

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Leukemia

Leukemia adalah penyakit klonal, yang berarti satu sel kanker abnormal berkembang biak secara tidak terkendali dan menghasilkan sekelompok sel anak yang tidak biasa. Sel-sel ini menumpuk di sumsum tulang dan menghentikan sel darah lain berkembang secara normal. Karena hal tersebut, leukemia disebut sebagai accumulation disorder dan clonal disorder. Pada akhirnya, sel leukemia mengambil alih sumsum tulang dan menyebabkan penurunan jumlah sel nonleukemik dalam darah [17].

#### 2.2 Deep Learning

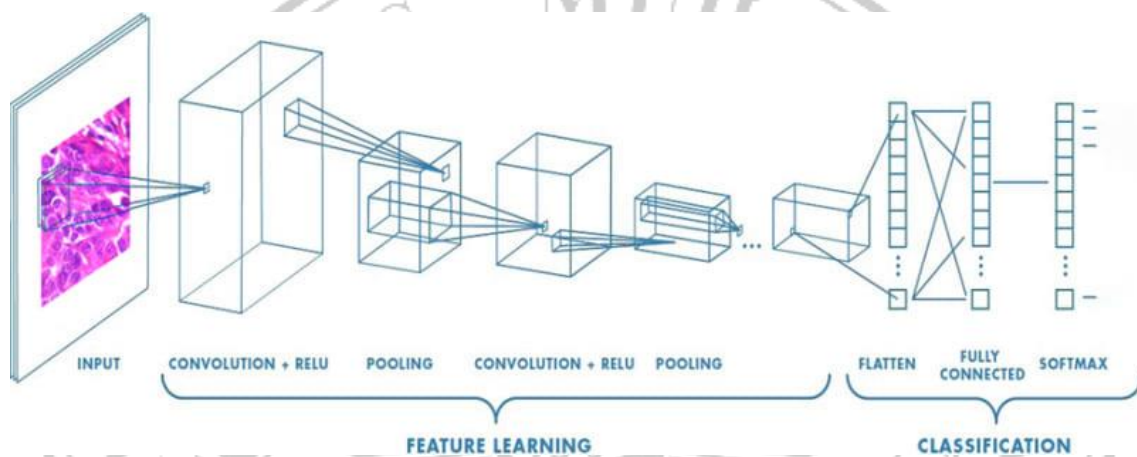
Salah satu cabang ilmu pembelajaran mesin adalah *deep learning*, juga disebut pembelajaran hierarki atau pembelajaran struktural mendalam. *Deep learning* terdiri dari pendekatan pemodelan data yang sangat abstrak menggunakan serangkaian fungsi transformasi nonlinier yang diatur secara mendalam dan berlapis-lapis [18].

*Deep Learning* bergantung pada karakteristik hierarkis, yang dapat disesuaikan dengan ukuran tertentu yang sesuai untuk skenario yang sedang dipertimbangkan. Akibatnya, algoritme pembelajaran mendalam memiliki kemampuan untuk melakukan ekstraksi fitur otomatis yang komprehensif dari data yang belum diproses. Ini hasil dari prosedur ekstraksi menggunakan struktur exploit, memungkinkan fitur untuk tetap tidak dieksploitasi secara implisit [19].

Metode pembelajaran mendalam membantu dalam studi analisis citra medis dengan menjelaskan pola penggunaan pemroses gambar. Prosesor yang menggunakan algoritma klasifikasi dikategorikan dalam pembelajaran yang diawasi [20]. *Deep learning* digunakan pada alat medis seperti CT scan, MRI, dan lainnya. Berdasarkan gambar yang diperoleh, kita dapat mendeteksi penyakit organ dalam seperti kanker, lesi, leukemia, dan lain-lain.

## 2.3 Convolutional Neural Network

Salah satu struktur Deep Learning adalah CNN (*Convolutional Neural Network*). CNN muncul dari penelitian tentang korteks otak dan telah digunakan untuk pengenalan gambar komputer sejak tahun 1980-an. Karena perkembangan komputer yang pesat dalam sepuluh tahun terakhir[21]. CNN telah mampu menyelesaikan masalah visual komputer yang kompleks dengan lebih baik daripada manusia. Selain masalah visual komputer seperti sistem pencarian gambar, mobil yang dapat berjalan sendiri, sistem klasifikasi video otomatis, dan pengenalan suara.




