

BAB II

TINJAUAN PUSTAKA

II.1 Penelitian Terkait

Pada Penelitian yang dilakukan oleh (Mohamed et al. 2018) yang berjudul **“Enhanced Human Face Recognition Using LBPH Descriptor, Multi-KNN, and Back-Propagation Neural Network”** menggunakan metode *Backpropagation Neural Network* Kontribusi utama dari pekerjaan ini adalah peningkatan pengenalan wajah manusia menggunakan LBPH, multi-KNN, dan BPNN. Kekuatan pendekatan kami didasarkan pada penambahan langkah setelah ekstraksi fitur dan reduksi dimensi untuk mendapatkan T-Dataset pembedaan yang jelas, yang akan digunakan untuk melatih *Backpropagation Neural Network*. Kebaruannya terletak pada T Dataset baru yang dicapai dengan mempertimbangkan korelasi antara gambar pelatihan, tidak seperti metode yang ada yang hanya mengandalkan kepadatan gambar.

Pada Penelitian yang dilakukan oleh (Wachiraphong et al, 2022) dengan judul **“An Improved Technique for Pneumonia Infected Patients Image Recognition Based on Combination Algorithm of Smooth Generalized Pinball SVM and Variational Autoencoders”** dengan metode Support Vector Machine (SVM). Dalam penelitian ini, mencoba menunjukkan bahwa Support Vector Machine masih salah satu metode terbaik untuk pembelajaran yang diawasi, terutama untuk kumpulan data kecil atau menengah, yang membuatnya lebih baik daripada jaringan saraf tiruan dalam beberapa aspek.

Adapun penelitian terkait yang berhubungan dapat dilihat pada **Tabel II.1**

sebagai berikut :

Tabel II.1. Penelitian Terkait

No.	Peneliti	Judul	Algoritma	Hasil
1	(Mohamed et al. 2018)	<i>Enhanced Human Face Recognition Using LBPH Descriptor, Multi-KNN, and Back-Propagation Neural Network</i>	<i>Backpropagation neural network (BPNN)</i>	hasil dari metode yang kami usulkan dan perbandingannya dengan metode canggih yang ada. Tingkat akurasi mencapai 95,71%, yang sebanding dengan metode canggih, dan mencapai nilai tertinggi kedua akurasi tertinggi setelah itu di [60]. Namun, kesalahan standar kurang dari pada [60], yang menghasilkan akurasi keseluruhan yang lebih tinggi.
2	(Wachiraphong et al, 2022)	<i>An Improved Technique for Pneumonia Infected Patients Image Recognition Based on Combination Algorithm of Smooth Generalized Pinball SVM and Variational Autoencoders</i>	Support Vector Machine (SVM)	klasifikasi yang dilaporkan untuk aplikasi pneumonia berdasarkan klasifikasi biner RES-SGSVM yang diusulkan lebih tinggi yaitu akurasi pelatihan 93,34%, akurasi pengujian 93,53%, sensitivitas 90,08%, dan spesifisitas 94,71% untuk penggunaan ruang laten 32 dimensi dari VAE
3	(Chen et al. 2021)	Calculation of Gamma-Ray Exposure Buildup Factor Based on Backpropagation Neural Network	<i>Backpropagation neural network (BPNN)</i>	Hasil penelitian menunjukkan bahwa usulan TS-ACNN (VGG19) masing-masing dapat mencapai akurasi sebesar 88,1%, 92,4% dan 93,8% pada CUB-200-2011, Pesawat FGVC dan Mobil Stanford. TSACNN (Resnet152) masing-masing dapat mencapai akurasi 91,4%, 94,7%, dan 95,9% pada tiga kumpulan data.

