

## **BAB 2**

### **DASAR TEORI**

#### **2.1 KAJIAN PUSTAKA**

Penelitian yang dilakukan oleh E. Mique Jr dan A. Malicdem adalah tentang pengembangan model segmentasi citra paru-paru menggunakan arsitektur Deep Residual U-Net. Penelitian ini bertujuan untuk mengembangkan model yang dapat mengidentifikasi penyakit paru-paru dengan fokus pada citra sinar-X (CXR) Model yang dikembangkan menggunakan 562 citra CXR dan masker paru-paru, dengan 70% digunakan sebagai data pelatihan dan 30% sebagai data pengujian. Model ini dilatih selama 40 epoch dengan ukuran batch 16 dan menggunakan koefisien Dice untuk mengevaluasi hasil segmentasi. Hasil penelitian menunjukkan bahwa model yang dikembangkan berhasil mencapai koefisien Dice sebesar 0,9860. Model ini dapat digunakan untuk mengklasifikasikan penyakit paru-paru dengan fokus pada citra yang telah di-segmentasi [10].

Penelitian kedua yaitu Penelitian yang berjudul "*U-Net Based Chest X-ray Segmentation with Ensemble Classification for Covid-19 and Pneumonia*" oleh K. A. S. H. Kumarasinghe, S. L. Kolonne, K. C. M. Fernando, dan D. Meedeniya bertujuan untuk mengembangkan model segmentasi citra sinar-X paru-paru dengan menggunakan arsitektur U-Net dan menerapkan klasifikasi ensemble untuk mendeteksi Covid-19 dan pneumonia. Metode yang diusulkan dalam studi ini melibatkan implementasi model segmentasi berbasis *deep learning* menggunakan arsitektur U-Net. Selain itu, pendekatan klasifikasi ensemble diterapkan untuk membedakan antara kasus pneumonia normal dan pneumonia Covid-19 dari citra sinar-X paru-paru. Ensemble classification dapat meningkatkan akurasi dan kehandalan deteksi dengan menggabungkan berbagai metode klasifikasi. Hasil penelitian menunjukkan bahwa model yang dikembangkan dapat memberikan segmentasi citra yang akurat dan mampu mengklasifikasikan dengan baik antara pneumonia normal dan pneumonia Covid-19. Oleh karena itu, studi ini membuka pintu untuk pengembangan lebih lanjut

dalam penerapan teknologi citra sinar-X untuk diagnosis penyakit pernapasan, terutama dalam konteks pandemi Covid-19 [11].

Penelitian ketiga melakukan dengan Studi yang berjudul "*Automatic Lung Segmentation in Chest X-ray Images Using Improved U-Net*" yang dilakukan oleh Wufeng Liu, Jiaxin Luo, Yan Yang, Wenlian Wang, Junkui Deng, dan Liang Yu bertujuan untuk mengembangkan metode segmentasi otomatis untuk wilayah paru-paru dalam citra sinar-X paru-paru, dengan memanfaatkan model U-Net yang telah ditingkatkan. Metode yang diusulkan dalam studi ini menghadirkan peningkatan pada jaringan U-Net dengan menggunakan *pre-training* Efficientnet-b4 sebagai *encoder* dan *decoder* yang disesuaikan. Pendekatan ini dirancang untuk meningkatkan kemampuan representasi fitur dari model, khususnya dalam tugas segmentasi paru-paru pada citra sinar-X.

Hasil eksperimen yang dilaporkan dalam penelitian ini menunjukkan bahwa metode yang diusulkan berhasil meningkatkan koefisien Dice dan Indeks Jaccard, yang merupakan matrik evaluasi kualitas segmentasi paru-paru. Selain itu, metode ini mampu meningkatkan akurasi segmentasi paru-paru pada citra sinar-X paru-paru. Hasil eksperimen yang positif ini menunjukkan bahwa pendekatan yang diterapkan dalam penelitian memiliki potensi untuk meningkatkan ketepatan dan konsistensi dalam proses segmentasi otomatis [12].

Penelitian keempat dengan Judul "*Attention U-Net Based Adversarial Architectures for Chest X-ray Lung Segmentation*" oleh Gusztav Gaál, Balázs Maga, dan András Lukács bertujuan untuk mengembangkan pendekatan segmentasi citra sinar-X paru-paru dengan menggunakan *Attention* U-Net dan arsitektur adversarial. Metode yang diusulkan dalam studi ini memanfaatkan jaringan saraf konvolusional (CNN) untuk melakukan segmentasi paru-paru pada citra sinar-X. Segmentasi paru-paru merupakan langkah kritis dalam diagnosis penyakit paru-paru, termasuk kondisi serius seperti kanker paru-paru, tuberkulosis, pneumonia, dan bahkan COVID-19. Selain itu, penelitian ini mengintegrasikan metode deteksi berbantuan komputer ke dalam alur kerja diagnostik radiologis. Hal ini bertujuan untuk mengurangi beban kerja dokter, serta meningkatkan analisis kuantitatif dalam proses diagnosa. Hasil penelitian menunjukkan bahwa pendekatan yang diusulkan mampu menghasilkan

segmentasi paru-paru dengan tingkat kesamaan Dice (DSC) yang tinggi, mencapai 97,5% pada dataset JSRT [13].

Penelitian yang kelima yaitu "*Automatic Lung Segmentation on Chest X-rays Using Self-Attention Deep Neural Network*" yang dilakukan oleh Minki Kim dan Byoung-Dai Lee mengusulkan metode berbasis *deep learning* untuk melakukan segmentasi area paru-paru pada citra sinar-X. Aspek inovatif dari metode yang diusulkan adalah penggunaan modul perhatian sendiri (*self-Attention*), yang menggabungkan hasil dari modul perhatian kanal dan modul perhatian spasial untuk menghasilkan peta perhatian. Peta perhatian ini kemudian dikalikan secara elemen dengan peta fitur masukan dan ditambahkan ke peta fitur masukan untuk pembelajaran residual. Para penulis menerapkan modul perhatian sendiri pada arsitektur U-Net untuk segmentasi area paru-paru dan mencapai kinerja yang setara atau lebih baik daripada jaringan segmentasi citra medis yang sudah ada, dilihat dari skor Dice. Studi ini memberikan kontribusi yang signifikan dalam pengembangan metode segmentasi otomatis paru-paru untuk mendukung diagnosis penyakit paru-paru melalui citra sinar-X. Penelitian ini dipublikasikan dalam jurnal "Sensors" pada tahun 2021 [14].

