

BAB II

TINJAUAN PUSTAKA

II.1 Analisis Kinerja Deep Learning Untuk Pengenalan Wajah

Beberapa penelitian sebelumnya yang terkait menggunakan metode pengenalan wajah dan analisis kinerja algoritma, diantaranya yaitu :

Pada penelitian sebelumnya, identifikasi wajah bermasker atau pun tidak menggunakan *CNN*. Fitur structural yang digunakan untuk mengidentifikasi wajah anatar lain mata, hidung, mulut dan batas karakteristik pada setiap citra gambar wajah. Data dibagi kedalam dua bagian yaitu *data latih* dan *data uji* dengan rasio 80:20. Data akan di modifikasi dengan metode *deep learning* yang dikenal dengan *DWSC-PCA-SAE (Depth-wise Separable Convolutional Neural Network using Principal Component Analysis and Stacked Autoencoder)*. Dengan menggunakan (*DWSC-PCA-SAE*) hasil yang di dapat jauh lebih baik disbanding metode *CNN* yang ada. Hasil akurasi 94,1%. *DWSC-PCA-SAE* memerlukan pemrosesan tambahan untuk membuat visualisasi data gambar wajah karena ini *DWSC-PCA-SAE* kurang dapat membedakan antara aplikasi wajah bermasker dan tidak bermasker yang sesuai. (Balasubaramanian S, et al., 2023)

Pada penelitian sebelumnya yang menggunakan *Deep metric learning* untuk mengetahui keretakan pada sistem rotor. *Deep metric learning* merupakan metode pemecahan masalah baru untuk pengenalan pola. Fungsinya untuk mempelajari jarak dan meningkatkan kerja algoritma. Sistem rotor dalam penelitian ini dibagi dalam 20 elemen dan 21 node. Pemecahan persamaan

menggunakan metode *Harmonic Balance Method (HBM)*. *CNN* akan memproses retak yang terjadi akibat respon frekuensi amplitudo pada sistem rotor pada daerah kecepatan rendah. Metode reduksi dan visualisasi digunakan untuk menganalisis distributor fitur *CNN* dan *CNN-C* pada ruang embedding. Metode *CNN-C* lebih baik dari pada *CNN* untuk mendiagnosis kesalahan lokasi retakan sistem rotor dengan hasil akurasi sebesar 98,15% dan 92,28%. (Jin Y, et al, 2021)

Penelitian terdahulu, diagnosa citra klinis dilakukan oleh *CNN* dengan pendekatan *ViT* alternatif untuk mendeteksi penyakit paru-paru. Model perbandingan untuk penelitian ini menggunakan *Visual Geometric Group Data Spatial Transformer (VDSNet)*. Data yang digunakan adalah data open source yang didapat dari website *Kaggle* sebanyak 112.120 gambar sinar X. hasil pengujian akan mendeteksi adanya penyakit pada paru-paru atau tidak. Model *ViT* memperoleh hasil akurasi yang lebih baik yaitu 70,24% dibandingkan dengan *VDSNet* yang hanya memperoleh tingkat akurasi 69,86%. *ViT* bekerja lebih baik karena ukuran gambar yang semakin kecil dan layer internal bertambah untuk pendeteksian. (Uparkar O, et al, 2023)

Penelitian yang dilakukan oleh (Han H., et al., 2022) bidang daur ulang sumber daya logam memiliki kekurangan pengenalan produk logam yang baik dan akurat. Pelatihan ganda dilakukan oleh *CNN*. Data yang digunakan sebanyak 9266 gambar dalam 18 kategori untuk alat limbah rumah tangga (*WHMA*) dan 11.757 gambar dalam 32 kategori limbah peralatan listrik dan elektronik (*WEEE*). *Matriks konvolusi* akan mengidentifikasi limbah dengan ciri yang dapat di daur ulang. Model *CNN* dengan *Multi-branch residual* sebagai backbone dapat

memperoleh akurasi rata-rata yang lebih tinggi. Mengidentifikasi logam limbah *WHMA* dan *WEEE* mencapai akurasi 94,31% dan 95,88%. Sistem ini lebih efisien digunakan untuk menentukan logam yang bisa di daur ulang.

