

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Artificial Intelligence (AI)

Kecerdasan Buatan atau *Artificial Intelligence (AI)* adalah teknik yang digunakan untuk meniru kecerdasan yang dimiliki oleh makhluk hidup maupun benda mati untuk menyelesaikan sebuah persoalan. Kecerdasan buatan merupakan sebuah studi tentang bagaimana membuat komputer melakukan hal-hal yang pada saat ini dilakukan lebih baik oleh manusia (Rich, 1991). *Artificial Intelligence (AI)* memiliki tujuan untuk menciptakan komputer-komputer yang dapat berpikir lebih cerdas dan membuat mesin lebih berguna (Ramadhan, 2011).

Mesin bisa bertindak seperti manusia dengan dibekali pengetahuan serta kemampuan menalar yang baik. AI dibuat berdasarkan sistem yang memiliki keahlian seperti manusia pada domain tertentu yaitu disebut dengan *soft computing*. *Soft computing* merupakan inovasi baru dalam membangun sistem cerdas yang mampu beradaptasi dan bekerja lebih baik jika terjadi perubahan lingkungan. *Soft computing* juga mengeksploitasi adanya toleransi terhadap ketidakpastian, ketidaktepatan, dan kebenaran parsial sehingga dapat diselesaikan dan dikendalikan dengan mudah agar sesuai dengan realita.

2.1.2 *Machine Learning*

Machine Learning atau pembelajaran mesin adalah pendekatan dalam *Artificial Intelligence* yang banyak digunakan untuk menggantikan atau menirukan perilaku manusia untuk menyelesaikan masalah atau melakukan otomatisasi. Sesuai namanya, *machine learning* mencoba menirukan bagaimana proses manusia atau makhluk cerdas belajar dan menggeneralisasi. Setidaknya ada dua aplikasi utama dalam machine learning yaitu, klasifikasi dan prediksi (Ahmad, 2017).

Machine learning membantu menangani dan memprediksi data yang sangat besar dengan cara merepresentasikan data-data tersebut dengan algoritma pembelajaran. *Machine learning* dapat membantu komputer memprogram diri mereka sendiri. Pada dasarnya *machine learning* membiarkan data melakukan pekerjaan.

2.1.3 *Deep Learning*

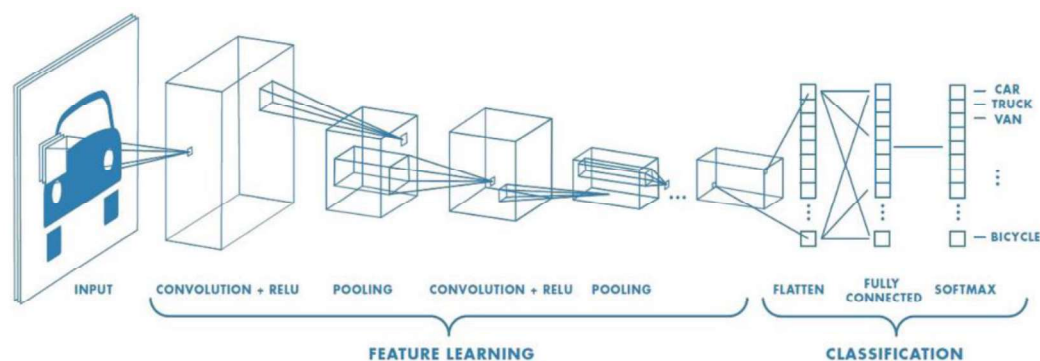
Deep learning adalah bagian dari *machine learning* yang menggabungkan model komputasi dan algoritma yang meniru arsitektur jaringan saraf biologis di otak manusia. Informasi baru yang diterima oleh otak akan dibandingkan dengan informasi yang telah diketahui sebelumnya untuk mendapatkan label baru yang dapat digunakan untuk menetapkan sebuah keputusan (Jakhar and Kaur 2020).