**Gambar 2.1** Arsitektur CNN

Berdasarkan pada **Gambar 2.1**, CNN memiliki tiga jenis lapisan: *convolutional*, *pooling*, dan *fully-connected*. Layer input berfungsi sebagai nilai pixel dari gambar, lapis *convolutional* menentukan output neuron yang terhubung ke input, lapis *pooling* melakukan *downsampling* pada dimensi spasial dari input, dan lapis *fully-connected* bertanggung jawab untuk menghasilkan nilai prediksi.

### 2.3.1 Convolution Layer

*Convolution layer* digunakan untuk mengekstraksi fitur dari data spasial, seperti gambar, dengan melakukan operasi konvolusi pada input data dan menggunakan filter *convolution* untuk menghasilkan feature map. Filter *convolution* adalah matriks yang digunakan untuk mengambil informasi dari input data dengan mengalikan setiap elemen pada filter dengan elemen yang sesuai pada input data, dan kemudian menjumlahkan

hasilnya[22]. Proses ini dilambangkan dengan layer konvolusi Untuk meningkatkan efisiensi komputasi dan mengurangi dimensi spasial *feature map*, lapis *convolution* biasanya diikuti oleh lapis *pooling*. Lapis *convolution* sangat penting untuk arsitektur CNN dan digunakan untuk berbagai fungsi seperti pengenalan objek, klasifikasi gambar, dan deteksi pola.




**Gambar 2. 2** Ilustrasi Convolution Layer

Berdasarkan pada **Gambar 2.2**, dijelaskan proses konvolusi di mana input gambar akan dikonversikan ke ukuran 4x4, Kernel 3x3 bergerak dari kiri atas ke kanan bawah, sehingga membuat satu nilai *output* baru dengan menggabungkan hasilnya.

### 2.3.2 Pooling Layer

*Pooling layer* adalah lapisan yang meminimalkan dimensi spasial fitur konvolusional, sehingga mengurangi sumber daya komputasi yang diperlukan untuk pemrosesan data. Hal ini dilakukan dengan mengurangi dimensi *feature map* juga dikenal sebagai *downsampling*, yang berarti bahwa parameter yang diperbarui semakin sedikit, yang menghasilkan peningkatan kecepatan komputasi[23]. Selain itu, berguna untuk mengidentifikasi fitur dominan, yang menghasilkan proses pelatihan model yang lebih efisien.



**Gambar 2. 3** Ilustrasi Max dan Average Pooling

Berdasarkan pada **Gambar 2. 3**, *Max pooling* dan *average pooling* adalah dua jenis dari *pooling layer*. Hanya nilai piksel maksimum di bidang reseptif yang dipilih oleh filter saat melakukan *max pooling*. Misalnya, jika bidang reseptif kita memiliki 4 piksel

dengan nilai 34, 70, 112, dan 100, *max pool layer* akan menghasilkan output 112. Sedangkan *Average pooling* bekerja dengan menghitung nilai rata-rata piksel di bidang reseptif. Misalnya, jika diberikan 4 piksel dengan nilai 34,70,112, dan 100, *Average pool layer* akan menghasilkan output

### 2.3.3 Activation Layer

Fungsi *Activation Layer* pada CNN adalah persamaan matematika yang menentukan outputnya. Untuk memprediksi sebuah model, Fungsi aktivasi ini akan diimplementasikan untuk setiap neuron dalam jaringan, menentukan aktivasinya tergantung pada signifikansi setiap input. Fungsi aktivasi harus efisien secara komputasi karena memerlukan pemrosesan beberapa neuron untuk setiap sampel data. Fungsi aktivasi membantu dalam menstandarisasi keluaran setiap neuron ke kisaran 0 hingga 1 atau -1 hingga 1 [23].