Jurnal "*Residual Attention U-Net for Automated Multi-Class Segmentation of COVID-19 Chest CT Images*" oleh Xiaocong Chen, Lina Yao, dan Yu Zhang membahas penggunaan model *Residual Attention U-Net* untuk meningkatkan akurasi dan efisiensi segmentasi berbagai jenis lesi pada gambar CT dada pasien COVID-19, seperti *ground-glass opacities, consolidations, dan pleural effusions*. Model ini menggabungkan keunggulan *Residual Network* (ResNet) dan *Attention Mechanism* dengan arsitektur U-Net, yang memungkinkan fokus pada bagian gambar yang lebih relevan dan mengatasi masalah degradasi jaringan. Hasil penelitian menunjukkan bahwa *Residual Attention U-Net* secara signifikan lebih akurat dibandingkan metode konvensional, dengan matrik seperti *Dice Similarity Coefficient, IoU, Precision, dan Recall* yang lebih tinggi, serta lebih efisien dalam waktu komputasi. Model ini juga mampu mendeteksi lesi-lesi kecil yang sering terlewatkan oleh metode lain dan menunjukkan kemampuan generalisasi yang baik ketika diuji pada dataset dari berbagai sumber, menjadikannya alat yang

potensial untuk aplikasi klinis dalam diagnosis dan pemantauan pasien COVID-19 [15].

Jurnal "*Automatic COVID-19 CT Segmentation using U-Net Integrated Spatial and Channel Attention Mechanism*" oleh Tongxue Zhou, Stéphane Canu, dan Su Ruan mengkaji pengembangan model segmentasi otomatis untuk gambar CT dada pasien COVID-19 menggunakan arsitektur U-Net yang ditingkatkan dengan mekanisme atensi spasial dan kanal. Penelitian ini bertujuan untuk meningkatkan akurasi dalam mendeteksi dan mengsegmentasi lesi terkait COVID-19, seperti ground-glass opacities dan konsolidasi, yang kritis untuk diagnosis dan penanganan penyakit. Mekanisme atensi spasial memungkinkan model untuk fokus pada lokasi-lokasi gambar yang lebih relevan, sementara mekanisme atensi kanal membantu menekankan fitur-fitur penting dalam setiap kanal gambar CT. Hasil penelitian menunjukkan bahwa model ini memberikan performa yang superior dalam hal matrik evaluasi seperti Dice Similarity Coefficient (DSC), Intersection over Union (IoU), *Precision*, dan *Recall* dibandingkan dengan U-Net konvensional. Pengujian pada dataset CT dari berbagai sumber juga menunjukkan kemampuan model ini untuk melakukan generalisasi dengan baik, menjadikannya solusi yang efisien dan andal untuk segmentasi otomatis pada aplikasi medis COVID-19 [16].

Dalam jurnal "*Attention U-Net++: A Nested Attention-Aware U-Net for Liver CT Image Segmentation*" yang diterbitkan dalam *Computers in Biology and Medicine*, Volume 117 tahun 2020, penelitian dilakukan untuk mengembangkan metode segmentasi citra CT liver yang disebut "Attention U-Net++". Metode ini memanfaatkan nested attention untuk meningkatkan akurasi segmentasi citra, dengan fokus pada identifikasi tepi dan struktur internal organ. Evaluasi dilakukan menggunakan dataset citra CT liver dan menunjukkan peningkatan kinerja dalam memperhatikan fitur-fitur penting, seperti lesi atau anomali, yang dapat meningkatkan aplikabilitasnya dalam diagnosis dan analisis klinis [17].

Berdasarkan judul "*Improving Pneumonia Identification on Chest X-rays with Deep learning: A Transfer Learning Approach*" yang diterbitkan dalam IEEE Access, dapat diasumsikan bahwa jurnal tersebut membahas penggunaan pendekatan *transfer learning* dalam *deep learning* untuk meningkatkan

identifikasi pneumonia pada citra sinar-X dada. Metode yang digunakan mungkin melibatkan penggunaan model *deep learning* yang telah dilatih sebelumnya pada dataset besar untuk tugas-tugas serupa, yang kemudian disesuaikan dan dioptimalkan untuk tujuan identifikasi pneumonia. Proses transfer *learning* ini mungkin memungkinkan model untuk belajar fitur-fitur penting yang relevan untuk pengenalan pneumonia, bahkan dengan dataset yang lebih kecil.

Hasil yang mungkin dicapai dalam jurnal ini termasuk peningkatan dalam akurasi identifikasi pneumonia pada citra sinar-X dada, dibandingkan dengan metode-metode tradisional atau model-model *deep learning* lainnya. Evaluasi kinerja model mungkin dilakukan menggunakan berbagai matrik, seperti akurasi, sensitivitas, dan spesifisitas, serta perbandingan dengan penelitian sebelumnya dalam bidang tersebut [18].

Jurnal "*Image Segmentation Using Deep learning: A Survey*" memberikan tinjauan luas tentang kemajuan teknik segmentasi citra yang didorong oleh pembelajaran mendalam. Segmentasi citra, sebuah tugas penting dalam visi komputer dan pemrosesan citra, memiliki aplikasi dalam berbagai bidang seperti pemahaman adegan, analisis citra medis, persepsi robotik, pengawasan video, realitas tertambah, dan kompresi gambar.

Survei ini mencakup berbagai metode segmentasi berbasis pembelajaran mendalam, yang dikategorikan terutama berdasarkan arsitektur model dasar mereka. Arsitektur kunci yang dibahas meliputi *Fully Convolutional Networks* (FCNs), model *encoder-decoder*, pendekatan berbasis multi-skala dan piramida, jaringan rekuren, model perhatian visual, dan jaringan adversarial generatif (GAN). Setiap pendekatan ini menawarkan kekuatan dan tantangan unik yang berkontribusi pada ketahanan dan akurasi tugas segmentasi citra.

Misalnya, FCNs, salah satu metode perintis di bidang ini, memungkinkan prediksi piksel-demi-piksel yang padat dengan menggunakan lapisan konvolusi untuk menghasilkan peta segmentasi dengan ukuran yang sama seperti gambar input. Pendekatan ini telah meningkatkan kinerja segmentasi semantik secara signifikan tetapi memiliki keterbatasan dalam hal inferensi waktu nyata dan penanganan konteks global.

Arsitektur *encoder-decoder* , model populer lainnya, menggunakan *encoder* untuk menangkap konteks gambar dan *decoder* untuk menghasilkan peta segmentasi yang terperinci. Integrasi koneksi lewati dalam model ini membantu menggabungkan informasi semantik tingkat tinggi dengan detail penampilan tingkat rendah, meningkatkan akurasi segmentasi.

Survei ini juga menyoroti penggunaan teknik canggih seperti GAN, yang terdiri dari generator dan diskriminator yang bekerja secara bersamaan untuk menghasilkan dan memperbaiki peta segmentasi. Model-model ini telah terbukti meningkatkan kualitas segmentasi dengan menghasilkan representasi data gambar yang lebih realistis dan akurat .

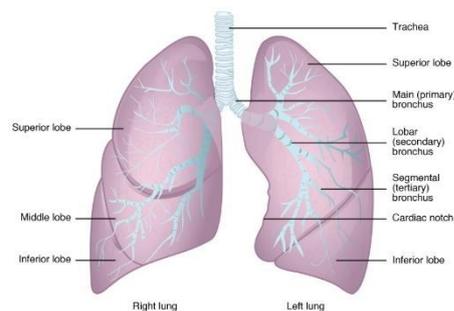
Selain itu, jurnal ini membahas tantangan yang dihadapi di bidang ini, seperti kebutuhan akan dataset anotasi besar, kompleksitas komputasi dari pelatihan jaringan mendalam, dan kesulitan dalam menggeneralisasi model di berbagai dataset dan aplikasi. Jurnal ini juga mengidentifikasi arah penelitian masa depan yang menjanjikan, termasuk pengembangan arsitektur yang lebih efisien, fungsi kehilangan yang lebih baik, dan teknik untuk memanfaatkan data tidak berlabel untuk pembelajaran semi-terawasi dan tidak terawasi.

