

BAB II

LANDASAN TEORI

2.1. Kajian Pustaka

Ada beberapa sistem AI yang telah diusulkan untuk Deteksi penyakit paru-paru dari gambar X-ray. Beberapa studi menunjukkan efisiensi analisis gambar X-ray untuk mendeteksi penyakit paru-paru seperti COVID-19, Tuberculosis, Pneumonia, dan Normal. Sebagian besar kasus, pendekatan berbasis Deep Learning telah diterapkan dan mencapai akurasi yang sangat menjanjikan untuk penyakit paru-paru.

Sebuah studi rinci telah dilakukan di [14], [15] untuk menggambarkan pentingnya penanganan penyakit paru-paru khususnya COVID-19 dan Pneumonia. Selain pemecahan masalah penyakit paru-paru, CNN juga menghasilkan pemecahan masalah medis seperti deteksi kanker payudara [16], [17], segmentasi tumor otak [18], [19], diagnosis penyakit Alzheimer dan klasifikasi lesi kulit [20], [21] dan lain-lain. Sejauh ini, kami menyadari bahwa beberapa penelitian tentang penyakit paru-paru menggunakan pembelajaran dalam. Pada [22] mengusulkan CNN yang arsitekturnya berbeda untuk mengekstraksi fitur dari gambar rontgen dada dan mengklasifikasikan gambar untuk mendeteksi apakah seseorang menderita pneumonia. Hasil percobaan yang dilakukan untuk menilai kinerja arsitektur dan efek dari data augmentasi pada kinerja CNN yang diusulkan menunjukkan bahwa CNN dengan dropout yang dilatih memiliki kinerja lebih baik dari model lainnya. Pada [9] menyaikan penerapan dua teknik yaitu CNN dan ANN yang digunakan untuk mendiagnosa tuberculosis. Pendekatan tersebut memberikan hasil yang menjanjikan dalam mendiagnosa tuberculosis. Jaringan ANN dengan fitur ResNet50, GLCM, DWT, dan LBP mencapai akurasi 99,22%, sensitivitas 99,23%, dan spesifitas 99,41%. Pada [23] menambahkan variabilitas agumentasi data sintesis lebih banyak ke dataset dengan memperbesarnya. CovidGAN digunakan untuk menghasilkan gambar sintetik rontgen dada (CXR). Peningkatan kinerja klasifikasi gambar rontgen dada sintesis (CXR) dengan mengembangkan ACGAN dan CNN yang menghasilkan akurasi 95%. Pada [5] mengusulkan sistem

end-to-end untuk mendeteksi COVID-19 dan lokalisasi wilayah yang terinfeksi dari dua gambar modalitas medis yang berbeda. Untuk klasifikasi, dan segmentasi kami meningkatkan Inception Recurrent Residual Neural Network (IRRCNN) dalam model jaringan NABLA-3 yang diterapkan. Model diuji pada X-ray, CT abdomen, dan CT seluruh tubuh gambar pada kumpulan data yang tersedia untuk umum. Hasil yang diamati menunjukkan hasil deteksi yang sangat menjanjikan dengan 84,67% dan akurasi pengujian 98,87% untuk COVID-19 dari X-ray dan CT images. Pada [24] menyelidiki penggunaan transfer pembelajaran dalam untuk mengklasifikasikan pneumonia pada gambar rontgen dada. Hasil eksperimen menunjukkan bahwa, dengan sedikit fine-tuning transfer pembelajaran dalam membawa keuntungan kinerja dari pelatihan awal. Tiga model yang diusulkan yaitu ResNet50, InceptionV3, dan DenseNet121 dilatih secara terpisah melalui transfer pembelajaran dari awal. Hasil pengujian mencapai 4,1% hingga 52,5% area di bawah kurva (AUC) yang lebih besar daripada yang diperoleh sebelumnya.

Tabel 2. 1. Penelitian Terdahulu

Peneliti	Judul	Tujuan	Hasil
[14]	Convolutional neural networks based efficient approach for classification of lung diseases	Melakukan klasifikasi penyakit paru-paru dengan 2 pendekatan. Pada pendekatan pertama, model jaringan saraf konvolusional dalam (CNN) terlatih digunakan untuk ekstraksi fitur dan pengklasifikasi mesin vektor dukungan (SVM) digunakan dalam klasifikasi suara paru-paru. Pada pendekatan kedua, model CNN mendalam yang telah dilatih sebelumnya disempurnakan (pembelajaran transfer) melalui gambar spektogram untuk klasifikasi suara paru-paru.	Akurasi metode yang diusulkan diuji dengan menggunakan validasi silang sepuluh kali lipat. Akurasi metode usulan pertama dan kedua masing-masing sebesar 65,5% dan 63,09%. Akurasi yang diperoleh kemudian dibandingkan dengan beberapa hasil yang ada dan terlihat skor yang diperoleh lebih baik dibandingkan hasil lainnya.
[11]	Multi-Class Classification of Lung Diseases Using CNN Models	Mengusulkan metode klasifikasi kelas jamak dengan mempelajari gambar penyakit paru-paru dengan Convolutional Neural Network (CNN).	Hasil percobaan, Tolok Ukur yang diukur dengan dataset NIH menunjukkan performa tertinggi di antara model yang diuji dengan akurasi 85,32%, dan prediksi empat kelas yang diukur dengan data dari Rumah Sakit