No.	Peneliti	Judul	Algoritma	Hasil
				Akurasi keseluruhan pada tiga dataset adalah 91,4% untuk TS-ACNN (VGG19) dan 94,0% untuk TS-ACNN (Resnet152)
4	(Majeed Sadeq, Aziz Qadir, and Hassan Abbas 2023)	<i>Cars logo recognition by using of backpropagation neural networks</i>	<i>Backpropagation neural network (BPNN)</i>	Hasil uji coba menunjukkan bahwa program yang dibuat berhasil menguji tingkat akurasi logo (99,6%) dan kegagalan dalam hal logo yang salah (1,5% persen). Dan jumlah lapisan tersembunyi, neuron, dan loop (untuk) menentukan seberapa cepat proses berlangsung.
5	(Abuzneid. et al 2018)	<i>Detection of Collaterals from Cone-Beam CT Images in Stroke</i>	<i>cone-beam computed tomography, support vector machine (SVM); K-nearest neighbors (KNN)</i>	Perbaikan kualitas citra, dan ekstraksi karakteristik citra dengan hasil akurasi klasifikasi yang menjanjikan di atas 90% dan mampu mendeteksi pembuluh kolateral dan non-kolateral dari gambar
6	(Park and Suh 2022a)	<i>Continual Learning With Speculative Backpropagation and Activation History</i>	<i>Backpropagation neural network (BPNN)</i>	Evaluasi mengungkapkan keuntungan kinerja dari skema dalam hal akurasi dan waktu pelatihan. SB+AH meningkatkan akurasi tugas sebelumnya sebesar 30,2%, dibandingkan dengan pelatihan normal, untuk Permuted MNIST Mode.
7	(Sester et al. 2021)	<i>A comparative study of support vector machine and neural networks for file type identification using n-gram analysis</i>	<i>Support Vector Machine (SVM) dan Backpropagation neural network (BPNN)</i>	Pengembangan pendekatan berbasis n-gram, yaitu berkinerja lebih baik dengan skalabilitas atau menggeser biaya komputasi algoritme ke kebutuhan penggunaan memori.
8	(Vishwakarma, Paul, and Elsawah 2020)	<i>An algorithm for outlier detection in a</i>	<i>Backpropagation neural network (BPNN)</i>	Perbandingan dilakukan berdasarkan korelasi antara nilai prediksi dan aktual dan

No.	Peneliti	Judul	Algoritma	Hasil
		<i>time series model using backpropagation neural network</i>		SE dari kesalahan prediksi. Metode yang dibahas untuk mengidentifikasi outlier telah diterapkan pada proses ARMA serta deret waktu non-linear.
9	(Dong dkk. 2018)	<i>Investigation of Support Vector Machine and Back Propagation Artificial Neural Network for Performance Prediction of the Organic Rankine Cycle System.</i>	<i>Support Vector Machine (SVM)</i>	Kemampuan SVM dan BP-ANN untuk memprediksi kinerja sistem ORC telah dieksplorasi dan dianalisis. Metode penentuan parameter C dan telah terbukti praktis dan mampu memberikan SVM menggunakan RBF dan LF dengan akurasi yang mengesankan.
10	(Cervantes dkk. 2020)	<i>Lung cancer classification using feed forward back propagation neural network for CT images</i>	<i>forward back propagation, genetic algorithm</i>	Mekanisme pelatihan menggunakan 200 gambar kanker dan metode yang diusulkan menghasilkan akurasi klasifikasi sebesar 96% dan sensitivitas sebesar 94,7%. Makalah ini juga membahas modifikasi masa depan yang mungkin dilakukan dalam karya yang disajikan.

II.2 Citra Digital

Citra merupakan gambaran atau kemiripan dari suatu objek. Citra analog tidak dapat diproses secara komputerisasi, agar dapat diproses maka citra analog diubah menjadi citra digital. Citra digital adalah citra yang dapat diolah secara komputerisasi namun jika citra yang dihasilkan dari peralatan digital maka dapat langsung diolah oleh komputer (Rika Rosnelly et al. 2020).