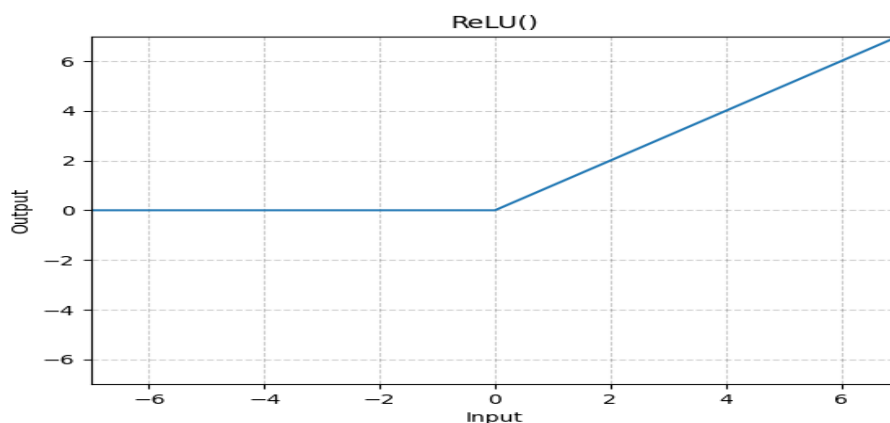
Fungsi ReLu, adalah fungsi non-linier di mana pengaktifan neuron tidak dilakukan secara bersamaan dan hanya dilakukan ketika output dari transformasi linier bernilai nol. Berikut rumus persamaan fungsi ReLu (1).

$$r(x) = \max(0, x) \quad (1)$$

Ket :

$x$  = Nilai dari data input

$r(x)$  = Fungsi ReLu menghasilkan nilai dalam bentuk 0 dan 1.

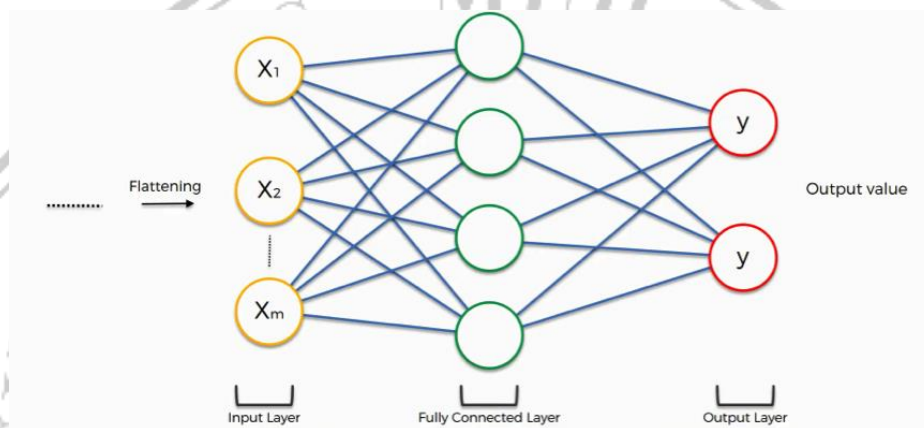


**Gambar 2. 4** Fungsi ReLu

Berdasarkan pada **Gambar 2.4**, jika memasukan neuron negatif, fungsi ReLu akan menerjemahkannya ke nilai 0, dan jika masukan neuron positif, output neuron adalah nilai aktivasi itu sendiri.

### 2.3.4 Fully Connected Layer

Berdasarkan pada **Gambar 2.5**, Setiap lapisan neuron aktif dari lapisan sebelumnya saling berhubungan dengan lapisan berikutnya. Keluaran dari satu lapisan diubah menjadi data satu dimensi sebelum ditransmisikan ke semua neuron di lapisan yang terhubung penuh; setelah diratakan, lapisan penyatuan atau konvolusional terakhir dimasukkan ke dalam fully connected layer. Hasil dari lapisan ini adalah matriks 3 dimensi, untuk melakukan flattened dengan mengubah semua nilainya menjadi vector[24].




**Gambar 2. 5** Ilustrasi *Fully Connected Layer*

### 2.3.5 Dropout

Untuk menangani data yang tidak seimbang, pendekatan *undersampling* dan *oversampling* biasanya digunakan, tetapi keduanya memiliki keterbatasan. *Undersampling* dapat mengurangi jumlah sampel dan berisiko kehilangan data penting, sementara *oversampling* menyebabkan duplikasi data asli, meningkatkan risiko *overfitting* [25]. Cara terbaik untuk mengurangi masalah *overfitting* adalah dengan merata-ratakan nilai setiap input dalam berbagai kondisi. Namun, dengan sistem jaringan syaraf tiruan cara berpikir dasarnya yang bergantung pada operasi averaging akan memakan waktu yang lama. Dalam algoritma CNN, dropout menggabungkan berbagai jenis arsitektur untuk mengantisipasi *overfitting*.