2.1.4 *Algoritma Convolutional Neural Network*

Convolutional Neural Network (CNN) merupakan algoritma yang termasuk ke dalam bagian dari *deep learning*. CNN sering digunakan untuk mengenali benda

dengan melakukan deteksi dan segmentasi objek. Kinerja CNN dalam melakukan deteksi sangat bergantung pada arsitekturnya (Sun et al. 2020).

CNN terdiri dari lapisan input, lapisan output, serta beberapa lapisan tersembunyi (*hidden layer*). *Hidden layer* dari CNN terdiri dari *convolutional layer*, *pooling layer*, *fully connected layer* dan *layer* normalisasi (ReLU). Lapisan tambahan dapat dimasukkan ke dalam CNN agar model lebih kompleks (Hussain, Bird, dan Faria 2019). Contoh dari arsitektur CNN dapat dilihat pada gambar 2.1.




Gambar 2. 1 Contoh Arsitektur CNN (Sumber :medium.com/@nadhifasofia)

Setiap lapisan dari arsitektur CNN memiliki karakteristik yang berbeda. Misalnya, jika input berupa gambar wajah, jaringan akan mempelajari beberapa karakteristik dasar dari gambar seperti titik-titik gelap dan cerah, bentuk dan sebagainya pada lapisan awal. Kumpulan lapisan berikutnya akan mendeteksi bentuk dan benda yang berhubungan dengan gambar yang dapat dikenali seperti mata, hidung dan mulut. Lapisan berikutnya terdiri dari aspek-aspek yang terlihat seperti wajah sebenarnya untuk mendefinisikan gambar tersebut adalah wajah manusia.

2.1.5 Convolution Layer

Convolution layer melakukan operasi konvolusi pada output dari lapisan sebelumnya. *Layer* tersebut adalah proses utama yang mendasari sebuah CNN. *Convolution layer* merupakan lapisan utama yang paling penting untuk digunakan. Konvolusi merupakan suatu istilah matematis yang dalam pengolahan citra berarti mengaplikasikan sebuah kernel (kotak kuning) pada citra disemua *offset* yang memungkinkan seperti yang ditunjukkan pada Gambar 2.2, sedangkan kotak berwarna hijau secara keseluruhan merupakan citra yang akan dikonvolusi. Kernel (kotak kuning) bergerak dari sudut kiri atas ke kanan bawah. Sehingga hasil konvolusi dari citra tersebut dapat dilihat pada gambar disebelah kanannya (Sari 2020).




Gambar 2. 2 Proses *Convolution Layer* (Sumber: burakbayramli.github.io)

Tujuan konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra input. Konvolusi akan menghasilkan transformasi linear dari data input sesuai informasi spasial pada data. Bobot pada *layer* tersebut menspesifikasikan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan input pada CNN.

2.1.6 Pooling Layer

Pooling Layer merupakan lapisan yang menggunakan fungsi dengan feature map sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat. *Pooling layer* pada model CNN biasanya disisipkan secara teratur setelah beberapa *convolution layer*. *Pooling layer* yang dimasukkan di antara lapisan konvolusi secara berturut-turut dalam arsitektur model *Convolutional Neural Network* dapat secara progresif mengurangi ukuran volume output pada feature map, sehingga jumlah parameter dan perhitungan di jaringan berkurang, serta untuk mengendalikan *overfitting*. *Pooling layer* digunakan untuk mengambil nilai maksimal (*max-pooling*) atau nilai rata-rata (*average pooling*) dari bagian-bagian piksel pada citra. Metode pooling yang sering digunakan dalam CNN adalah metode *max-pooling* (Sari 2020). *Max-pooling* membagi output dari *convolution layer* menjadi beberapa grid kecil lalu mengambil nilai maksimal dari setiap grid untuk menyusun matriks citra yang telah direduksi seperti yang ditunjukkan pada Gambar 2.3.