Dalam teknik pengenalan gambar, terdapat beberapa pendekatan yang umum digunakan (Sugiartha, Sudarma, and Widhyantara 2016), antara lain:

1. Ekstraksi Fitur: Teknik ini melibatkan ekstraksi atribut-atribut visual yang relevan dari gambar. Contohnya termasuk ekstraksi tekstur, warna, bentuk, atau pola yang ada dalam gambar. Proses ini dilakukan untuk mengidentifikasi dan merepresentasikan informasi visual yang penting dalam bentuk fitur numerik yang dapat digunakan dalam proses klasifikasi atau pengenalan.
2. Pengklasifikasian: Setelah fitur-fitur diekstraksi, teknik pengklasifikasian digunakan untuk mengklasifikasikan gambar ke dalam kategori atau kelas yang telah ditentukan sebelumnya. Ini melibatkan penggunaan algoritma pembelajaran mesin, seperti *Support Vector Machine (SVM)*, *Random Forest*, atau *Deep Neural Network*, yang dilatih menggunakan data gambar berlabel untuk mengenali pola dan membedakan objek atau entitas dalam gambar.
3. Deteksi Objek: Teknik ini berfokus pada menemukan dan mengidentifikasi keberadaan objek tertentu dalam gambar. Deteksi objek dapat melibatkan teknik seperti deteksi wajah, deteksi kendaraan, atau deteksi objek umum lainnya. Hal ini sering dilakukan dengan menggunakan algoritma khusus, seperti Viola-Jones untuk deteksi wajah, yang mencari pola atau fitur tertentu dalam gambar untuk mengenali objek yang ditargetkan.

II.3 Preprocessing

Pada tahap *preprocessing* ini adalah mengubah citra *Red Green Blue (RGB)* menjadi citra keabuan. Yang bertujuan mempermudah dalam proses berikutnya. Dalam proses ini data uji atau citra diubah kedalam bentuk citra biner yang terdapat pada warna hitam dan putih (Rika Rosnelly et al. 2020). Dalam *processing* citra akan melalui beberapa tahapan.

II.3.1 Cropping

Cropping merupakan proses pemotongan bagian objek pada citra agar ukurannya lebih sederhana dan fokus pada objek yang diproses. Tujuannya untuk mengetahui bagian dari citra yang akan diproses pada tahap berikutnya.



Gambar 2.1 *image cropping*

II.3.2 Citra RGB ke Citra Keabuan

Pada citra berwarna sudah secara *default* pada kamera dan sudah menghasilkan gambar dengan ruang warna RGB. Setiap komponen warna RGB mengandung 8 bit dengan nilai berkisar antara 0-225. Biasanya nilai warna yang tertera adalah $255(\text{red}) \times 255(\text{green}) \times 255(\text{blue}) = 16.581.375$ warna. Contoh perhitungannya dapat dilihat pada persamaan 2.2.

$$\text{Keabuan} = 0.2989 * R + 0.5870 * G + 0.1141 * B \quad (2.1)$$

II.3.3 Median Filter

Median filtering adalah teknik peningkatan kualitas citra. Perhitungan *median filtering* akan menentukan nilai piksel *output*. Cara kerja median filtering yaitu dengan mengurutkan nilai intensitas piksel dari lingkungan matriks kemudian mencari nilai tengah. Pengurutan akan menghasilkan nilai terkecil hingga terbesar. Sehingga untuk menentukan nilai median melalui persamaan 2.2.

$$M = \left\lfloor \frac{(n+1)}{2} \right\rfloor \quad (2.2)$$

Dimana:

M = median

n = jumlah piksel dalam suatu matriks dan harus bernilai ganjil

II.3.4 Transformasi Citra Binner

Untuk melakukan perhitungan secara komputerisasi maka citra akan terlebih dahulu di transformasi untuk mendapatkan nilai binner yaitu putih dan abu dan dibutuhkan 1 bit dimemori tempat menyimpan kedua warna. Gradasi warna masing- masing adalah 0 untuk hitam dan 1 untuk putih. Perhitungan transformasi ditulis pada persamaan 2.3 dibawah ini:

$$T = \frac{f_{maks} + f_{min}}{2}$$

Dimana :

T= Nilai Tranformasi

(2.3)

Dimana :

T= Nilai Tranformasi

II.3.5 Deteksi Tepi *Sobel*

Metode *Sobel* merupakan pengembangan metode *robert* dengan menggunakan *High Pass Filter* (HPF) yang diberi satu angka nol penyangga. Metode *sobel* memiliki kemampuan untuk mengurangi *noise* sebelum dilakukan perhitungan deteksi tepi. Dalam deteksi tepi dibutuhkan perhitungan dengan mencari nilai gradien x dan y seperti pada persamaan 2.4 dan 2.5.