Secara keseluruhan, survei ini memberikan tinjauan komprehensif tentang keadaan terkini segmentasi citra berbasis pembelajaran mendalam, menyoroti pentingnya dan upaya yang sedang berlangsung untuk memajukan area kritis dari visi komputer ini [19].

## 2.2 DASAR TEORI

### 2.2.1 Paru-Paru

Paru-paru merupakan sepasang organ dengan tekstur kenyal yang berisi udara. Proses penghantaran udara dibantu oleh trakea. Paru-paru terletak di bagian atas rongga dada, dibatasi di sisi oleh otot dan rusuk, serta di bagian bawah dibatasi oleh diafragma yang merupakan otot kuat. Terdapat dua bagian paru-paru, yaitu paru-paru kanan (pulmo dekster) yang memiliki 3 lobus, dan paru-paru kiri (pulmo sinister) yang terdiri dari dua lobus [20]. Paru-paru berperan sebagai tempat pertukaran oksigen dari udara dengan karbon dioksida dari darah. Oksigen diambil oleh paru-paru dari udara yang dihirup, kemudian masuk ke dalam aliran darah dan didistribusikan ke seluruh sel dalam tubuh. Organ paru-paru turut terlibat dalam proses sintesis, penyimpanan, transformasi, dan degresi xat. Anatomi paru-paru dan jantung dapat dilihat pada Gambar 2.1 [21].



**Gambar 2. 1 Anatomi Paru-Paru [22]**

Paru-paru juga dilapisi oleh membran pleura, yang terdiri dari dua lapisan: pleura parietal yang melapisi dinding rongga dada, dan pleura visceral yang melapisi paru-paru itu sendiri. Antara kedua lapisan ini terdapat cairan pleura yang berfungsi untuk mengurangi gesekan saat paru-paru mengembang dan mengempis selama pernapasan .

Di dalam paru-paru, udara yang masuk melalui trakea akan melewati bronkus utama yang kemudian bercabang menjadi bronkus sekunder dan lebih lanjut lagi menjadi bronkiolus. Bronkiolus ini berakhir di alveolus, struktur kecil mirip kantong yang dikelilingi oleh kapiler darah. Di sinilah pertukaran gas terjadi: oksigen dari udara masuk ke dalam darah, sementara karbon dioksida dari

darah dilepaskan ke dalam alveolus untuk kemudian dikeluarkan saat kita menghembuskan napas .

Fungsi paru-paru tidak hanya terbatas pada pertukaran gas. Paru-paru juga memiliki peran penting dalam menjaga keseimbangan pH darah melalui pengaturan kadar karbon dioksida. Selain itu, paru-paru berperan dalam sistem kekebalan tubuh dengan menyaring partikel asing dan mikroorganisme yang terhirup, serta menghasilkan sejumlah zat penting seperti surfaktan, yang membantu menjaga alveolus tetap terbuka dan mencegah kolaps .

Mekanisme pernapasan dimulai ketika diafragma dan otot antar tulang rusuk berkontraksi, memperbesar rongga dada dan menurunkan tekanan di dalam paru-paru, sehingga udara masuk. Saat diafragma dan otot-otot ini relaksasi, rongga dada mengecil, tekanan meningkat, dan udara dikeluarkan dari paru-paru. Proses ini terjadi secara otomatis dan berkesinambungan untuk memastikan suplai oksigen yang cukup ke seluruh tubuh dan pembuangan karbon dioksida yang efektif .

Secara keseluruhan, paru-paru merupakan organ vital yang kompleks dengan berbagai fungsi penting bagi kehidupan. Dari pertukaran gas esensial hingga peran dalam sistem imun dan regulasi keseimbangan asam-basa, kesehatan paru-paru sangatlah krusial untuk mempertahankan fungsi tubuh yang optimal. Pengetahuan mendalam tentang anatomi dan fisiologi paru-paru terus berkembang, memungkinkan penanganan yang lebih baik terhadap berbagai penyakit paru-paru dan kondisi pernapasan [23].

### 2.2.2 Pneumonia

Pneumonia adalah infeksi yang menyebabkan inflamasi pada kantung-kantung udara (alveoli) di salah satu atau kedua paru-paru. Alveoli bisa terisi dengan cairan atau nanah, menyebabkan gejala seperti batuk berdahak atau bernanah, demam, menggigil, dan kesulitan bernapas. Pneumonia bisa disebabkan oleh berbagai organisme, termasuk bakteri, virus, dan jamur. Penyakit ini bisa berkisar dari ringan hingga mengancam jiwa, dan lebih serius pada bayi, anak kecil, orang tua, dan orang dengan masalah kesehatan atau sistem kekebalan tubuh yang lemah [24].



**Gambar 2. 2 Rontgen Dada Pneumonia Bacetria**

Secara klinis pneumonia didefinisikan sebagai suatu peradangan parenkim paru distal dari bronkiolus terminalis yang mencakup bronkiolus respiratorius dan alveoli serta menimbulkan konsolidasi jaringan paru dan gangguan pertukaran gas setempat [25]. Pneumonia dibedakan menjadi dua yaitu pneumonia komunitas dan pneumonia nosokomial. Pneumonia komunitas adalah pneumonia yang terjadi akibat infeksi di luar rumah sakit, sedangkan pneumonia nosokomial adalah pneumonia yang terjadi lebih dari 48 jam atau lebih setelah dirawat di rumah sakit [26].

World Health Organization (WHO) menyatakan bahwa pneumonia adalah suatu penyakit yang terbentuk dari infeksi akut dari daerah saluran pernafasan bagian bawah yang secara spesifik mempengaruhi paru-paru. Pneumonia juga didefinisikan sebagai salah satu penyakit infeksi saluran pernafasan akut yang mengenai jaringan alveolus pada paru-paru

Pneumonia dapat disebabkan oleh berbagai mikroorganisme seperti bakteri, virus, jamur, dan protozoa. Pneumonia komunitas yang diderita oleh

masyarakat luar negeri banyak disebabkan gram positif, sedangkan pneumonia rumah sakit banyak disebabkan gram negatif. Dari laporan beberapa kota di Indonesia ditemukan dari pemeriksaan dahak penderita komunitas adalah bakteri gram negatif [26].

Penyebab pneumonia adalah berbagai macam virus, bakteri atau jamur. Bakteri penyebab pneumonia yang tersering adalah pneumokokus (*Streptococcus pneumoniae*), HiB (*Haemophilus influenzae type b*) dan stafilokokus (*Staphylococcus aureus*). Hasil penelitian menunjukkan bahwa 70% penyakit pneumonia disebabkan oleh bakteri. Bakteri penyebab pneumonia tersering adalah *Streptococcus pneumoniae* (50%) dan *Haemophilus influenzae* (20%). Virus penyebab pneumonia sangat banyak, misalnya rhinovirus, respiratory syncytial virus (RSV), virus influenza [27].