			Universitas Soonchunhyang di Cheonan memiliki akurasi rata-rata 96,1% , sensitivitas rata-rata 92,2%, spesifisitas rata-rata 97,4%, dan waktu inferensi rata-rata 0,2 detik.
[13]	COVID-19 Detection Through Transfer Learning Using Multimodal Imaging Data	Mengusulkan tahap pra-pemrosesan gambar untuk membuat kumpulan data gambar yang dapat dipercaya untuk mengembangkan dan menguji model pembelajaran mendalam. Pendekatan baru ini bertujuan untuk mengurangi noise yang tidak diinginkan dari gambar sehingga model pembelajaran mendalam dapat fokus dalam mendeteksi penyakit dengan ciri-ciri tertentu.	Hasil kami menunjukkan bahwa gambar USG memberikan akurasi deteksi yang lebih unggul dibandingkan dengan X-Ray dan CT scan. Hasil eksperimen menyoroti bahwa dengan data yang terbatas, sebagian besar jaringan yang lebih dalam kesulitan untuk berlatih dengan baik dan kurang memberikan konsistensi pada tiga mode pencitraan yang kami gunakan. Model VGG19 yang dipilih, yang kemudian disesuaikan secara ekstensif dengan parameter yang sesuai, melakukan deteksi COVID-19 terhadap pneumonia pada tingkat yang cukup besar atau normal untuk ketiga mode gambar paru-paru dengan presisi

			hingga 86% untuk X-Ray, 100% untuk Ultrasound dan 84% untuk CT scan.
[4]	Deep learning approaches for COVID-19 detection based on chest X-ray images	Model CNN baru diusulkan dalam penelitian ini dengan pelatihan end-to-end. Kumpulan data yang berisi 180 gambar rontgen dada COVID-19 dan 200 gambar normal (sehat) digunakan dalam eksperimen penelitian ini. Akurasi klasifikasi digunakan sebagai pengukuran kinerja penelitian.	Karya eksperimental mengungkapkan bahwa pembelajaran mendalam menunjukkan potensi dalam mendeteksi COVID-19 berdasarkan gambar rontgen dada. Fitur mendalam yang diekstraksi dari model ResNet50 dan pengklasifikasi SVM dengan fungsi kernel Linear menghasilkan skor akurasi 94,7%, yang merupakan skor tertinggi di antara semua hasil yang diperoleh. Pencapaian model ResNet50 yang telah disempurnakan mencapai 92,6%, sedangkan pelatihan menyeluruh dari model CNN yang dikembangkan memberikan hasil sebesar 91,6%. Berbagai deskriptor tekstur lokal dan klasifikasi SVM juga digunakan untuk perbandingan kinerja dengan pendekatan mendalam alternatif; yang hasilnya menunjukkan pendekatan deep cukup

			efisien jika dibandingkan dengan deskriptor tekstur lokal dalam mendeteksi COVID-19 berdasarkan gambar rontgen dada.
[25]	COVIDetectioNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble	Penelitian ini mengusulkan sistem yang dirancang oleh para ahli yang disebut model COVIDetectioNet, yang memanfaatkan fitur-fitur yang dipilih dari kombinasi fitur-fitur mendalam untuk diagnosis COVID-19. Untuk tujuan ini, digunakan arsitektur AlexNet berbasis Convolutional Neural Network (CNN) yang menggunakan pendekatan pembelajaran transfer. Fitur-fitur efektif yang dipilih menggunakan algoritma pemilihan fitur Relief dari seluruh lapisan arsitektur kemudian diklasifikasikan menggunakan metode Support Vector Machine (SVM).	Pada hasil eksperimen, akurasi dicapai sebesar 99,18% dengan menggunakan model yang diusulkan. Hasilnya menunjukkan bahwa model COVIDetectioNet yang diusulkan mencapai tingkat keberhasilan yang lebih tinggi jika dibandingkan dengan penelitian sebelumnya.

2.2. Landasan Teori

2.2.1 Anatomi Paru

Paru-paru merupakan bagian dari sistem pernapasan manusia. Organ ini terdiri dari paru-paru kanan, yang terdiri dari tiga lobus, dan paru-paru kiri, yang terdiri dari dua lobus. Paru-paru kanan terpisah oleh Fissura obliqua dan Fissura horizontalis, sementara paru-paru kiri terpisah oleh Fissura obliqua [26]. Ukuran paru-paru bagian kiri lebih kecil daripada bagian kanan karena jantung memerlukan lebih banyak ruang di sisi kiri. Pleura merupakan lapisan yang melapisi paru-paru dan berfungsi sebagai pelumas untuk mencegah iritasi saat paru-paru berkontraksi atau mengembang. [26]. Volume paru-paru kanan pada saat inspirasi normal adalah sekitar 2-3 L dan dapat meningkat hingga 5-8 L saat inspirasi maksimal. Di sisi lain, paru-paru kiri memiliki volume yang sedikit lebih kecil sekitar 10-20% karena adanya jantung yang berada di sebelah kiri [25].