$$G_x = (Z_7 + 2Z_8 + Z_9) - (Z_1 + 2Z_2 + Z_3) \quad (2.4)$$

$$G_y = (Z_3 + 2Z_6 + Z_9) - (Z_1 + 2Z_4 + Z_7) \quad (2.5)$$

Keterangan:


Gx : perhitungan deteksi tepi menggunakan *kernel* horizontal

Gy : perhitungan deteksi tepi menggunakan *kernel* b=vertikal Setelah diketahui nilai Gx dan Gy kemudian menghitung nilai Gradien Gy dan Gx dengan persamaan 2.5.

$$\text{Gradien} = \sqrt{Gx^2 + Gy^2} \quad (2.6)$$

II.3.6 Area atau Luas


Area atau luas merupakan ukuran atau luas piksel pada suatu objek. Piksel yang dihitung merupakan jumlah piksel yang sudah diubah dalam bentuk citra biner yang terdapat intensitas warna 0 dan 1 sehingga digunakan intensitas 1 sebagai jumlah piksel objek (Rika Rosnelly et all). Sebagai ilustrasi sebagai berikut (Gambar II.3).



Gambar II.2. Hitung luas citra

II.3.7 Perimeter

Perimeter merupakan hasil deteksi keliling dari objek atau biasa disebut panjang tepi. Perhitungan keliling dilakukan dengan menghitung seluruh jumlah piksel seluruh objek yang berada pada bagian tepi (Rika Rosnelly et all). Contohnya seperti pada gambar II.4.



Gambar II.3. Objek dengan *perimeter*

Pada Gambar II.4 terdapat berwarna coklat pada beberapa pixel yang merupakan bagian dari *perimeter* sehingga pada gambar diketahui ada 15 jumlah *perimeter*.

II.3.8 Rectangularity

Merupakan ukuran persegi panjang terhadap objek dalam sebuah citra yang diperoleh dari *minimum bounding rectangle* (Ballard & Brown, 2017). Perhitungan dapat dilihat pada persamaan 2.7.

$$Rectangularity = \frac{A}{LW}$$

A : Luas dari objek
L : Panjang objek (*mayor axis*)
W : Lebar objek (*minor axis*)

(2.7)

II.3.9 Roundness

Dilakukan pengukuran dengan cara mengubah citra warna menjadi citra biner dengan tujuan untuk membedakan objek dengan latar belakang (Ballard & Brown, 2017). Kemudian citra dianalisis faktor bentuknya yang disebut *roundness*. Area objek dihitung dengan menjumlahkan piksel objek yang berwarna putih.

II.4 *Machine Learning*

II.3.1 Pengertian *Machine Learning*

Machine learning adalah salah satu cabang dari pembelajaran mesin (*machine learning*) yang menggunakan arsitektur jaringan saraf tiruan yang dalam (dalam arti memiliki banyak lapisan tersembunyi) untuk memproses dan mempelajari data dengan tingkat kompleksitas yang tinggi (Fletcher et al. 2021). Konsep utama dalam machine Learning adalah pembentukan hierarki representasi fitur yang semakin kompleks dan abstrak dari data yang diberikan.

Pada dasarnya, *Machine Learning* mencoba untuk meniru cara kerja otak manusia dalam memproses informasi. Dengan menggunakan jaringan saraf tiruan yang terdiri dari berbagai lapisan, *machine Learning* mampu mengidentifikasi dan memahami pola-pola yang tersembunyi dalam data secara otomatis, tanpa perlu adanya ekstraksi fitur manual. Hal ini memungkinkan machine Learning untuk berhasil dalam berbagai tugas yang kompleks seperti pengenalan gambar, pengenalan suara, pemrosesan bahasa alami, dan masih banyak lagi (Bijoy et al. 2023).