Penyebab selain bakteri antara lain seperti aspirasi (makanan atau asam lambung, benda asing, hidrokarbon dan substansi lipoid), reaksi hipersensitivitas, obat atau radiasi yang menginduksi pneumonitis [28]. Pneumonia dapat diklasifikasikan dalam berbagai cara, klasifikasi paling sering ialah menggunakan klasifikasi berdasarkan tempat didapatkannya pneumonia (pneumonia komunitas dan pneumonia nosokomial), tetapi pneumonia juga dapat diklasifikasikan berdasarkan area paru yang terinfeksi (lobar pneumonia, multilobar pneumonia, bronchial pneumonia, dan interstitial pneumonia) atau agen kausatif. Pneumonia juga sering diklasifikasikan berdasarkan kondisi yang mendasari pasien, seperti pneumonia rekurens (pneumonia yang terjadi berulang kali, berdasarkan penyakit paru kronik), pneumonia aspirasi (alkoholik, usia tua), dan pneumonia pada gangguan imun (pneumonia pada pasien transplantasi organ, onkologi, dan AIDS).

Gejala pneumonia bakterial dapat meliputi demam, batuk yang menghasilkan lendir berwarna kuning atau hijau, napas yang cepat, nyeri dada, kelelahan, dan gejala lain yang terkait dengan infeksi saluran pernapasan. Pengobatan pneumonia bakterial melibatkan pemberian antibiotik untuk membunuh bakteri penyebab infeksi.

### **2.2.3 Citra**

Citra merupakan objek abstrak yang tidak nyata serta tidak dapat digambarkan secara fisik dan tidak dapat diukur secara sistematis tampaknya mengandung kekeliruan. Dalam konteks umum dan ilmiah, citra atau gambar adalah representasi visual dari objek atau pemandangan yang dapat diamati melalui berbagai media seperti foto, lukisan, atau gambar digital [29]. Citra dapat digambarkan secara fisik pada media seperti kertas atau layar komputer, dan citra digital dapat diukur serta dianalisis menggunakan teknik pengolahan citra [30]. Penggunaan citra mencakup berbagai bidang seperti kedokteran (CT scan dan MRI), astronomi, dan geografi (peta satelit) [31].

Pengolahan citra melibatkan teknik untuk meningkatkan, menganalisis, dan memahami citra, termasuk segmentasi, kompresi, pemulihan citra, dan pengenalan pola. Citra digital diukur dengan parameter seperti piksel, resolusi, kontras, dan intensitas, memungkinkan ekstraksi informasi yang sistematis. Mungkin yang dimaksud adalah citra dalam konteks tertentu, seperti citra dalam pikiran atau konsep abstrak, yang memang tidak dapat digambarkan atau diukur secara fisik.

Selain itu, pengolahan citra memiliki aplikasi yang luas dalam berbagai bidang, termasuk medis, forensik, astronomi, dan pengawasan keamanan. Misalnya, dalam bidang medis, teknik pengolahan citra digunakan untuk meningkatkan kualitas gambar hasil scan medis seperti MRI dan CT scan, sehingga mempermudah dokter dalam mendiagnosis penyakit. Dalam bidang forensik, analisis citra digital dapat membantu dalam identifikasi pelaku kejahatan melalui pengenalan wajah atau analisis sidik jari digital .

Namun, ada juga konsep citra yang lebih abstrak dan tidak dapat diukur secara fisik, seperti citra dalam pikiran atau ide. Citra ini sering kali berhubungan dengan persepsi dan representasi mental seseorang terhadap suatu objek atau konsep. Studi tentang citra mental melibatkan pemahaman bagaimana otak membentuk, menyimpan, dan mengolah representasi visual tanpa adanya stimulasi visual langsung. Meskipun tidak dapat diukur dengan parameter fisik seperti piksel atau resolusi, citra mental memainkan peran penting dalam kognisi dan persepsi manusia .

Pengolahan citra, baik dalam konteks digital maupun mental, merupakan area penelitian yang terus berkembang, menawarkan potensi besar untuk inovasi dan aplikasi baru di masa depan. Teknologi baru seperti kecerdasan buatan dan pembelajaran mesin semakin memperluas kemampuan kita dalam mengolah dan memahami citra, membuka jalan bagi perkembangan yang lebih canggih dan efisien di berbagai bidang.

#### 2.2.4 Fungsi Aktivasi

Fungsi aktivasi adalah fungsi pada sebuah *layer neural network* yang digunakan untuk menghitung *output* dari nilai inputnya. Fungsi aktivasi menentukan bagaimana sinyal yang masuk ke neuron jaringan saraf diterjemahkan ke dalam *output*. Dalam konteks segmentasi citra, fungsi aktivasi berperan dalam membantu jaringan saraf memahami dan memetakan piksel ke kelas yang tepat, seperti objek atau latar belakang. Berikut fungsi aktivasi yang digunakan :

##### 2.2.4.1 Sigmoid

Fungsi ini berfungsi untuk mengubah input menjadi nilai antara 0 dan 1. Dalam segmentasi, sigmoid sering digunakan dalam lapisan *output* untuk masalah segmentasi biner, di mana tugasnya adalah mengklasifikasikan setiap piksel ke dalam satu dari dua kelas [32][33]. Secara matematis, fungsi ini dirumuskan dalam persamaan :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.1)$$

Keterangan :

- x : Variabel independen, yang bisa berupa nilai kontinu.
- e : Basis dari logaritma natural, kira-kira bernilai 2.71828.

#### 2.2.4.2 ReLu(*Rectified Linear Unit*)

Fungsi ini memberikan *output* sama dengan input, jika input positif, dan nol jika input negatif. ReLu sering digunakan di lapisan tersembunyi dari jaringan saraf karena membantu dalam menangani masalah *vanishing gradient* dan mempercepat konvergensi. Fungsi ini secara umum memiliki batas bawah yaitu bilangan nol, yang berarti jika *outputnya* positif ( $x > 0$ ) maka akan menghasilkan nilai yang sama ( $X = x$ ) dan jika *outputnya* negatif ( $x \leq 0$ ) maka akan menghasilkan nilai nol ( $x = 0$ ) [34]. Secara sistematis, fungsi ini dirumuskan pada persamaan :

$$F(x) = \max(0, x) \quad (2.2)$$

Fungsi ReLU (*Rectified Linear Unit*) telah menjadi pilihan utama untuk aktivasi di dalam lapisan tersembunyi jaringan saraf tiruan. Salah satu keunggulan utama dari ReLU dibandingkan dengan fungsi aktivasi sebelumnya, seperti sigmoid, adalah kemampuannya untuk mengatasi masalah *vanishing gradient*. Masalah ini sering terjadi pada jaringan yang sangat dalam di mana gradien yang dihitung selama *backpropagation* menjadi sangat kecil, menyebabkan pembaruan bobot menjadi tidak signifikan dan memperlambat pembelajaran. Dengan ReLU, gradien untuk nilai positif adalah konstan (1), yang menjaga aliran gradien tetap besar dan stabil selama proses pelatihan [35].