Pada penelitian sebelumnya, *Notasi Big-O* digunakan untuk mengetahui kompleksitas algoritma *MFCC*. *MFCC (Mel-Frequency Cepstral Coeffisients)* merupakan metode yang digunakan untuk peningkatan akurasi. Ekstraksi ciri merupakan bagian penting pada pengenalan suara. Ekstraksi ciri pada penelitian ini berguna untuk mengetahui pola frekuensi pada setiap kata yang dihasilkan oleh suara. Penelitian ini tidak hanya sekedar menemukan nilai akurasi tetapi juga menemukan kompleksitas algoritma yang digunakan. *MFCC-Multikanal* dan *MFCC-Dualkanal* adalah model *MFCC* yang akan dianalisis. Terdapat tiga notasi yaitu O (Big-oh), Ω (Omega), θ (Teta) yang masing-masing adalah batas atas, batas bawah dan batas antara. Analisa ketiga notasi ini digunakan untuk melihat *running time* dan kebutuhan memori. Nilai kompleksitas dipresentasikan berdasarkan data masukan. Untuk memilah frekuensi digunakan *filter digital* kemudian diekstraksi menggunakan metode *MFCC*. Perbandingan *MFCC- Multikanal* dan *MFCC-Dualkanal* dilakukan dengan menginput beberapa varian data ekstraksi dan hasil kompleksitas yang didapat adalah terendah 0.007 detik tertinggi 23.721 detik (varian data uji 1-400 kata) untuk *MFCC-Multikanal* dan terendah 0.0040 detik tertinggi 12.58 detik (varian data uji 1-400 kata) untuk *MFCC-Dualkanal*. (Huizen R, et al., 2019)

Pada penelitian sebelumnya *Notasi Big-O* mencari kompleksitas algoritma *bruce force* dan *divide and conquer*. Keduanya sama-sama algoritma *sorting*

(pengurutan) tetapi memiliki cara kerja yang berbeda. Untuk mengetahui efektivitas dari kedua algoritma tersebut perlu dilakukan analisa dalam kompleksitas dimensi waktu dengan mengukur waktu eksekusi dengan *Notasi Big-O*. Algoritma *bruce force* menggunakan metode *bubble sort* dan algoritma *divide and conquer* menggunakan metode *merge sort*. Masing-masing algoritma melakukan pengurutan dan kompleksitas waktu akan dihitung oleh *Notasi Big-O* seiring bertambahnya jumlah masukan data dalam proses pengurutan. Proses dijalankan dengan menginput 1000 data, lalu kemudian bertambah banyak mencapai 5000 data. Percobaan dilakukan selama 5 kali dan dalam setiap percobaan dilakukan 7 kali perhitungan waktu. Hasil yang didapat untuk 1000 data adalah 0,22 detik untuk *bubble sort* dan 0,05 detik untuk *merge sort*. Hasil yang didapat untuk 5000 data adalah 5,69 detik untuk *bubble sort* dan 1,15 detik untuk *merge sort*. (Jaya I., et al.,2020)

Deep learning dengan metode *CNN* digunakan untuk pengenalan wajah pada sistem keamanan pintu akses pada sebuah bank. Tahapan pengenalan wajah pada penelitian ini adalah akuisisi gambar, preprocessing, ekstraksi, klasifikasi dan identifikasi. Dataset menggunakan wajah 5 orang data pegawai bank dari 70 data wajah pada masing-masing orang. Total data adalah 350 dan dibagi dalam 3 tahapan data yaitu *data training*, *data validasi* dan *data uji*. Dari hasil pengujian, program dapat mengidentifikasi wajah dengan presentasi keakuratan 95%. (Arsal M., et al.,2020).

II.2 Citra

Citra adalah kombinasi antara titik, garis, bidang, dan warna untuk menciptakan suatu imitasi dari suatu objek fisik atau manusia. Citra juga dapat diartikan sebagai gambar yang mirip dengan objek aslinya. Perkembangan citra membuat berbagai jenis data citra dapat diolah dan dimanipulasi menggunakan teknik tertentu”. Citra (*image*) menjadi salah satu bidang dari pada multimedia yang dianggap berperan penting terhadap bentuk-bentuk informasi visual karena citra dapat memberikan persepsi tentang suatu objek (Prasetio A, 2021).