Gambar 2. 3 Proses *Pooling Layer* Metode *Max Polling*

(sumber : medium.com/@samuelsena)

Kotak yang berwarna merah, hijau, kuning dan biru pada sisi kiri merupakan kelompok kotak yang akan dipilih nilai maksimumnya. Sehingga hasil dari proses

tersebut dapat dilihat pada kumpulan kotak disebelah kanannya. Proses tersebut memastikan fitur yang didapatkan akan sama meskipun objek citra mengalami translasi (pergeseran). Penggunaan *pooling layer* pada CNN hanya bertujuan untuk mereduksi ukuran citra sehingga dapat dengan mudah digantikan dengan sebuah *convolution layer* dengan *stride* yang sama dengan *pooling layer* yang bersangkutan. *Stride* merupakan parameter yang menentukan berapa jumlah pergeseran *filter*. Jika nilai *stride* adalah satu, maka *filter* akan bergeser sebanyak satu piksel secara horizontal lalu vertikal. Semakin kecil *stride* yang digunakan, maka semakin detail informasi yang didapatkan dari sebuah input, namun membutuhkan komputasi lebih jika dibandingkan dengan *stride* yang besar.

2.1.7 Fully Connected Layer

Fully connected layer merupakan lapisan dimana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya. *Fully connected layer* biasanya digunakan dalam penerapan *Multi Layer Perceptron* (MLP) dan bertujuan untuk melakukan transformasi pada dimensi data agar dapat diklasifikasikan secara linear. Perbedaan antara *fully connected layer* dan *convolution layer* biasanya adalah neuron di *convolution layer* terhubung hanya ke daerah tertentu pada input, sedangkan *fully connected layer* mempunyai neuron yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoperasikan produk dot, sehingga fungsinya tidak begitu berbeda.

2.1.8 Confusion Matrix

Confusion matrix juga sering disebut *error matrix*. Pada dasarnya *confusion matrix* memberikan informasi perbandingan hasil klasifikasi yang dilakukan oleh sistem (model) dengan hasil klasifikasi sebenarnya. *Confusion matrix* adalah tabel yang menyatakan klasifikasi jumlah data uji yang benar dan jumlah data uji yang salah (Normawati dan Prayogi 2021).

Pada gambar 2.4 merupakan *confusion matrix* dengan 4 kombinasi nilai prediksi dan nilai aktual yang berbeda.

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <small>Type I Error</small>
	0 (Negative)	FN (False Negative) <small>Type II Error</small>	TN (True Negative)

Gambar 2. 4 *Confusion Matrix* (Sumber : <https://ksnugroho.medium.com>)

Terdapat 4 istilah sebagai representasi hasil proses klasifikasi pada *confusion matrix*. Keempat istilah tersebut adalah True Positive (TP), True Negative (TN), False Positive (FP) dan False Negative (FN).

- True Positive (TP): Merupakan data positif yang diprediksi benar.
- True Negative (TN): Merupakan data negatif yang diprediksi benar
- False Positive (FP) — Type I Error:

Merupakan data negatif namun diprediksi sebagai data positif.

- False Negative (FN) — Type II Error:

Merupakan data positif namun diprediksi sebagai data negative.

2.1.9 Klasifikasi

Klasifikasi adalah proses analisis data untuk melakukan pengelompokan data agar menghasilkan kelas baru berdasarkan aturan pengelompokan yang telah dibuat. (Sanjaya, Setyati, dan Budianto 2020).

2.1.10 Citra Digital

Citra (*image*) adalah kombinasi antara titik, garis, bidang dan warna untuk menciptakan suatu imitasi dari suatu objek, biasanya objek fisik atau manusia. Citra bisa berwujud gambar (*picture*) dua dimensi, seperti lukisan, foto dan berwujud tiga dimensi, seperti patung. Citra terbagi 2 yaitu ada citra yang bersifat analog dan ada citra yang bersifat digital. Citra analog tidak dapat direpresentasikan dalam komputer, sehingga tidak bisa diproses oleh komputer secara langsung. Citra analog harus dikonversi menjadi citra digital terlebih dahulu agar dapat diproses di komputer (Sutojo, 2017).