Di dalam paru-paru terdapat struktur yang disebut alveoli, yaitu rongga kecil yang dikelilingi oleh banyak kapiler. Alveoli berperan sebagai tempat terjadinya pertukaran udara. Diameter alveoli dapat bervariasi antara 150 hingga 500 μm , dengan ukuran rata-rata sekitar 250 μm . Pada pria dewasa dengan berat 70 kg, diperkirakan terdapat sekitar 300 miliar alveoli di paru-parunya. Luas permukaan total alveoli mencapai sekitar 143m². [26]. Di bagian atas paru-paru terdapat batang tenggorokan yang membelah menjadi dua cabang. Cabang batang tenggorokan sebelah kanan memiliki panjang yang lebih pendek, lebar yang lebih besar, dan berorientasi lebih vertikal dibandingkan dengan cabang batang tenggorokan sebelah kiri. [6]. Di bagian bawah paru-paru terdapat otot yang memisahkan rongga dada dan perut, yang dikenal sebagai otot diafragma. Fungsinya terkait dengan proses pernapasan. Ketika seseorang mengambil napas, otot diafragma akan berkontraksi dan menjadi datar. Ketika mengeluarkan napas, otot diafragma akan mengendur.

2.2.2 Pneumonia

Pneumonia, juga dikenal sebagai radang paru-paru, adalah suatu kondisi infeksi yang mengenai paru-paru, yang mengakibatkan peradangan dan pembengkakan pada kantung udara di salah satu atau kedua paru-paru. Gejalanya

termasuk batuk berdahak, demam, sesak napas, dan menggigil. Pneumonia dapat disebabkan oleh berbagai faktor, seperti virus, bakteri, dan jamur. Siapa pun dapat terkena pneumonia. Namun, kasus pneumonia paling umum terjadi pada anak-anak di bawah usia 5 tahun dan orang dewasa yang berusia di atas 70 tahun [27]. Di Indonesia, pneumonia merupakan penyebab kematian kedua tertinggi pada anak-anak. [28]. Pada tahun 2017, angka kematian akibat pneumonia pada anak-anak mencapai setidaknya 15%, sementara sebanyak 1,13 juta orang berusia di atas 70 tahun meninggal dunia karena penyakit tersebut. Penyebab pneumonia sangat beragam dan dikelompokkan berdasarkan jenis kuman, sebagai berikut:

- a. Pneumonia virus adalah bentuk pneumonia yang disebabkan oleh infeksi virus, termasuk virus flu, virus influenza, dan juga virus coronavirus. Penyakit ini telah mengalami peningkatan signifikan sejak dimulainya pandemi Covid-19.
- b. Pneumonia bakterial merupakan bentuk pneumonia yang disebabkan oleh infeksi bakteri. Bakteri utama yang sering menjadi penyebab pneumonia adalah *Streptococcus pneumoniae*. Selain itu, terdapat bakteri lain seperti *Mycoplasma pneumoniae*, *Haemophilus influenzae*, dan *Legionella pneumophila* yang juga dapat menyebabkan pneumonia.
- c. Pneumonia jamur adalah bentuk pneumonia yang disebabkan oleh infeksi jamur, terutama oleh jamur *Pneumocystis jirovecii*. Orang yang memiliki sistem kekebalan tubuh yang lemah berisiko terkena pneumonia yang disebabkan oleh jamur ini.

Pencegahan pneumonia dapat dilakukan melalui pemberian vaksin *Pneumococcal conjugate vaccine (PCV)* [11], namun pemberian vaksin ini belum merata di seluruh dunia. Diagnosa terhadap pneumonia dapat dilihat dari gejala penderita, beberapa tes dapat dilakukan guna menyelidiki lebih lanjut penyakit pneumonia. Salah satunya adalah foto rontgen dada. Penyakit pneumonia dapat diidentifikasi dengan melihat adanya pergantian udara dalam alveoli oleh nanah, darah, sel dan cairan lainnya atau biasa disebut consolidation. Consolidation pada foto rontgen paru ditandai dengan adanya area berwarna abu-abu [29].

2.2.3 COVID-19

Covid-19, yang juga dikenal sebagai virus corona atau severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2), adalah salah satu anggota dari keluarga virus Coronaviridae. [30]. Virus tersebut menginfeksi sistem pernapasan dan dapat menyebabkan berbagai gangguan pernapasan, mulai dari yang ringan hingga fatal dengan kegagalan fungsi organ tubuh. Infeksi Covid-19 pertama kali terdeteksi di Wuhan, China pada bulan Desember 2019, dan kemudian menyebar ke hampir seluruh negara di seluruh dunia.