Salah satu keunggulan *machine Learning* adalah kemampuannya dalam mempelajari representasi fitur secara mandiri dari data yang diberikan, sehingga tidak memerlukan definisi fitur yang telah ditentukan terlebih dahulu. Dalam proses pembelajaran, machine Learning menggunakan metode propagasi mundur (*backpropagation*) untuk memperbarui bobot-bobot jaringan berdasarkan perbedaan antara *output* yang dihasilkan dengan target

yang diinginkan. Proses ini dilakukan secara iteratif untuk meningkatkan performa dan akurasi jaringan.


Machine Learning telah menunjukkan hasil yang sangat mengesankan dalam berbagai aplikasi, termasuk pengenalan objek dalam gambar, terjemahan mesin, pengenalan suara, dan pengenalan tulisan tangan. Kemampuannya dalam menangani data yang kompleks dan mempelajari representasi fitur secara mandiri menjadikannya alat yang kuat dalam memahami dan memproses informasi yang terkandung dalam data dengan tingkat kecerdasan yang semakin meningkat.

II.3.2 Arsitektur *Machine Learning*

Pada sub-bagian ini, akan dijelaskan beberapa arsitektur *Machine Learning* yang umum digunakan dalam pengenalan gambar, seperti *Convolutional Neural Network (CNN)* dan *Recurrent Neural Network (RNN)* (Abuzneid and Mahmood 2018). *CNN* digunakan secara khusus untuk pengenalan gambar karena kemampuannya dalam mengekstraksi fitur hierarkis dari data gambar. Sementara itu, *RNN* digunakan untuk pengenalan pola temporal dalam data berurutan.

II.5 Support Vector Machines (SVM)

Support Vector Machines (SVM) merupakan metode pembelajaran mesin yang banyak digemari untuk klasifikasi dan regresi. *Support Vector Machine* digunakan untuk membangun model yang dapat memisahkan dua kelas dengan memaksimalkan margin (jarak) antara data dari kelas yang berbeda.



Gambar II.4 SVM dengan maximum marginal hyperlane (MMH)

II.4.1 Cara kerja *Support Vector Machine* dapat dijelaskan sebagai berikut:

Pemilihan Kernel: Kernel adalah fungsi matematika yang digunakan untuk memetakan data ke dalam dimensi yang lebih tinggi. *Support Vector Machine* dapat menggunakan berbagai jenis kernel seperti *linear*, *polynomial*, *sigmoid*, dan *RBF* (*Radial Basis Function*). Pemilihan kernel yang tepat penting untuk mencapai pemisahan yang optimal antara kelas.


Pelatihan: *Support Vector Machine* mencari hyperplane (bidang pemisah) yang paling baik memisahkan dua kelas dengan memaksimalkan margin antara data dari kedua kelas tersebut. *Margin* adalah jarak terdekat antara *hyperplane* dan titik data terdekat dari masing-masing kelas, yang disebut vektor pendukung (*support vectors*). Proses pelatihan *Support Vector Machine* melibatkan penyesuaian parameter untuk menemukan hyperplane yang optimal.

Transformasi Data: Jika data tidak dapat dipisahkan secara linear, *Support Vector Machine* menggunakan teknik transformasi data dengan kernel untuk memetakan data ke dalam dimensi yang lebih tinggi. Dalam dimensi yang lebih tinggi, pemisahan linear mungkin menjadi mungkin.

Klasifikasi: Setelah melatih model *Support Vector Machine*, kita dapat mengklasifikasikan data baru dengan memproyeksikannya ke dalam ruang fitur yang sama dengan data pelatihan dan memprediksi kelas berdasarkan posisinya terhadap *hyperplane*.