Sebuah citra dapat didefinisikan sebagai fungsi $f(x, y)$ berukuran M baris dan N kolom, dengan x dan y adalah koordinat spasial, dan amplitudo f di titik koordinat (x, y) dinamakan intensitas atau tingkat keabuan dari citra pada titik tersebut. Apabila nilai x , y dan nilai amplitudo f secara keseluruhan berhingga (*finite*) dan bernilai diskrit maka dapat dikatakan bahwa citra tersebut adalah citra digital (Putra, 2010).

2.1.11 Esofagitis

Esofagitis refluks adalah suatu kelainan yang terjadi akibat proses inflamasi pada *esofagus* (tenggorokan) yang dapat disebabkan oleh berbagai faktor diantaranya *refluks gastroesofagus* (RGE), infeksi (bakteri, virus dan jamur), atau bahan korosif (Hegar dan Mulyani 2006).

2.1.12 Normal-Z-Line

Normal-Z-Line di kerongkongan adalah istilah untuk bagian tenggorokan normal menyerupai bentuk zig-zag samar di persimpangan gastro-esofagus yang membatasi transisi antara epitel *skuamosa* berlapis di kerongkongan dan epitel usus dari kardia lambung (sambungan skuamokolumnar).

2.2 Penelitian Terkait dan Kebaruan Penelitian

Tantangan penelitian dijawab dengan memperluas *state-of-the-art* bidang penelitian dengan memasukkan unsur-unsur tambahan yang dapat memenuhi kebutuhan klasifikasi citra hasil endoskopi dengan metode pendekatan citra menggunakan *CNN*. Tabel 2.1 menunjukkan perbandingan penelitian yang berhubungan dengan fokus pada kontribusi dan batasan dalam proses klasifikasi citra.

Tabel 2. 1 *State of The Art* Penelitian Terkait

No	Nama Pengarang	Judul	Masalah	Solusi
1	(Athiyah, Muhiimah, and Marfianti 2018)	Ekstraksi Ciri Polip dan Pendarahan Berdasarkan Citra Endoskopi Kolorektal	Citra yang dihasilkan dari proses endoskopi sangatlah bervariasi, sehingga cukup sulit untuk mengenali tanda awal kanker kolorektal dengan cepat.	Melakukan deteksi pendarahan polip dengan menggunakan ekstraksi GLCM dan berdasarkan bentuk.
2	(Banwari et al. 2017)	Automated Segmentation of Colon Gland Using Histology Images	Interpretasi visual secara tradisional memiliki keterbatasan diantaranya pada sensitivitas, spesifitas dan subjektifitas serta memerlukan keahlian di bidang pantologi.	Deteksi kanker kolokteral dengan menggunakan based-thresholding dan automated segmentation dengan akurasi 91,25%.

No	Nama Pengarang	Judul	Masalah	Solusi
3	(Naufal, Adiwijaya, and Astuti 2020)	Analisis Perbandingan Klasifikasi Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) untuk Deteksi Kanker dengan Data Microarray	Diperlukan sebuah teknologi yang berguna untuk mendeteksi penyakit kanker dengan akurasi yang tinggi agar penyakit kanker dapat dideteksi sejak dini	Klasifikasi kanker dengan SVM dan KNN dengan akurasi tertinggi yaitu 98,54%.
4	(Yunianto, Anwar, and Septianingsih 2021)	Klasifikasi Kanker Paru-Paru Menggunakan Naïve Bayes Dengan Variasi Filter Dan Ekstraksi Ciri Gray Level Co-Occurance Matrix (GlcM)	Deteksi CT-Scan secara cepat perlu dilakukan serta perlunya juga perbaikan noise dalam citra hasil CT-Scan.	Ekstraksi citra dengan GLCM dan perbaikan noise dengan filtering dan klasifikasi dengan Naive Baiyes dengan nilai akurasi 88,3%
5	(Thohir et al. 2020)	Classification of Colposcopy Data Using GLCM-SVM on Cervical Cancer	Proses pendeteksian dilakukan oleh dokter dengan membuat pengamatan visual langsung. Pengamatan visual memiliki beberapa kelemahan yang menyebabkan kurangnya akurasi.	Deteksi dini kanker serviks dengan metode GLCM dan SVM dengan akurasi yang didapat adalah 90%.