Selain itu, ReLU mempercepat konvergensi jaringan saraf. Fungsi aktivasi lainnya seperti sigmoid dan tanh mengalami saturasi di kedua ujungnya, yang menyebabkan gradien sangat kecil dan memperlambat pembelajaran. ReLU, dengan sifat linearnya untuk nilai positif, membantu model belajar lebih cepat karena tidak memiliki efek saturasi untuk nilai positif. Selain itu, komputasi ReLU sangat sederhana dan efisien, hanya memerlukan operasi perbandingan dan maksimal, sehingga mengurangi overhead komputasi selama pelatihan [36].

Namun, ReLU juga memiliki beberapa kelemahan. Salah satu masalah utama adalah "*dying ReLU*," di mana sejumlah besar neuron bisa menjadi tidak aktif dan hanya mengeluarkan nilai nol untuk semua input. Ini terjadi ketika input negatif besar atau bobot menjadi negatif besar selama pelatihan, menyebabkan

neuron tersebut tidak pernah diaktifkan kembali. Untuk mengatasi masalah ini, beberapa varian dari ReLU telah dikembangkan, seperti Leaky ReLU, yang memperkenalkan kemiringan kecil untuk nilai negatif sehingga neuron tersebut tetap memiliki gradien non-nol dan dapat berkontribusi pada pembelajaran .

Secara keseluruhan, ReLU telah membuktikan dirinya sebagai komponen krusial dalam arsitektur jaringan saraf modern. Keunggulannya dalam mengatasi vanishing gradient dan mempercepat proses konvergensi membuatnya menjadi pilihan utama dalam berbagai aplikasi pembelajaran mendalam, mulai dari pengenalan gambar hingga pemrosesan bahasa alami. Dengan penyesuaian dan pengembangan varian ReLU, para peneliti dan praktisi terus memperbaiki performa jaringan saraf, membawa kita lebih dekat pada solusi yang lebih efisien dan efektif untuk berbagai tantangan dalam kecerdasan buatan .

### 2.2.5 Segmentasi Citra

Segmentasi merupakan proses mempartisi citra menjadi beberapa daerah atau objek. Proses ini memiliki sifat *discontinuity*, yang mencakup pendekatan berbasis tepi (*edge-based*) untuk mempartisi citra ketika terdapat perubahan intensitas secara tiba-tiba, serta sifat *similarity* yang mencakup pendekatan berbasis daerah (*region-based*) seperti thresholding, region growing, dan region *splitting and merging*. Pendekatan *discontinuity* bertujuan mempartisi citra saat terdapat perubahan intensitas yang tiba-tiba, yang sering kali terkait dengan tepi atau batas objek. Di sisi lain, pendekatan *similarity* bertujuan mempartisi citra menjadi daerah-daerah yang memiliki kesamaan sifat tertentu. Sebagai contoh, thresholding digunakan untuk memisahkan piksel berdasarkan ambang tertentu, region growing membangun daerah-daerah berdasarkan kriteria kesamaan, dan region *splitting and merging* memecah atau menggabungkan daerah-daerah berdasarkan perbedaan atau kesamaan fitur tertentu. Segmentasi memainkan peran penting dalam pengolahan citra digital, mengidentifikasi dan memisahkan objek atau bagian tertentu dalam citra. Objek yang dihasilkan dari proses segmentasi seringkali menjadi fokus untuk langkah-langkah selanjutnya dalam analisis dan pengolahan citra [37].

Segmentasi citra adalah proses pengolahan citra yang bertujuan memisahkan wilayah (*region*) objek dengan wilayah latar belakang agar objek mudah dianalisis dalam rangka mengenali objek yang banyak melibatkan persepsi visual. Proses segmentasi citra didasarkan pada perbedaan derajat keabuan citra [38]. Untuk mengubah citra berwarna yang memiliki nilai matriks masing-masing untuk kanal merah (r), hijau (g), dan biru (b) menjadi citra *grayscale* dengan nilai keabuan tunggal (s), dilakukan konversi dengan mengambil rata-rata dari nilai r, g, dan b seperti persamaan berikut:

$$s = \frac{(r+g+b)}{3} \quad (2.3)$$

Keterangan :

s: Nilai skala abu-abu (*grayscale*)

r: Nilai saluran warna merah (*red*)

g: Nilai saluran warna hijau (*green*)

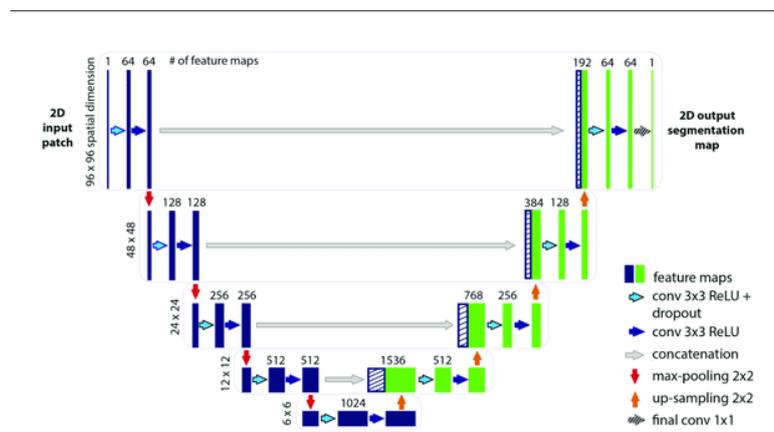
b: Nilai saluran warna biru (*blue*)

Dalam persamaan tersebut, *s* adalah nilai keabuan citra *grayscale* yang dihasilkan dari rata-rata nilai kanal warna (r, g, b). Langkah ini membantu menyederhanakan citra berwarna menjadi citra keabuan, memungkinkan analisis yang lebih efektif pada tingkat keabuan tunggal.

## 2.2.6 U-Net

UNet adalah arsitektur jaringan saraf konvolusional (Convolutional Neural Network atau CNN) yang dirancang khusus untuk tugas segmentasi citra, seperti dalam bidang kedokteran untuk segmentasi gambar medis. Pertama kali diperkenalkan oleh Olaf Ronneberger, Philipp Fischer, dan Thomas Brox dalam makalah berjudul "U-Net: *Convolutional Networks for Biomedical Image Segmentation*" yang dipresentasikan pada konferensi MICCAI 2015, UNet memiliki struktur simetris berbentuk huruf U yang terdiri dari dua bagian utama: kontraksi (*downsampling*) dan ekspansi (*upsampling*). Bagian kontraksi bertugas mengekstraksi fitur penting dari citra input melalui serangkaian operasi konvolusi dan pooling, sedangkan bagian ekspansi bertujuan memulihkan resolusi asli citra

input melalui upsampling dan konvolusi. Fitur kunci dari UNet adalah penggunaan skip connections, yaitu penggabungan feature maps dari lapisan kontraksi ke lapisan ekspansi yang sesuai, memungkinkan model mempertahankan informasi spasial yang detail dari citra input asli, yang sangat penting untuk segmentasi presisi tinggi. Secara keseluruhan, UNet terdiri dari lapisan input, jalur downsampling, bottleneck, jalur upsampling, dan lapisan output. Arsitektur ini terkenal karena akurasi tinggi, efisiensi komputasi, dan fleksibilitasnya dalam menangani berbagai jenis citra dan tugas segmentasi [39].