Covid-19 memiliki diameter 65 – 125 nm dan mengandung RNA untai tunggal [30]. Selain Covid-19, virus ini juga termasuk dalam kelompok virus yang menyebabkan severe acute respiratory syndrome (SARS) dan Middle East Respiratory Syndrome (MERS). Pada tanggal 14 April 2021, jumlah kasus Covid-19 di seluruh dunia mencapai 138.688.383, dengan 2.978.935 kasus yang berujung pada kematian. Negara dengan jumlah kasus tertinggi pada saat itu adalah Amerika Serikat, dengan 59.053.949 kasus dan 1.432.017 kasus kematian. Di urutan kedua, negara-negara di Eropa melaporkan 48.741.077 kasus dengan 1.028.387 kasus kematian akibat Covid-19. [7].

Gejala Covid-19 serupa dengan gejala flu, termasuk pilek, sakit tenggorokan, demam, dan batuk kering. Namun, gejala tersebut cenderung bertahan lama atau bahkan memburuk. Pasien yang mengalami gejala serius seperti demam tinggi, kesulitan bernapas, batuk berdahak, dan nyeri dada harus segera mendapatkan perawatan medis di rumah sakit. Gejala serius tersebut dapat menyebabkan beberapa komplikasi seperti pneumonia, kegagalan ginjal, dan infeksi pada organ tubuh lainnya. [31]. Gejala ini muncul dalam waktu dua hari sampai dua minggu setelah terpapar covid-19. Virus ini menyebar lewat percikan ludah, batuk atau bersin [32]. Efek dari paparan virus ini menjadi lebih berbahaya jika terjadi pada individu yang memiliki kondisi penyakit bawaan, ibu hamil, orang tua, atau mereka dengan sistem kekebalan yang lemah. Tenaga medis yang menangani kasus Covid-19 diwajibkan menggunakan alat perlindungan diri (APD). Untuk mendeteksi infeksi Covid-19 pada pasien, beberapa metode pengujian seperti rapid test, swab test, dan CT scan digunakan. Saat ini, masih belum ada obat

yang dapat menyembuhkan Covid-19, tetapi beberapa penelitian sedang dilakukan untuk mengembangkan vaksin Covid-19. Beberapa langkah yang dapat diambil untuk mencegah penularan Covid-19 meliputi:

- a. Mencuci tangan dengan sabun dan air mengalir.
- b. Jika mengalami gejala Covid-19 lakukan isolasi mandiri dengan tinggal berpisah untuk sementara waktu.
- c. Gunakan masker saat beraktivitas di luar rumah terutama di tempat umum.
- d. Tidak menyentuh mata, hidung, dan mulut sebelum mencuci tangan atau ketika berada di tempat umum.
- e. Tutup mulut dan hidung ketika bersin dan batuk dengan siku bagian dalam atau tisu, kemudian buang tisu atau masker ke tempat sampah.
- f. Jaga kebersihan benda sekitar dengan menggunakan hand sanitizer atau cairan desinfektan.
- g. Jaga jarak minimal 1m dan jangan ke luar rumah kecuali ada keperluan mendesak.

2.2.4 Foto Rontgen

Pemeriksaan radiografi, yang sering disebut foto rontgen, menggunakan radiasi gelombang elektromagnetik untuk menghasilkan gambar organ tubuh manusia. Metode ini digunakan untuk melihat kondisi organ tubuh, mengamati perkembangan penyakit, dan memantau efektivitas pengobatan yang diberikan. Dalam pemeriksaan rongga dada, terdapat beberapa tipe berdasarkan posisi tubuh. Untuk pemeriksaan tampilan depan paru-paru, terdapat dua jenis yang umum digunakan yaitu Posterior-anterior (PA) dan Anterior-posterior (AP). Sementara itu, pemeriksaan tampilan samping sering disebut sebagai lateral. [33].

Untuk mendapatkan citra PA, seseorang akan berdiri dengan posisi dada yang menempel pada mesin serta lengan yang direntangkan ke samping [34]. Sedangkan untuk mendapatkan citra AP, seseorang diharuskan berdiri atau terlentang di tempat tidur dengan punggung menempel pada mesin. Citra lateral digunakan untuk melengkapi tampilan depan paru-paru, sebab tampilan dari total volume paru secara keseluruhan pada citra lateral merupakan citra terbaik [34].

Gambaran dari organ tubuh seperti tulang atau besi ditampilkan dengan warna putih, sedangkan untuk organ yang memiliki ruang akan berwarna hitam. Contoh foto rontgen dapat dilihat pada Gambar 2.1.