II.2.1 Citra Biner

Sebuah citra biner adalah citra digital yang hanya memiliki dua kemungkinan nilai untuk masing - masing piksel. Umumnya dua warna yang digunakan untuk citra biner adalah hitam dan putih. Citra biner biasanya juga disebut *bilevel* atau *two - level*. Artinya bahwa tiap tiap piksel disimpan dalam sebuah single bit (0 atau 1). Konsep ciitra biner biasanya disebut dengan *black- and white*, B&W, *monochrome* atau *monochromatic*, tetapi bisa juga didefinisikan dengan citra yang hanya memiliki satu sampel tiap piksel seperti citra *gray-scale* (Nabuasa Y, 2019).

II.2.2 Citra Grayscale

Proses yang banyak dilakukan dalam *image processing* adalah mengubah citra berwarna menjadi *citra grayscale*. Hal ini dilakukan dengan menyederhanakan model citra berwarna (RGB) yang terdiri dari 3 layer matrik yaitu *R-layer*, *G-layer* dan *B-layer*. Setiap proses perhitungan dilakukan

menggunakan tiga layer. Artinya dilakukan tiga perhitungan yang sama pada ketiga layer tersebut (Munantri et al 2019). Untuk mendapatkan citra dalam bentuk grayscale, salah satu rumus yang dapat digunakan adalah sebagai berikut :

$$\text{Grayscale} = 0.3\text{RED} + 0.59 \text{ GREEN} + 0.11\text{BLUE} \quad (1)$$


II.2.3 Citra Warna

Red (Merah), Green (Hijau) dan Blue (Biru) merupakan warna dasar yang dapat diterima oleh mata manusia. Setiap piksel pada citra warna mewakili warna yang merupakan kombinasi dari ketiga warna dasar RGB. Setiap titik pada citra warna membutuhkan data sebesar 3 byte. Setiap warna dasar memiliki intensitas tersendiri dengan nilai minimum nol (0) dan nilai maksimum 255 (8 bit). Citra high color biasanya disebut citra warna 16 bit setiap pixelnya diwakili dengan 2 byte memory. Citra 16 bit memiliki warna 65.536 warna. Dalam formasi bitnya, nilai red dan blue mengambil tempat di 5 bit kanan dan kiri. Komponen green memiliki 5 bit ditambah 1 bit ekstra (Azlansyah M.,2019).

II.3 Pengolahan Citra Digital


Pengolahan Citra Digital (*Digital Image Processing*) merupakan disiplin ilmu yang mempelajari teknik dalam mengolah citra, citra yang dimaksud adalah merupakan gambar diam (foto) atau gambar yang bergerak (seperti video yang direkam). Sedangkan arti digital adalah pengolahan citra/gambar dilakukan menggunakan komputer secara digital. RGB adalah singkatan dari Red-Green-Blue, merupakan tiga warna dasar (primary colors) yang secara umum dijadikan acuan warna lainnya. Dari basis RGB, kita dapat mengkonversi warna menjadi

kode-kode angka yang membuat warna tersebut akan tampil universal (Ratna S, 2020).



Gambar 1.1 Proses Sederhana Pengolahan Citra

Pengenalan wajah merupakan teknologi komputer yang dapat digunakan untuk menentukan ukuran pada wajah, pendeteksian wajah, lokasi wajah, dan pengabaian latar belakang (background) citra, yang dimana kemudian dilakukan pengidentifikasian pada citra suatu wajah (Adrianto et al., 2021).



Gambar 1.2 Model Sistem Klasifikasi Pengenalan Wajah

II.4 Artificial Intelligence


Artificial Intelligence (AI) adalah istilah umum untuk ilmu kecerdasan buatan. Ini menggunakan komputer untuk mensimulasikan perilaku cerdas manusia dan melatih komputer untuk mempelajari perilaku manusia seperti belajar, penilaian, dan pengambilan keputusan (Xu et al., 2021).

AI memainkan peran yang sangat diperlukan dalam pembangunan sosial, dan telah membawa hasil revolusioner dalam meningkatkan efisiensi tenaga kerja, mengurangi biaya tenaga kerja, mengoptimalkan struktur sumber daya manusia, dan menciptakan tuntutan pekerjaan baru (Duan et al., 2019).