**Gambar 2. 3 Ilustrasi Model U-Net [40]**

Jaringan yang terdapat pada Gambar 2.3 dirancang untuk menangani masalah data terbatas dalam bidang medis sambil mempertahankan kecepatan dan akurasi. U-Net dirancang agar dapat mempertahankan kecepatan dan akurasi dalam pengolahan citra medis. Hal ini diperlukan karena dalam konteks medis, waktu pemrosesan yang cepat dan akurasi yang tinggi kritis untuk mendukung pengambilan keputusan klinis. [41]. U-Net terdiri dari *layer input*, beberapa *layer downsampler* dan *upsampler* dan *layer output*. U-Net menggunakan struktur jalur kontraksi (*downsampling*) dan jalur ekspansi (*upsampling*). Jalur kontraksi bertujuan untuk mengekstrak fitur-fitur penting dari input dan mengurangi dimensi spasialnya, sedangkan jalur ekspansi bertujuan memulihkan dimensi spasial dan menghasilkan *output* segmentasi.

Transmisi informasi spasial multilevel dari *encoder* ke decoder dimungkinkan oleh arsitektur U-Net yang menggunakan lapisan concatenate.

Kemampuan ini memungkinkan model menghasilkan segmentasi gambar yang halus dan akurat. Dalam U-net, *encoder* terdiri dari lapisan konvolusi dua dimensi dengan kernel 3x3 dan max pooling dengan kernel 2x2. Sementara itu, decoder terdiri dari lapisan konvolusi dua dimensi dengan kernel 3x3, *transpose convolution*, atau *deconvolution* dengan kernel 2x2 dan *striding 2*. Proses di decoder bertujuan untuk memulihkan dimensi spasial dan menghasilkan segmentasi citra dengan tingkat resolusi yang lebih tinggi [42].

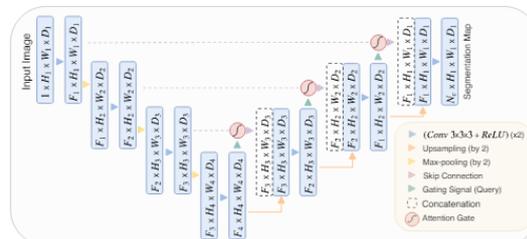
Unet dapat menerima *input* gambar 3 dimensi maupun 2 dimensi, dengan bantuan *layer convolutional*, hal ini menjadi mudah. Karena *layer convolutional* berupa 3 dimensi, maka *weight* juga berupa 3 dimensi. Proses perkalian *input* (bukan dot *matrix*) dengan *weight* akan menghasilkan *output* 3 dimensi juga. Dimensi *output* dapat diatur menggunakan *stride* dan *padding*, dimensi *output* dapat sama dengan dimensi *input* dengan bantuan *padding* dengan tipe sama. Hal yang membedakan U-Net dari *Autoencoder* adalah adanya *layer skip connection* yang menghubungkan hasil *feature map* sebagai *input* tambahan untuk *layer decoder* pada level yang sama dengan menggunakan bantuan *layer concatenate*, sehingga dimensi *input* akan bertambah, bukannya nilai dari *input decoder* yang bertambah.

Pada gambar 2.3, garis abu-abu adalah *layer concatenate* yang menghubungkan *encoder* ke decoder. Garis merah ke bawah adalah *layer downsampling* yang biasanya menggunakan *layer max pooling* ataupun dapat memanfaatkan atribut *stride* pada *layer convolutional*. Garis merah ke atas adalah *layer transpose*. *Transpose layer* adalah teknik lain selain *up sampling* biasa. *Transpose layer* seringkali salah dikenal sebagai *layer deconvolutional*, padahal kedua *layer* adalah jenis yang berbeda. *Layer deconvolutional* memutar balikan operasi dari *layer convolutional* biasa. Sedangkan *layer transposed* meningkatkan spasial dimensi dari *input* dengan bantuan *stride* dan *padding*. Selain itu, *layer transposed* memiliki *weight* yang dapat dipelajari, cara mempelajari *weight* sama dengan *layer convolutional* pada umumnya, sehingga *layer* ini mempunyai ukuran filter dan jumlah channel. Hal ini lah yang membedakan dari *layer up sampling* biasa. Hasil *output* dari *layer deconvolutional* dan *layer transpose* memiliki

spatial dimension yang sama, sehingga hal ini yang membuat pemahaman kebanyakan orang salah [43].

### 2.2.5.1 Attention U-Net

Attention U-Net adalah sebuah varian dari arsitektur U-Net yang diperluas dengan mekanisme perhatian (*attention mechanism*) untuk meningkatkan kemampuan segmentasi pada gambar medis. Arsitektur U-Net telah terbukti sangat efektif dalam tugas segmentasi gambar medis dengan menggunakan jaringan konvolusi yang terdiri dari jalur kontraksi untuk mengekstraksi fitur dan jalur ekspansi untuk menghasilkan masker segmentasi. Namun, dalam gambar medis yang kompleks seperti CT atau MRI, tidak semua bagian gambar memiliki kontribusi yang sama terhadap proses segmentasi. Dengan mengintegrasikan mekanisme perhatian, Attention U-Net dapat menyesuaikan bobot pada bagian-bagian gambar yang paling penting untuk segmentasi, meningkatkan akurasi dan keberhasilan proses tersebut.



**Gambar 2. 4 Arsitektur Attention U-Net [44]**

Gambar 2.4 menunjukkan arsitektur jaringan saraf tiruan yang menyerupai model U-Net yang dimodifikasi dengan mekanisme perhatian (*attention mechanism*). Fungsi utama dari model ini adalah untuk melakukan segmentasi citra, di mana setiap piksel dari gambar input diklasifikasikan ke dalam kelas tertentu. Pada tahap pertama, gambar input diproses melalui beberapa lapisan konvolusi dan pooling untuk mengekstrak fitur penting sambil mengurangi dimensi spasialnya (*downsampling*). Setiap blok konvolusi menggunakan operasi Conv 3x3 + ReLU, yang diikuti oleh operasi max-pooling untuk menangkap fitur penting [39].

Di titik tengah (*bottleneck*), resolusi spasial paling kecil dan kedalaman fitur map paling tinggi, memungkinkan jaringan untuk menangkap fitur yang lebih kompleks . Pada tahap kedua, fitur map yang telah diperkecil dimensinya kemudian ditingkatkan kembali melalui blok upsampling dan konvolusi, mengembalikan resolusi spasial ke ukuran asli input . Proses ini dibantu oleh skip connections yang membawa fitur dari lapisan encoder ke lapisan decoder yang sesuai, memastikan informasi spasial penting tidak hilang . Attention gates ditempatkan pada skip connections untuk memfokuskan jaringan pada fitur penting sebelum penggabungan (*concatenation*) dengan fitur yang telah di-upsample .