Gambar 2.1. Citra Rontgen Dada

2.2.5 Pembelajaran Dalam (*Deep Learning*)

Pembelajaran Dalam (*Deep Learning*) atau sering dikenal dengan istilah Pembelajaran Struktural Mendalam (*Deep Structured Learning*) atau Pembelajaran Hierarki (*Hierarchical Learning*) adalah salah satu cabang ilmu pembelajaran mesin (*Machine Learning*) yang terdiri dari algoritma pemodelan abstraksi tingkat tinggi pada data menggunakan sekumpulan fungsi transformasi non-linear yang data berlapis-lapis dan mendalam. Teknik dan algoritma dalam *Deep Learning* dapat digunakan baik untuk kebutuhan pembelajaran terarah (*Supervised Learning*), pembelajaran tak terarah (*Unsupervised Learning*) dan semi terarah (*Semi-Supervised Learning*) dalam berbagai aplikasi seperti pengenalan citra, pengenalan suara, klasifikasi teks, dan sebagainya. *Deep Learning* disebut *Deep* (dalam) karena struktur dan jumlah jaringan saraf pada algoritmanya sangat banyak bisa mencapai hingga ratusan lapisan (Dadang, 2018).

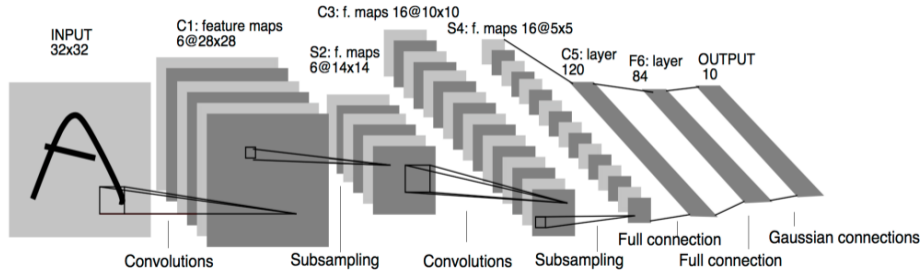
Pembelajaran Dalam (*Deep Learning*) atau sering dikenal dengan istilah Pembelajaran Struktural Mendalam (*Deep Structured Learning*) atau Pembelajaran Hierarki (*Hierarchical Learning*) adalah salah satu cabang ilmu pembelajaran mesin (*Machine Learning*) yang terdiri dari algoritma pemodelan abstraksi tingkat

tinggi pada data menggunakan sekumpulan fungsi transformasi non-linear yang data berlapis-lapis dan mendalam. Teknik dan algoritma dalam *Deep Learning* dapat digunakan baik untuk kebutuhan pembelajaran terarah (*Supervised Learning*), pembelajaran tak terarah (*Unsupervised Learning*) dan semi terarah (*Semi-Supervised Learning*) dalam berbagai aplikasi seperti pengenalan citra, pengenalan suara, klasifikasi teks, dan sebagainya. *Deep Learning* disebut *Deep* (dalam) karena struktur dan jumlah jaringan saraf pada algoritmanya sangat banyak bisa mencapai hingga ratusan lapisan (Dadang, 2018).

2.2.6 Convolutional Neural Network

Convolutional Neural Networks merupakan analog dengan *Artificial Neural Networks* tradisional dimana mereka terdiri dari neuron yang mengoptimalkan diri melalui pembelajaran. Setiap *neuron* masih akan menerima input dan melakukan operasi (seperti scalar produk diikuti oleh fungsi non-linear) basis *Artificial Neural Networks* yang tak terhitung jumlahnya. Dari input vektor gambar mentah ke hasil akhir dari skor kelas, seluruh jaringan masih akan mengekspresikan fungsi skor persepsi tunggal (berat). Lapisan terakhir akan berisi *loss function* yang terkait dengan kelas, dan semuanya tips dan trik regular yang dikembangkan untuk *Artificial Neural Networks* tradisional yang masih berlaku [35].

Salah satu perbedaan penting antara *Convolutional Neural Networks* dan *Artificial Neural Networks* tradisional adalah *Convolutional Neural Networks* digunakan di bidang pengenalan pola dalam gambar. Ini memungkinkan kami menyandikan fitur-fitur khusus gambar ke dalam arsitektur, membuat jaringan lebih cocok untuk tugas-tugas yang berfokus pada gambar dan mengurangi parameter yang diperlukan untuk mengatur model (O'Shea dan Nash, 2015). *Convolutional Neural Networks* terdiri dari tiga jenis lapisan. Lapisan tersebut yaitu *convolutional layers*, *pooling layers*, and *fully connected layers*. Ketika lapisan-lapisan ini ditumpuk. Sebuah arsitektur *Convolutional Neural Networks* telah terbentuk. Arsitektur *Convolutional Neural Networks* yang disederhanakan untuk *Modified National Institute of Standards and Technology database* (MNIST) klasifikasi diilustrasikan pada Gambar 3.4 (O'Shea dan Nash, 2015).



Gambar 2.2 Arsitektur *Convolutional Neural Network* [36]

Fungsionalitas dasar dari contoh CNN di atas dapat dibagi menjadi beberapa bagian utama.

a. *Input layer*

Seperti yang ditemukan dalam bentuk *Artificial Neural Networks* lainnya, *input layer* akan menampung nilai piksel dari gambar (O’Shea dan Nash, 2015).

b. *Convolutional layers*

Convolutional layers terdiri dari satu set kernel *convolution* dimana setiap neuron bertindak sebagai kernel. Namun, jika kernel simetris maka operasi konvolusi menjadi operasi korelasi. *Convolution* bekerja dengan membagi gambar menjadi irisan kecil yang biasa dikenal sebagai bidang *receptive*. Pembagian gambar menjadi blok-blok kecil membantu dalam mengekstraksi motif (Khan dkk, 2020).