II.4.1 Machine Learning

Selama beberapa dekade terakhir, bidang *ML* telah menghasilkan berbagai kemajuan luar biasa dalam algoritme pembelajaran yang canggih dan teknik prapemrosesan yang efisien. Salah satu kemajuan ini adalah evolusi jaringan syaraf tiruan (Janiesch et al., 2021)

Dalam *Machine Learning*, sebuah program komputer ditugaskan untuk melakukan beberapa tugas dan dikatakan bahwa mesin telah belajar dari pengalamannya jika kinerjanya yang dapat diukur dalam tugas-tugas ini meningkat karena ia memperoleh lebih banyak pengalaman dalam melaksanakan tugas-tugas. Jadi mesin mengambil keputusan dan melakukan prediksi/peramalan berdasarkan data (Ray Susmita., 2019.)



Gambar 1.3 Skema Hubungan AI dan ML

II.5 Deep Learning

Deep Learning merupakan metode learning yang memanfaatkan artificial neural network yang berlapis-lapis(multi layer). Artificial Neural Network kini dibuat mirip otak manusia, dimana neuron-neuron terkoneksi satu sama lain sehingga membentuk sebuah jaringan neuron yang sangat rumit (Adi Nugroho et al., 2020)

Beberapa algoritma termasuk dalam kategori Deep Learning antara lain:

- a. Convolutional Networks
- b. Restricted Boltzmann Machine (RBM)
- c. Deep Belief Networks (DBN)
- d. Stacked Autocoders

Deep Learning yang mulai populer digunakan sejak tahun 2006, menggunakan mekanisme *Deep Architecture Of Learning* atau pendekatan *Hierarchical Learning*. Learning atau pembelajaran dalam hal ini adalah sebuah prosedur yang berisi proses estimasi parameter-parameteer suatu model sehingga model yang di kembangkan (Algoritma) dapat menyelesaikan suatu tugas atau permasalahan tertentu. Beberapa teknik dalam *Deep Learning* dapat dikategorikan menjadi : *Supervised*, *Semi-Supervised* dan *Unsupervised*. Kategori laian seperti *Reinforcement Learning (RL)* atau *Deep RL (DRL)* (Alom et al., 2019)

II.6 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu jenis neural networks yang ada pada deep learning. Berbeda dengan ANN dan RNN, CNN

adalah jenis neural networks yang biasanya digunakan untuk mengolah data dalam bentuk citra. CNN bekerja menggunakan kernel. Kernel tersebut akan mengekstrak fitur dari input menggunakan operasi konvolusi. (Fawwaz et al., 2020)

Convolutional Neural Network (CNN) adalah salah satu algoritma deep learning yang digunakan untuk kasus-kasus penggunaan computer vision seperti mengklasifikasikan gambar atau video dan mendeteksi objek di dalam gambar atau bahkan wilayah dalam gambar (Moolayil, 2019)

Konvolusi adalah operasi matematis yang digunakan dalam pengolahan sinyal dan pengolahan gambar. Dalam konteks Convolutional Neural Network (CNN), konvolusi digunakan untuk mengekstraksi fitur dari gambar. Proses konvolusi melibatkan penggunaan filter (kernel) yang berukuran kecil yang diterapkan pada seluruh gambar secara bergeser.

Berikut adalah langkah-langkah utama dalam operasi konvolusi:

- a. Filter adalah matriks kecil yang digunakan untuk melakukan operasi konvolusi. Filter ini berfungsi untuk mendeteksi fitur-fitur tertentu dalam gambar, seperti tepi, sudut, atau tekstur.
- b. Filter diterapkan pada gambar dengan menggesernya di seluruh area gambar. Di setiap posisi, nilai piksel dalam filter dikalikan dengan nilai piksel yang sesuai dalam gambar, dan hasilnya dijumlahkan. Proses ini menghasilkan peta fitur (feature map) yang menyoroti lokasi fitur dalam gambar.
- c. Stride adalah langkah geser filter saat diterapkan pada gambar. Stride menentukan seberapa jauh filter digeser setiap kali operasi konvolusi dilakukan. Stride yang lebih besar menghasilkan peta fitur yang lebih kecil.
- d. Padding adalah proses menambahkan nilai piksel tambahan di sekitar gambar sebelum konvolusi dilakukan. Ini dapat membantu mempertahankan ukuran gambar saat konvolusi dilakukan, dan juga mengurangi efek

pinggiran (edge effects) yang mungkin terjadi.