Setelah proses dekoder selesai, hasil akhirnya adalah peta segmentasi (*segmentation map*) yang memiliki resolusi yang sama dengan gambar input dan menunjukkan klasifikasi tiap piksel . Arsitektur ini mengkombinasikan kekuatan model U-Net dengan mekanisme perhatian, menghasilkan jaringan yang mampu melakukan segmentasi citra dengan lebih efektif dan akurat [45].

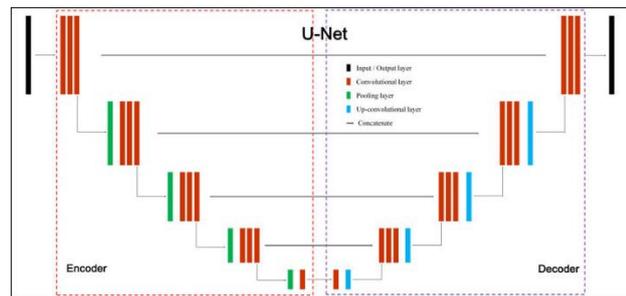
Mekanisme perhatian dalam Attention U-Net bekerja dengan memberikan bobot yang berbeda pada fitur-fitur yang diekstraksi oleh jaringan. Fitur-fitur yang penting atau relevan untuk segmentasi diberi bobot yang lebih tinggi, sementara fitur-fitur yang kurang penting diberi bobot yang lebih rendah. Hal ini memungkinkan model untuk "mengerti" bagian mana dari gambar yang perlu mendapatkan perhatian lebih dalam proses segmentasi, sehingga menghasilkan hasil yang lebih akurat. Dengan memperhatikan fitur-fitur yang relevan, Attention U-Net dapat memperbaiki masalah segmentasi yang mungkin terjadi pada bagian-bagian gambar yang kompleks atau memiliki banyak struktur yang saling tumpang tindih.

Penelitian yang menggunakan Attention U-Net telah menunjukkan peningkatan signifikan dalam akurasi segmentasi pada berbagai jenis gambar medis, termasuk segmentasi organ-organ internal seperti pankreas dalam gambar CT. Model ini telah terbukti mampu mengatasi tantangan segmentasi pada gambar medis yang kompleks, dengan memberikan fokus pada fitur-fitur yang penting

dan relevan. Hasil penelitian yang positif ini menunjukkan bahwa Attention U-Net memiliki potensi besar untuk digunakan dalam aplikasi medis di mana segmentasi gambar medis yang akurat sangat penting untuk diagnosis dan perawatan pasien [45].

### 2.2.5.2 Decoder dan Encoder

Encoder dan decoder adalah komponen penting dalam berbagai sistem komunikasi dan pemrosesan sinyal. Encoder bertugas mengubah informasi dari format aslinya menjadi format yang sesuai untuk transmisi atau penyimpanan, sementara decoder mengubahnya kembali ke format asli atau format yang dapat dipahami oleh penerima. Proses encoding dan decoding memainkan peran vital dalam memastikan integritas dan efisiensi komunikasi data, baik dalam aplikasi sehari-hari seperti kompresi data dan transmisi video, maupun dalam teknologi canggih seperti jaringan saraf tiruan dan sistem pembelajaran mesin [46].



**Gambar 2.5 Encoder dan Decoder** [47]

Jenis jaringan ini terdiri dari dua bagian yaitu *encoder* dan *decoder*. Ilustrasi *encoder-decoder* dapat dilihat pada Gambar 2.17. pada bagian *encoder* biasanya mengurangi dimensi spasial dan *feature map*, sedangkan bagian *decoder* akan memulihkan detail dan dimensi spasial yang tereduksi oleh *encoder*. Contoh jaringan *encoder-decoder* adalah SegNet, U-Net, dan RefineNet. Untuk meningkatkan resolusi, SegNet menggunakan indeks penggabungan dari *encoder* untuk mempelajari *upsampling* pada lapisan *decoder*. U-Net memanfaatkan skip connection antara *feature map encoder-decoder* untuk meningkatkan resolusi. U-Net menggunakan konsep skip connection atau shortcut connection antara *feature map encoder* dan *decoder*. *Skip connection* memungkinkan informasi untuk

"melompat" atau melewati lapisan-lapisan, memungkinkan penggabungan informasi tingkat tinggi dari *encoder* ke dalam lapisan decoder yang sesuai. Hal ini membantu meningkatkan resolusi dan pemulihan detail.

Arsitektur *encoder-decoder* cocok untuk tugas segmentasi citra, di mana tujuannya adalah untuk memisahkan dan mengidentifikasi objek atau daerah tertentu dalam citra. Model seperti U-Net sangat populer dalam tugas ini. Dalam tugas rekonstruksi citra, arsitektur *encoder-decoder* dapat digunakan untuk merekonstruksi citra input dari representasi yang lebih rendah. Ini sering digunakan dalam tugas restorasi citra atau generasi citra. Untuk mengatasi tantangan seperti *noise* atau kabur dalam citra, arsitektur *encoder-decoder* dapat digunakan untuk memahami dan memulihkan fitur-fitur yang hilang atau terganggu. Keunggulan arsitektur *encoder-decoder* terletak pada kemampuannya untuk menangkap informasi berhierarki melalui jalur *encoder* dan kemudian menggunakan informasi tersebut untuk membangun kembali citra pada jalur *decoder*. Ini memungkinkan model untuk memahami fitur-fitur dari tingkat representasi yang rendah hingga tingkat yang lebih tinggi, yang sangat berguna dalam berbagai konteks pengolahan citra [48].

### 2.2.5.3 Matrik Evaluasi

#### a. Akurasi

Mengukur sejauh mana model *Attention U-Net* dapat secara akurat memisahkan dan mengidentifikasi area yang terkena lesi pneumonia pada citra radiografi.

$$\text{Akurasi} = \frac{(TP+TN)}{TP+FP+FN+TN} \quad (4)$$

Keterangan :

TP (*True Positive*)      Jumlah kasus positif yang diprediksi dengan benar.

TN (*True Negative*)      Jumlah kasus negatif yang diprediksi dengan benar.

FP ( <i>False Positive</i> )	Jumlah kasus negatif yang diprediksi sebagai positif (kesalahan tipe I).
FN ( <i>False Negative</i> )	Jumlah kasus positif yang diprediksi sebagai negatif (kesalahan tipe II).

b. Loss

Fungsi kerugian yang dibandingkan dalam penelitian ini telah dipilih karena potensinya untuk mengatasi ketidakseimbangan kelas. Semua fungsi kerugian telah dianalisis dibawah klasifikasi biner (latar depan vs latar belakang) karena mewakili pengaturan paling sederhana yang memungkinkan kuantifikasi ketidakseimbangan kelas[49].