Rumus operasi *convolution*:

$$f_i^k(p, q) = \sum_c \sum_{x,y} i_c(x, y) \cdot e_l^k(u, v) \quad (2.1)$$

dimana:

$f_i^k(p, q) = (p, q)$ elemen dari matrix fitur.

$i_c(x, y) = (x, y)$ elemen dari c^{th} channel pada gambar.

$e_l^k(u, v) = (x, y)$ elemen dari k^{th} kernel inti dari l^{th} lapisan.

Sedangkan output dari *feature map* k^{th} dapat dinyatakan:

$$F_i^k = [f_i^k(1,1), \dots, f_i^k(p, q), \dots, f_i^k(P, Q)] \quad (2.2)$$

dimana:

F_l^k = input matrix fitur untuk l^{th} lapisan dan k^{th} kernel.

$f_l^k(p, q)$ = (p, q) elemen dari matrix fitur.

$f_l^k(P, Q)$ = (P, Q) total baris dan kolom pada fitur matrix.

Karena kemampuan berbagai bobot dari operasi konvolusi, rangkaian fitur yang berbeda dalam gambar dapat diekstraksi dengan menggeser kernel dengan set bobot yang sama pada gambar dan dengan demikian membuat parameter CNN berkerja dengan efisien. Operasi *convolution* selanjutnya dapat dikategorikan ke dalam berbagai jenis *stride* dan *padding*.

Stride merupakan parameter yang digunakan untuk menentukan jumlah pergeseran *filter*. *Padding* merupakan penambahan jumlah *pixel* yang berisi nilai 0 yang ditambahkan disetiap sisi input. Operasi *convolution* dengan menggunakan parameter *stride* dan *padding* dapat dinyatakan:

$$dimention = \frac{V - F + 2P}{S} + 1 \tag{2.3}$$

dimana:


V = panjang / tinggi *input* (*volume size*)

F = panjang / tinggi *filter* (*kernel*)


P = *zero padding*

S = *stride*

Ilustrasi proses *convolution* dengan *stride 1* dapat dilihat pada Gambar 2.3 dan ilustrasi proses *zero padding* dapat dilihat pada Gambar 2.4.



Gambar 2.3 Ilustrasi *convolution* [37]



Gambar 2.4. Ilustrasi *zero padding* [37]

Pada Gambar 2.3 merupakan ilustrasi proses *convolution* merupakan proses *convolution* dengan *stride* 1 (a) *input* 5 x 5 dengan (b) *filter* 3 x 3 (c) dan menghasilkan *output* 3 x 3. Pada Gambar 2.4 merupakan ilustrasi *zero padding* (a) 1 dan (b) 2 pada data 3 x 3.

c. *Pooling layers*

Pooling layers kemudian hanya akan melakukan *downsampling* sepanjang dimensi spasial dari input yang diberikan, selanjutnya mengurangi parameter dalam aktivasi tersebut (O’Shea dan Nash, 2015). Motif fitur, yang dihasilkan sebagai output dari operasi *convolution* dapat terjadi pada lokasi yang berbeda pada gambar. *Pooling* bertujuan untuk mengurai ukuran pada matriks (Khan dkk, 2020).

Rumus operasi *pooling*:

$$\mathbf{Z}_l^k = g_p(\mathbf{F}_l^k) \tag{2.4}$$


dimana:

\mathbf{Z}_l^k = gabungan *feature map* dari l^{th} lapisan dan k^{th} kernel.

g_p = operasi *pooling*.

\mathbf{F}_l^k = input matrix fitur untuk l^{th} lapisan dan k^{th} kernel.

Ilustrasi proses *pooling* dapat dilihat pada Gambar 2.5.




Gambar 2.5. Ilustrasi *pooling* [39]

Pada Gambar 2.5 merupakan ilustrasi proses *pooling* dengan ukuran *filter* 2 x 2 dan *stride* 2.

d. ReLU (*Rectification Linear Unit*)

ReLU (*Rectification Linear Unit*) merupakan salah satu fungsi aktivasi yang paling umum digunakan. Berjalan seperti linear dan berfungsi ketika input lebih besar dari 0, jika tidak akan selalu sama dengan 0. Fungsi aktivasi ReLU dapat dinyatakan dengan $f(x) = \max(0, x)$ [37]. Ilustrasi proses ReLU dapat dilihat pada Gambar 2.6.



Gambar 2.6. Ilustrasi ReLU [17]

Pada Gambar 2.6 merupakan ilustrasi proses ReLU dimana matrix yang bernilai negative akan diubah menjadi 0.

e. *Batch Normalization*

Batch Normalization digunakan untuk mengatasi masalah yang terkait dengan pergeseran kovarians internal pada *feature map*. Pergeseran kovarian internal merupakan perubahan pada distribusi nilai unit tersembunyi yang memperlambat konvergensi dan membutuhkan inisialisasi parameter (Khan dkk, 2020).