**Gambar 2. 6** Ilustrasi Dropout

Berdasarkan pada **Gambar 2.6**, Jika nilai bobot meningkat, proses testing akan membutuhkan waktu yang lebih lama, yang nantinya akan mempengaruhi kinerja CNN saat melakukan testing. Menghilangkan neuron memerlukan penghapusan sementara dari jaringan saat ini. Ini mungkin neuron di lapisan tersembunyi atau lapisan yang terlihat di dalam jaringan. Neuron yang ditunjuk untuk eliminasi akan dipilih secara acak. Setiap neuron akan dialokasikan probabilitas mulai dari 0 hingga 1 [26].

### 2.3.6 Softmax

*Softmax* menghitung probabilitas distribusi dari vektor bilangan real dan menghitung probabilitas pada hasil *output*, yang terjadi di layer output di mana nilai probabilitas terbesar diambil sebagai prediksi. Fungsi aktivasi *softmax* menghasilkan keluaran yang bernilai antara 0 dan 1, dengan totalnya sama dengan 1 [27]. Berikut rumus persamaan *Softmax* (2).

$$f(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (2)$$

Ket :

$x$  = nilai input pada layer sebelumnya

$i, j$  = nilai indeks unit dan layer

Dalam model multi kelas, *Softmax* menghitung probabilitas untuk setiap kelas. Fungsi *Softmax* sebagian besar digunakan di hampir semua lapisan keluaran arsitektur pembelajaran mendalam. Perbedaan utama antara fungsi aktivasi *Sigmoid* dan *Softmax* adalah bahwa *Sigmoid* digunakan untuk klasifikasi biner, sedangkan *Softmax* digunakan untuk klasifikasi multikelas.

## 2.6 Studi pustaka

Bab ini menguraikan penelitian sebelumnya yang menjadi acuan untuk penelitian ini, beserta penjelasan tentang temuan dari banyak penelitian sebelumnya yang dapat dilihat pada **Tabel 2.1**.

**Tabel 2. 1** Studi literatur penelitian terdahulu

No.	Penulis	Tahun	Judul	Hasil
1.	Taha Emara, Heba M. Afify, Fatma Helmy Ismail, Aboul Ella Hassanien	2020	A MODIFIED INCEPTION-V4 FOR IMBALANCED SKIN CANCER CLASSIFICATION DATASET	Model yang diusulkan dapat mencapai akurasi 94,7% pada set uji dan 86% pada set validasi[11].
2.	Mohammed Abdulla Salim Al Husaini, Mohamed Hadi Habaebi1, Teddy Surya Gunawan, Md Rafiqul Islam, Elfatih A. A. Elsheikh, F. M. Suliman	2022	THERMAL-BASED EARLY BREAST CANCER DETECTION USING INCEPTION V3, INCEPTION V4, AND MODIFIED INCEPTION MV4	Mendapatkan tingkat akurasi rata-rata sebesar 99,712% dengan kesalahan margin sebesar $\pm 0,27\%$ dalam mengklasifikasikan gambar termal payudara[12].
3.	Joanna Jaworek- Korjakowska, Pawel Kleczek, Marek Gorgon	2019	MELANOMA THICKNESS PREDICTION BASED ON CONVOLUTIONAL NEURAL NETWORK	Mencapai akurasi keseluruhan sebesar 87,2%, dalam mengklasifikasikan

No.	Penulis	Tahun	Judul	Hasil
			WITH VGG-19 MODEL TRANSFER LEARNING	ketebalan melanoma[15].
4.	Dina M. Ibrahim, Nada M. Elshennawy, Amany M. Sarhan	2021	DEEP-CHEST: MULTI- CLASSIFICATION DEEP LEARNING MODEL FOR DIAGNOSING COVID-19, PNEUMONIA, AND LUNG CANCER CHEST DISEASES	Mendapatkan akurasi sebesar 98,05%, 98,05% recall, 98,43% presisi, dan 99,5% spesifisitas, dalam mengklasifikasikan gambar rontgen dan CT Scan dada[16].
5.	Shakir M. Abas and Adnan M. Abdulazeez	2021	Detection and Classification of Leukocytes in Leukemia using YOLOv2 with CNN	Mendapatkan akurasi deteksi sebesar 94.1% dan 92.4% klasifikasi dalam total waktu training 4 jam 44 menit pada dataset sel darah putih[28].
6.	Muhammad Islahfari Wahid, Syamsul Akbar Mustamin , dan Armin Lawi	2021	Klasifikasi Citra Penyakit Daun Tomat Menggunakan Inception V4.	Penelitian ini menghasilkan akurasi 90,00% dalam mengidentifikasi penyakit daun tomat [29].