2.2.1 Kebaruan Penelitian

Tabel 2. 2 Matriks Penelitian

No	Nama Peneliti	Tahun	Judul	Ruang Lingkup				Objek	
				Algoritma			Pengujian		
				Dataset	Ekstraksi	Pengolahan Data			
1	Ummi Athiyah dkk	2018	Ekstraksi Ciri Polip dan Pendarahan Berdasarkan Citra Endoskopi Kolorektal	Data endoskopi RS Pantj Rapih Yogyay	GLCM-Ekstraksi Bentuk	-	Independent t-Test	Kanker Kolokteral	
2	Banwari dkk	2016	Automated Segmentation of Colon Gland Using Histology Images	Hematoxylin and Eosin (H&E)	Intensity Based Thresholding	-	KNN	Kanker Kolokteral	
3	Naufal dkk	2020	Analisis Perbandingan Klasifikasi Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) untuk Deteksi Kanker dengan Data Microarray	Data Micro Array Colon	-	-	Partial Least Square	SVM-KNN	Kanker

No	Nama Peneliti	Tahun	Judul	Ruang Lingkup				Objek
				Algoritma				
				Dataset	Ekstraksi	Pengolahan Data	Pengujian	
4	Yunianto dkk	2021	Klasifikasi Kanker Paru Paru Menggunakan Naïve Bayes Dengan Variasi Filter Dan Ekstraksi Ciri Gray Level Co- Occurance Matrix (GLCM)	Daset Kanker NBIA	GLCM	-	Naive Baiyes	Kanker Paru-Paru
5	Thohir dkk	2020	Classification of Colposcopy Data Using GLCM-SVM on Cervical Cancer	Dataset GFMER	GLCM	-	SVM	Kanker Serviks
6	Imam Kharits	2022	Klasifikasi Penyakit Esophagitis Pada Citra Hasil Endoskopi Menggunakan CNN	Kvasir Dataset	-	-	CNN	Esofagitis

Keterangan:

GLCM = *Gray Level Co-Occurance Matrix*

KNN = *K-Nearest Neighbour*

SVM = *Support Vector Machine*

CNN = *Convolutional Neural Network*

2.2.2 Relevansi Penelitian

Tabel 2. 3 Relevansi Penelitian

Peneliti	(Athiyah, Muhimmah, and Marfianti 2018)	Imam Kharits (2022)
Judul	Ekstraksi Ciri Polip dan Pendarahan Berdasarkan Citra Endoskopi Kolorektal	Klasifikasi Penyakit Esophagitis pada Citra Hasil Endoskopi dengan menggunakan CNN
Masalah Penelitian	Citra yang dihasilkan dari proses endoskopi sangatlah bervariasi, sehingga cukup sulit untuk mengenali tanda awal kanker kolorektal dengan cepat.	Diperlukan sebuah sistem untuk mengklasifikasi citra endoskopi terutama pada esofagitis secara cepat dengan menggunakan deep learning.
Objek Penelitian	Citra Endoskopi Pendarahan Polip	Citra Endoskopi Esofagitis
Algoritma	GLCM-Ekstraksi Bentuk-Independt t-Test	CNN