Proses konvolusi ini memungkinkan CNN untuk secara efektif mengekstraksi fitur-fitur penting dari gambar, seperti garis, pola, dan tekstur, yang kemudian digunakan untuk tugas-tugas seperti klasifikasi gambar atau deteksi objek.

II.7 Notasi Big-O

Algoritma yang baik tidak hanya mampu memenuhi spesifikasi (kebutuhan) user tetapi juga harus memiliki efektivitas tinggi. Algoritma yang efektif artinya lebih serba guna pada berbagai mesin dan prosesor. Algoritma yang efektif dapat dilihat ketika semakin sedikit memori dan waktu yang terpakai saat pemrosesan.

Jumlah memori dan waktu yang digunakan bergantung pada masukan algoritma (inputan) atau n , semakin besar nilai masukan maka memori dan waktu yang dibutuhkan ketika menjalankan proses lebih besar pula. Keefektifan algoritma tidak bergantung pada *prosesor* maupun *compiler*.

Untuk dapat mengetahui seberapa efisien suatu algoritma, dipakailah teori kompleksitas algoritma sebagai dasar kajian. Kompleksitas Waktu, $T(n)$, adalah jumlah operasi yang dilakukan untuk melaksanakan algoritma sebagai fungsi dari ukuran masukan n . Maka, dalam mengukur kompleksitas waktu dihitunglah

banyaknya operasi yang dilakukan oleh algoritma. Idealnya, kita memang harus menghitung semua operasi yang ada dalam suatu algoritma. Namun, untuk alasan praktis, cukup menghitung jumlah operasi abstrak yang mendasari suatu algoritma. Operasi abstrak ini disebut Operasi Dasar. Biasanya kompleksitas algoritma dinyatakan secara asimptotik dengan *Notasi big-O* (Rahayuningsih P., 2021). Jika kompleksitas waktu untuk menjalankan suatu algoritma dinyatakan dengan $T(n)$ dan memenuhi :

$$T(n) \leq C(f(n)) \quad (2)$$

untuk $n \geq n_0$,

maka kompleksitas dapat dinyatakan dengan

$$T(n) = O(f(n)). \quad (3)$$

II.8 Penelitian Terkait

Tabel II.1. Penelitian terkait yang relevan

No	Nama Peneliti/Tahun	Judul Penelitian	Persamaan	Perbedaan
1	Balasubaramanian S, et al., 2023	An Effective Stacked Autoencoder Based Depth Separable Convolutional Neural Network Model For Face Mask Detection	Identifikasi wajah bermasker atau pun tidak menggunakan <i>CNN</i> . Fitur structural yang digunakan untuk mengidentifikasi wajah anatar lain mata, hidung, mulut dan batas	Menggunakan metode <i>deep learning</i> yang dikenal dengan DWSC-PCA-SAE (Depth-wise Separable Convolutional Neural Network using Principal

			karakteristik pada setiap citra gambar wajah.	Component Analysis and Stacked Autoencoder). Tidak menggunakan <i>Notasi Big-O</i> untuk mengetahui kompleksitas algoritma.
2	Jin Y, et al, 2021	An Effective Crack Position Diagnosis Method For The Hollow Shaft Rotor System Based On The Convolutional Neural Network And Deep Metric Learning	Menggunakan algoritma <i>Deep metric learning</i> Metode <i>CNN</i> dan <i>CNN-C</i>.	<i>CNN</i> untuk mengidentifikasi retakan sistem rotor. Tidak menggunakan <i>Notasi Big-O</i> untuk mengetahui kompleksitas algoritma.