Rumus *batch normalization*:

$$N_l^k = \frac{F_l^k - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \tag{2.5}$$

dimana:

N_l^k = *feature map* yang dinormalisasi.

F_l^k = *input feature map*.

μ_B = nilai rata-rata.


σ_B^2 = varians dari *feature map* untuk *batch* mini.

ε = stabilitas numerik.

Batch normalization menyatukan distribusi nilai *feature map* dengan mengaturnya dengan rata-rata nol dan unit varians. Selain itu, memperlancar dan mengatur aliran gradien yang membantu dalam meningkatkan generalisasi pada jaringan.

f. *Flatten*

Setelah tahap *pooling* selesai, tahap selanjutnya yaitu *flatten* yang bertujuan membentuk ulang fitur menjadi sebuah *vector* agar dapat digunakan sebagai *input* pada *fully connected layer*. Ilustrasi *flattening* dapat dilihat pada Gambar 2.7.

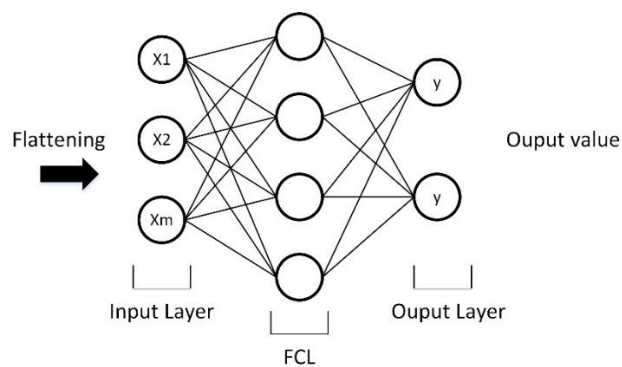


Gambar 2.7 Ilustrasi flattening [40]

g. *Fully Connected Layers*

Fully connected layers sebagian digunakan pada akhir jaringan untuk tujuan klasifikasi. Dibutuhkan input dari tahap ekstraksi *feature* dan secara global menganalisis output dari semua lapisan sebelumnya. Ini membuat kombinasi non – linear dari fitur yang dipilih, untuk digunakan untuk klasifikasi data (Khan dkk, 2020).

Fully connected layers disini merupakan *multilayer perceptron* yang setiap node-nya berhubungan ke semua *node layer* berikutnya melalui sebuah matriks bobot yang direpresentasikan sebagai sebuah net. Bobot pada *fully connected layers* juga dilakukan dengan berbagai cara seperti kernel pada proses *convolution* seperti, random normal, random uniform, glorot uniform, glorot normal, he normal, dan he uniform. Ilustrasi *fully connected layer* dapat dilihat pada Gambar 2.8.



Gambar 2.8. Ilustrasi fully connected layer [40]

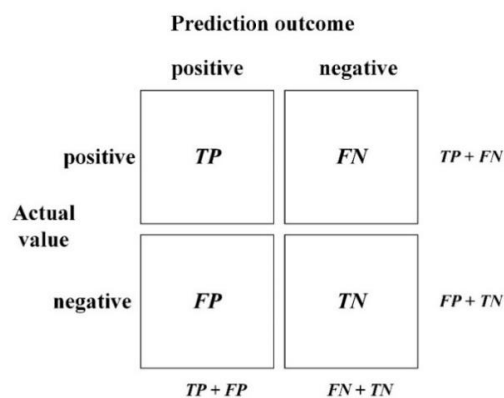
Matriks input akan melalui operasi perkalian matriks dengan semua matriks bobot pada setiap layer nodes. Pada setiap layer node hasil dari operasi akan diaktivasi dengan fungsi tertentu, proses ini disebut *forwardpropagation*. Setelah proses *forwardpropagation* selanjutnya yaitu *backpropagation*, yang dilakukan untuk menyesuaikan kembali tiap bobot berdasarkan *error* yang didapatkan pada saat proses *forwardpropagation*.

2.2.7 Evaluasi Klasifikasi

Evaluasi ketepatan klasifikasi adalah suatu evaluasi yang melihat peluang kesalahan klasifikasi yang dilakukan oleh suatu fungsi klasifikasi [41].

a. Confusion Matrix

Confusion matrix merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja pada metode klasifikasi. *Confusion matrix* pada dasarnya mengandung informasi yang membandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya [42]. Pada jenis klasifikasi *binary* yang hanya memiliki kedua keluaran kelas. Pada Gambar 2.9 merupakan ilustrasi dari *confusion matrix*:



Gambar 2.9. *Confusion matrix* [43]

Berdasarkan gambar diatas terdapat 4 istilah sebagai representasi hasil proses klasifikasi pada *confusion matrix*. Istilah tersebut yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), yang dapat diperoleh nilai akurasi, presisi, *recall*, dan *f1-score*. Nilai akurasi

menggambarkan seberapa akurat sistem dapat mengklasifikasikan data secara benar, dengan kata lain nilai akurasi yaitu perbandingan antara data yang terklasifikasi benar dengan keseluruhan data. Nilai presisi menggambarkan jumlah data kategori *positive* yang diklasifikasikan secara benar dibagi dengan total data yang diklasifikasi *positive*. Nilai *recall* menggambarkan berapa persen data kategori *positive* yang terklasifikasi dengan benar oleh sistem. Nilai *F1-score* menggambarkan perbandingan rata – rata presisi dan *recall* yang dibobotkan.