Kinerja keseluruhan dari sebuah model segmentasi tergantung Tidak hanya pada arsitektur jaringan tetapi juga pada pilihan fungsi kerugian, terutama dalam kasus yang mengalami masalah ketidakseimbangan kelas yang tinggi. Oleh karena itu, memilih fungsi kerugian yang sesuai menjadi lebih menantang. Karena distribusi tumor dan non-tumor daerah, tugas segmentasi tumor otak memiliki kelas bawaan masalah ketidakseimbangan. Dengan demikian, fungsi kerugian yang banyak digunakan di tugas segmentasi tidak sesuai untuk melatih kami jaringan. Jika fungsi-fungsi ini diadopsi, jaringan mencoba untuk mempelajari kelas yang lebih besar dan ini menghasilkan segmentasi yang buruk kinerja[50].

$$\text{BCE Loss} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(y_i) + (1 - y_i) \log(1 - y_i)] \quad (2.5)$$

Keterangan :

- N : Jumlah total sampel data.
- $y_i$  : Nilai sebenarnya dari sampel data ke-i (0 atau 1).
- $(1 - y_i)$  : Kebalikan dari nilai sebenarnya  $y_i$  (jika  $y_i = 1$ , maka  $1 - y_i = 0$ , dan sebaliknya).
- $\log(1 - y_i)$  : Logaritma dari kebalikan nilai sebenarnya  $y_i$ .
- $\log(y_i)$  : Logaritma dari nilai sebenarnya  $y_i$ .

Sebagai fungsi objektif, merupakan nilai invers dari IoU dan dihitung sebagai  $1 - \text{IoU}$ . Fungsi objektif ini menjadi parameter yang dioptimalkan selama pelatihan model untuk meningkatkan ketepatan prediksi terhadap label sebenarnya.

c. IoU (*Intersection over Union*)

$$\text{IoU} = \frac{TP}{TP+FP+FN} \quad (2.6)$$

Intersection over Union (IoU) menjadi parameter utama yang mengukur sejauh mana prediksi model bertumpuk dengan area sebenarnya pada label. IoU menghitung rasio antara area pencarian bersama (intersection) dan area gabungan (union), memberikan nilai antara 0 dan 1, di mana 1 menunjukkan prediksi yang sempurna sesuai dengan label sebenarnya. Mengukur seberapa baik area yang dihasilkan oleh segmentasi model tumpang tindih dengan area sebenarnya yang terkena pneumonia pada citra radiografi

d. Presisi

$$\text{Presisi} = \frac{TP}{(TP+TF)} \quad (2.7)$$

Presisi menjadi variabel analisis yang menitikberatkan pada seberapa banyak dari instansi positif yang diprediksi oleh model benar-benar positif. Dengan rumus yang mempertimbangkan true positives dan false positives, presisi memberikan pemahaman tentang sejauh mana model menghindari prediksi yang salah positif.

### 2.2.7 Python

Python adalah bahasa pemrograman interpretatif yang dianggap mudah dipelajari serta berfokus pada keterbacaan kode. Python secara umum berbentuk pemrograman berorientasi objek, pemrograman imperatif dan pemrograman fungsional [51]. Fitur dan kelebihan python, yaitu:

- a. Memiliki koleksi kepustakaan yang banyak, tersedia modul-modul yang ‘siap pakai’ untuk berbagai keperluan.
- b. Memiliki struktur bahasa yang jelas, sederhana, dan mudah dipelajari.
- c. Berorientasi objek.
- d. Memiliki sistem pengelolaan memori otomatis.
- e. Bersifat modular.

Pemrograman adalah kegiatan penulisan kode program menggunakan bahasa pemrograman tertentu. Untuk dapat menyelesaikan pemrograman, seseorang perlu memahami algoritma, karena pada dasarnya program komputer adalah implementasi dari algoritma. Algoritma adalah sekumpulan langkah rinci yang ditujukan untuk komputer dalam menyelesaikan suatu masalah. Algoritma dibuat pada tahapan perancangan program. Algoritma memiliki peranan penting untuk menghubungkan antara keluaran yang dikehendaki dan masukan-masukan yang tersedia[52].

Python adalah bahasa pemrograman yang diartikan (*interpreted*) dan berbasis objek yang mendukung struktur data tingkat tinggi seperti daftar (*lists*) dan kamus (*dictionaries*), serta pengetikan dan pengikatan dinamis. Bahasa ini terkenal dengan sintaks yang sederhana dan elegan, membuatnya mudah dipelajari dan digunakan, tetapi tetap kuat dan serbaguna [53].

Program Python dikompilasi secara otomatis oleh *interpreter* ke dalam kode byte yang independen dari platform dan kemudian dijalankan oleh mesin virtual Python. Bahasa ini mendukung berbagai sistem operasi seperti Linux, Windows, dan mac OS. Python bersifat modular dengan inti yang kecil dan dapat diperluas melalui modul ekstensi. Distribusi Python mencakup banyak pustaka standar untuk berbagai tugas mulai dari manipulasi string dan ekspresi reguler hingga antarmuka pengguna grafis (GUI) dan utilitas web, serta alat untuk debugging dan pembuatan profil. Kemampuan untuk menambah fungsionalitas

melalui modul ekstensi membuat Python sangat fleksibel dan dapat digunakan untuk berbagai aplikasi. Komunitas pengguna Python telah mengembangkan banyak modul ekstensi yang memperluas kemampuan bahasa ini [54].

### 2.2.8 Jupyter Notebook

Jupyter Notebook telah menjadi alat yang sangat penting dalam dunia ilmu data dan komputasi ilmiah. Dengan fitur-fitur interaktifnya, Jupyter Notebook memungkinkan para peneliti dan praktisi untuk menjalankan kode secara langsung di dalam dokumen, membuatnya menjadi lingkungan yang ideal untuk eksplorasi data, analisis statistik, dan pembelajaran mesin. Selain itu, kemampuan untuk menambahkan teks naratif dan visualisasi data menjadikan Jupyter Notebook sebagai platform yang sangat fleksibel untuk mengkomunikasikan ide dan temuan kepada sesama peneliti atau pemangku kepentingan lainnya.

Dalam penelitian terbaru oleh Kluyver et al. (2016), Jupyter Notebook dipuji sebagai format publikasi yang dapat mendukung workflow komputasi yang dapat direproduksi. Kluyver dan rekan-rekannya menyoroti peran Jupyter Notebook dalam meningkatkan transparansi dan reproduksibilitas penelitian ilmiah. Dengan menggunakan Jupyter Notebook, peneliti dapat merekam langkah-langkah analisis data secara terperinci, mengungkapkan logika di balik keputusan yang diambil, serta menyediakan kode yang dapat dijalankan ulang untuk memvalidasi temuan mereka. Ini membantu memperkuat kepercayaan dan integritas dalam praktik penelitian.

Selain di dunia akademis, Jupyter Notebook juga semakin populer dalam industri sebagai alat untuk pengembangan perangkat lunak, prototyping produk, dan pengembangan model *machine learning*. Jupyter Notebook telah menjadi fondasi bagi berbagai proyek dan inisiatif, mendukung kolaborasi tim dan memfasilitasi inovasi dalam berbagai bidang [55].