II.6 Backpropagation Neural Network

"*Backpropagation Neural Network* adalah algoritma pembelajaran yang menggunakan aturan propagasi balik gradien untuk mengestimasi dan memperbarui bobot jaringan berdasarkan perbedaan antara output yang diharapkan dan output yang dihasilkan oleh jaringan. Algoritma ini menghitung gradien fungsi kesalahan terhadap bobot dengan memanfaatkan rantai aturan diferensiasi dan memperbarui bobot jaringan menggunakan aturan pembelajaran seperti *Stochastic Gradient Descent*." (Nielsen, 2015)



Gambar II.6 *Backpropagation of weights*

"*Image Classification using Machine Learning with Backpropagation Neural Network*" oleh Li et al. (2017): Penelitian ini menggambarkan penggunaan jaringan saraf dengan propagasi balik untuk klasifikasi gambar. Mereka membandingkan

performa berbagai arsitektur jaringan saraf, termasuk *Convolutional Neural Networks (CNN)*, dalam tugas pengenalan gambar. Hasilnya menunjukkan bahwa jaringan saraf dengan propagasi balik, terutama *CNN*, mampu mencapai tingkat akurasi yang tinggi dalam pengenalan gambar.

II.7 Fungsi Aktivasi

Fungsi aktivasi membantu dalam pelatihan agar menjadi lebih baik, proses pelatihan dan kemampuan generalisasi menjadi lebih baik. Fungsi aktivasi mengendalikan setiap unit didalam *layer* dengan bekerja pada bobot dan *bias*. Proses ini menggabungkan *nonlinear* dalam *output* dari setiap *neuron*. Bobot diupdate berdasarkan *error output*. Proses dari *backpropagation* mendukung fungsi aktivasi dengan memberikan *gradient* (Singh et al. 2023).

II.8 Python

Python adalah bahasa pemrograman tingkat tinggi yang didesain dengan fokus pada kemudahan pembacaan dan sintaksis yang jelas. Diciptakan oleh Guido van Rossum pada awal 1990-an, *Python* telah menjadi salah satu bahasa pemrograman yang sangat populer dan banyak digunakan di berbagai bidang, termasuk pengembangan perangkat lunak, analisis data, kecerdasan buatan, dan pengembangan web.

Karakteristik Utama Python:

1. Sintaksis yang Bersih dan Ekspresif: *Python* didesain untuk memiliki sintaksis yang mudah dipahami dan ditulis, memungkinkan pengembang untuk fokus pada logika program tanpa terganggu oleh kerumitan sintaksis.

2. Bahasa yang Dinamis: Python adalah bahasa yang dinamis, yang berarti variabel tidak perlu dideklarasikan secara eksplisit dan jenis data dapat berubah selama eksekusi program.
3. Interpretatif: Python diinterpretasikan oleh interpreter, sehingga pengembang dapat menjalankan kode secara langsung tanpa perlu mengkompilasi terlebih dahulu.
4. Multi-Paradigma: Python mendukung berbagai paradigma pemrograman, termasuk pemrograman berorientasi objek, pemrograman fungsional, dan pemrograman berbasis komponen.
5. Modularitas dan Pustaka Luas: Python menyediakan berbagai pustaka standar dan modul yang dapat digunakan untuk mempercepat pengembangan. Keberadaan pustaka-pustaka ini memungkinkan pengembang untuk mengatasi masalah umum tanpa perlu menulis ulang kode yang sama.
6. Portabilitas: Python dapat dijalankan di berbagai platform, termasuk Windows, macOS, dan Linux, membuatnya sangat portabel.
7. Dukungan Komunitas yang Kuat: Python memiliki komunitas pengembang yang besar dan aktif. Ini berarti bahwa pengembang Python dapat dengan mudah mengakses dukungan, tutorial, dan sumber daya online untuk membantu mereka dalam pengembangan perangkat lunak.
8. Open Source: Python bersifat open source, artinya kode sumbernya dapat diakses dan dimodifikasi oleh siapa saja. Hal ini mendorong kolaborasi dan inovasi di antara komunitas pengembang Python.

II. 9 Kontribusi Penelitian

Adapun kontribusi penelitian yang berjudul Analisis Performa Algoritma *Machine Learning* Pada Pengenalan Gambar Dengan Metode *Support Vector Machine* dan *Backpropagation Neural Network* ini adalah:

1. Memperoleh hasil kinerja metode *Support Vector Machine* dalam pengenalan gambar.
2. Memperoleh hasil kinerja metode *Backpropagation Neural Network* dalam pengenalan gambar.
3. Memperoleh hasil yang paling akurasi antara *Support Vector Machine* dengan *Backpropagation Neural Network*.