Persamaan Akurasi:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} * 100\% \quad (2.6)$$

Persamaan Presisi:

$$Presisi = \frac{TP}{FP+TP} * 100\% \quad (2.7)$$

Persamaan *Recall*:

$$Recall = \frac{TP}{FN+TP} * 100\% \quad (2.8)$$

Persamaan *F1-score*:

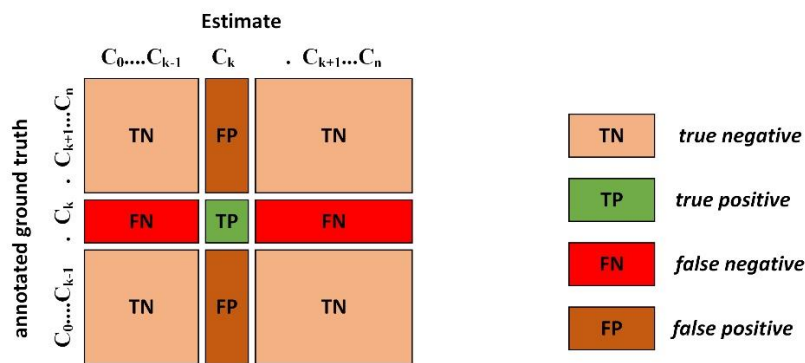
$$F1-score = 2 * \frac{Recall*Presisi}{Recall+Presisi} \quad (2.9)$$

dimana:

- (a) TP merupakan True Positive, yaitu jumlah data *positive* yang terklasifikasi dengan benar oleh sistem.

- (b) TN merupakan True Negative, yaitu jumlah data negative yang terklasifikasi dengan benar oleh sistem.
- (c) FP merupakan False Positive, yaitu jumlah data positive namun terklasifikasi salah oleh sistem.
- (d) FN merupakan False Negative, yaitu jumlah data negative namun terklasifikasi salah oleh sistem.

Sedangkan pada klasifikasi dengan jumlah keluaran kelas yang lebih dari satu atau dua (*multi-class*), cara menghitung akurasi, presisi, *recall*, dan *f1-score* dapat dilakukan dengan menghitung rata – rata dari nilai akurasi keseluruhan, dan juga presisi, *recall*, dan *f1-score* pada setiap kelas. Pada Gambar 2.10 merupakan ilustrasi *confusion matrix multiclass*:



Gambar 2.10 Confusion matrix multiclass [44]

Confusion matrix dari klasifikasi dengan n class. Ketika mempertimbangkan class k ($0 \leq k \leq n$), hasil klasifikasi dari ke empat nya berbeda dimana: *true positive* (hijau), *true negative* (orange), *false positive* (coklat), dan *false negative* (merah).

Persamaan Akurasi:

$$Akurasi = \sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} * 100\%$$

(2.10)

dimana:

- (a) TP_i adalah *true positive*, yaitu jumlah data *positive* yang terklasifikasi dengan benar oleh sistem untuk kelas ke $- i$.
- (b) TN_i adalah *true negative*, yaitu jumlah data *negative* yang terklasifikasi dengan benar oleh sistem untuk kelas ke $- i$.
- (c) FN_i adalah *false positive*, yaitu jumlah data *positive* namun terklasifikasi salah oleh sistem untuk kelas ke $- i$.
- (d) FP_i adalah *false negative*, yaitu jumlah data *negative* namun terklasifikasi salah oleh sistem untuk kelas ke $- i$.
- (e) l merupakan jumlah kelas.

Persamaan presisi setiap kelas:

$$Presisi_{class} = \frac{TP_{class}}{TP_{class} + FP_{class}} * 100\% \quad (2.11)$$

Persamaan *recall* setiap kelas:

$$Recall_{class} = \frac{TP_{class}}{TP_{class} + FN_{class}} * 100\% \quad (2.12)$$

Persamaan *F1-score* setiap kelas:

$$F1-score_{class} = 2 * \frac{Recall_{class} * Presisi_{class}}{Recall_{class} + Presisi_{class}} \quad (2.13)$$

dimana:

- (a) TP_{class} adalah *true positive*, yaitu jumlah data *positive* yang terklasifikasi dengan benar oleh sistem untuk kelas tertentu.
- (b) FP_{class} adalah *false positive*, yaitu jumlah data *positive* namun terklasifikasi salah oleh sistem untuk kelas tertentu.

(c) FN_{class} adalah *false negative*, yaitu jumlah data *negative* namun terklasifikasi salah oleh sistem untuk kelas tertentu.