediksi sebuah kasus, penjelasan ini meliputi jumlah kesalahan dan keakuratan yang dibuat oleh model sehingga performa dapat dievaluasi secara keseluruhan. Penjelasan secara rinci pada setiap kolom sebagai berikut.

1. TP (*True positive*)

TP adalah jumlah kasus yang sebenarnya positif dan diprediksi positif dengan benar oleh model.

2. FP (*False positive*)

FP adalah jumlah kasus yang sebenarnya negatif tetapi diprediksi positif oleh model, hal ini merupakan kesalahan prediksi.

3. TN (*True negative*)

TN adalah jumlah kasus yang sebenarnya negatif dan diprediksi negatif dengan benar oleh model.

4. FN (*False negative*)

FN adalah jumlah kasus yang sebenarnya positif tetapi diprediksi negatif oleh model, yang juga merupakan kesalahan prediksi.

2.2.13 Evaluasi Model

Evaluasi model merupakan proses mengukur kinerja model terhadap data yang belum pernah dilihat selama pelatihan, hal ini dilakukan untuk mengukur apakah model CNN yang dihasilkan dari pengaturan hiperparameter apakah sudah optimal, *overfitting* atau *underfitting*. Evaluasi model menggunakan matrik evaluasi, yaitu alat atau metrik yang digunakan untuk mengevaluasi kinerja model pembelajaran mesin atau sistem klasifikasi berdasarkan prediksi yang dihasilkan (Ali dkk., 2021). Matrik evaluasi antara lain meliputi akurasi, presisi, *recall*, F1-Score, *Receiver Operating Characteristic* (ROC) dan *Area Under the Curve* (AUC).

Metrik akurasi digunakan untuk mengukur seberapa sering model dapat benar-benar memprediksi keberadaan atau ketiadaan pneumotoraks dari citra sinar-X toraks dengan benar sesuai dengan labelnya (Ali dkk., 2021), berikut persamaan metrik akurasi :

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.2)$$

Pada persamaan tersebut TP adalah *true positive*, TN adalah *true negative*, FP adalah *false positive*, dan FN adalah *false negative*.

Metrik presisi digunakan untuk mengukur seberapa akurat model dalam memprediksi keberadaan pneumotoraks ketika model mengklasifikasikan citra dengan label positif (Ali dkk., 2021), berikut persamaan metrik presisi :

$$Presisi = \frac{TP}{TP+FP} \quad (2.3)$$

Pada persamaan tersebut TP adalah *true positive* dan FP adalah *false positive*.

Metrik Recall digunakan untuk mengukur seberapa baik model dalam menemukan semua kasus yang sebenarnya positif di antara semua kasus positif yang tersedia (Ali dkk., 2021), berikut persamaan metrik recal :

$$Recall = \frac{TP}{TP+FN} \quad (2.4)$$

Pada persamaan tersebut TP adalah *true positive* dan FN adalah *false negatives*.

Metrik F1-Scores merupakan nilai rata-rata dari metrik presisi dan recall, metrik ini memberikan hasil yang lebih baik tentang keseimbangan antara kedua metrik tersebut, sehingga berguna saat kelas target tidak seimbang (Ali dkk., 2021), berikut persamaan metrik F1-Scores :

$$F1 - Scores = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (2.5)$$

Pada persamaan tersebut, F1 Scores dihitung menggunakan hasil dari presisi dan recall.

Metrik ROC adalah grafik yang menunjukkan kemampuan model dalam membedakan kelas positif dan negatif dengan menggambarkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai batas ambang klasifikasi (Yao dkk., 2022). Berikut persamaan yang membentuk TPR dan FPR :

$$TPR = \frac{TP}{TP+FN} \quad (2.6)$$

$$FPR = \frac{FP}{FP+TN} \quad (2.7)$$

Melalui persamaan tersebut, grafik pada metrik ROC dapat dibuat berdasarkan nilai TPR dan FPR.

Metrik AUC adalah nilai yang mengukur luas area di bawah kurva ROC sehingga dapat menunjukkan seberapa baik model membedakan kelas positif dan negatif, dengan nilai antara 0 hingga 1, di mana semakin tinggi AUC, semakin baik kinerja model (Yao dkk., 2022).

$$AUC = \sum_{i=1}^{n-1} (FPR_{i+1} + FPR_i) \times \frac{(TPR_{i+1} + TPR_i)}{2} \quad (2.8)$$

Melalui persamaan tersebut, dapat diketahui seberapa baik model dapat membedakan kelas positif dan negatif berdasarkan metrik ROC.