3	Uparkar O, et al, 2023	Vision Transformer Outperforms Deep Convolutional Neural Network-Based Model In Classifying X-Ray Images	Diagnosa citra klinis dilakukan oleh CNN dengan pendekatan ViT alternatif untuk mendeteksi penyakit paru-paru.	Model perbandingan untuk penelitian ini menggunakan Visual Geometric Group Data Spatial Transformer (VDSNet).
4	Han H., et al., 2022	Metallic Product Recognition With Dual Attention And Multi-Branch Residual Block-Based Convolutional Neural Networks	Model CNN dengan Multi-branch residual sebagai backbone pada klasifikasi logam.	Data yang digunakan data gambar logam limbah WHMA dan limbah WEEE. Tidak menggunakan <i>Notasi Big-O</i> untuk mengetahui kompleksitas algoritma.
5	Huizen R, et al., 2019	Analisis <i>Running Time</i> Algoritma <i>MFCC-Multikanal</i> Dan <i>MFCC-Dualkanal</i> Untuk Ekstraksi	<i>Notasi Big-O</i> digunakan untuk mengetahui kompleksitas algoritma <i>MFCC (Mel-Frequency Cepstral Coeffisients)</i> .	Identifikasi ciri suara. Algoritma yang digunakan adalah <i>MFCC-Multikanal</i> dan <i>MFCC-Dualkanal</i> adalah model <i>MFCC</i> Tidak menggunakan

				metode <i>Deep Learning</i>
6	Jaya I., et al.,2020	Analisis Komprasi Algoritma <i>Sorting</i> Antara Metode <i>Brute Force</i> dengan <i>Devide and Conquer</i>	<i>Notasi Big-O</i> mencari kompleksitas algoritma <i>bruce force</i> dan <i>divide and conquer</i> .	Data yang digunakan adalah data angka dan di urutkan menggunakan <i>bruce force</i> dan <i>divide and conquer</i> . Tidak menggunakan metode <i>Deep Learning</i>
7	Arsal M., et al.,2020	<i>Face Recognition</i> untuk Akses Pegawai Bank Menggunakan <i>Deep Learning</i> dengan Metode <i>CNN</i>	Menggunakan <i>deep learning</i> dengan metode <i>CNN</i> untuk pengenalan wajah.	Menggunakan framework tensorflow dan arsitektur model VGG16 untuk identifikasi gambar wajah Menggunakan <i>Notasi Big-O</i> .
8	Sudirman, 2021	<i>Machine Learning</i> Deteksi Jatuh Menggunakan Algoritma <i>Human Posture Recognition</i>	Menggunakan algoritma <i>machine learning</i> untuk pengenalan pola gambar bergerak. Proses <i>computer vision</i> (segmentasi, klasifikasi,dll) yang digunakan merupakan langkah pada penelitian ini.	Data yang digunakan adalah gambar bergerak (Video) yang mengamati gerak jatuh pada tubuh manusia menggunakan algoritma <i>Human Posture Recognition</i>
9	Melangi S, 2020	Klasifikasi Usia	Data merupakan citra	Menggunakan

		Berdasarkan Pola Citra Wajah Menggunakan Algoritma <i>Artificial Neural Network</i> dan <i>Gabor Filter</i>	wajah yang perlu dikenali untuk mengetahui usia berdasarkan wajah. Proses <i>computer vision</i> (segmentasi, klasifikasi, dll) yang digunakan merupakan langkah pada penelitian ini.	Algoritma <i>Artificial Neural Network</i> dan <i>Gabor Filter</i> dalam pengenalan citra wajah
10	Riadi A, et al, 2019	Analisis Implementasi <i>Preprocessing</i> dengan <i>Otsu-Gaussian</i> pada Pengenalan Wajah	Data gambar wajah di kenali menggunakan algoritma <i>deep learning (SVM)</i>	Lebih menganalisis implementasi metode <i>preprocessing</i> pada data gambar wajah bukan algoritma yang digunakan

II.9 Kontribusi Penelitian

Kontribusi pada penelitian ini adalah menganalisis kinerja algoritma dengan mengukur tingkat efisiensi algoritma *Deep Learning* dengan metode *Convolutional Neural Network* untuk pengenalan wajah menggunakan *Notasi Big-O*. Pada penerapannya, *Notasi Big-O* digunakan untuk mengukur tingkat lamanya *proses running*, *space memory* yang digunakan berbanding lurus dengan penambahan data input dan menggambarkan kerumitan suatu sistem.

