

BAB II

TINJAUAN PUSTAKA

II.1 Penelitian Terkait

Beberapa penelitian sebelumnya yang membahas tentang Kendaraan diantaranya seperti penelitian yang dilakukan oleh :

Penelitian yang dilakukan oleh Peryanto et al., 2020 dengan judul “Rancang Bangun Klasifikasi Citra Dengan Teknologi *Deep Learning* Berbasis Metode *Convolutional Neural Network*” Penelitian ini menggunakan algoritma *Convolution Neural Network* ini berhasil mengimplementasikan metode CNN untuk pengklasifikasian citra menggunakan library keras dengan bahasa pemrograman python, dan didapatkan tingkat kecocokan/akurasi tertinggi sebesar 98,02% dan rata-rata akurasi tertinggi yaitu 97,56 %, serta akurasi sistem sebesar 96,64%. Sistem yang telah dibuat juga telah dapat memprediksi dengan prosentase yang sangat tinggi yaitu sebesar 91,10% (Ahmed & Wang, 2023). Selain itu dapat disimpulkan juga bahwa penambahan jumlah epoch menjadikan akurasi menjadi naik dan nilai prediksi menjadi lebih bagus, walaupun juga terdapat kekurangan pada saat proses training menjadi lebih lama dan berat untuk proses non GPU (CPU). Sedangkan untuk peningkatan ukuran data training untuk proses training tidak menyebabkan akurasi meningkat secara signifikan. Peningkatan akurasi hanya terjadi 0,0274 % sehingga tidak terlalu efektif. Pada saat proses train dilakukan menggunakan ukuran gambar yang lebih besar proses train menjadi sangat lama.

Penelitian yang dilakukan oleh Hudaya et al., 2020 dengan judul “Perancangan Sistem Pelacakan (Tracking) Dan Perhitungan Kendaraan Pada Citra Bergerak Menggunakan Metode *Convolutional Neural Network*” Pada pengujian performa tracking, nilai confidence yang didapatkan selama proses tracking selalu berubah tiap detik. Hal ini disebabkan karena posisi objek yang berubah terhadap kamera yang menyebabkan nilai confidence fluktuatif. Sementara pada pengujian proses perhitungan, pengujian menggunakan intersection antara objek yang dikenali dengan garis diperoleh tingkat akurasi sebesar 83.33%. Sedangkan pada pengujian perhitungan kendaraan menggunakan bounding box didapatkan tingkat akurasi sebesar 83.5%. Dari hasil penelitian ini, disarankan untuk menggunakan data latih dan iterasi pelatihan yang lebih banyak untuk mendapatkan tingkat akurasi yang lebih tinggi. Disamping itu penggunaan kamera serta jarak dan sudut perekaman citra serta proses anotasi citra yang optimal dapat meningkatkan akurasi. Model CNN yang digunakan terdiri dari empat lapisan konvolusi dengan ukuran filter 3×3 , fungsi aktivasi yang digunakan yaitu ReLU, dan 2 pooling layer dengan ukuran 2×2 . Citra yang digunakan untuk penelitian ini yaitu sebanyak 120 citra. Berdasarkan hasil pelatihan diperoleh tingkat akurasi dari model CNN yaitu sebesar 0.9444444 dengan loss 0.171811. Pada proses pengujian dihasilkan nilai loss yang masih cukup besar yaitu 0.9727243 dengan akurasi sebesar 0.7333333.

Penelitian yang dilakukan oleh Minematsu et al., 2022 dengan judul “Strategi deteksi dan penghitungan kendaraan berbasis CNN yang lebih cepat untuk pemandangan kamera tetap” Proses deteksi dilakukan pada frame pertama setiap frameset (N-frame). Kemudian, KLT tracker diadopsi dengan K-means clustering

untuk menyempurnakan dan mengelompokkan kendaraan yang terdeteksi melalui N-frame (Anggi Priliani Yulianto & Darwis, 2021). Akhirnya, menggabungkan cluster diperkenalkan untuk mengklasifikasikan kendaraan yang terdeteksi dengan cluster kendaraan yang sesuai. Eksperimen yang berbeda dilakukan untuk menyelidiki klasifikasi berbasis CNN piksel dan klasifikasi berbasis CNN regresi, termasuk R-CNN dan YOLOv2 yang lebih cepat untuk deteksi dan penghitungan kendaraan. Selain itu, kami menyelidiki algoritme saat pendeteksian hanya didasarkan pada algoritme YOLOv2 dibandingkan dengan keputusan pendeteksian berdasarkan YOLOv2 dengan informasi pelacakan (Nugroho et al., 2020). Metode yang diusulkan lebih cepat daripada pengurangan latar belakang dan deteksi berbasis R-CNN yang lebih cepat. Untuk mencapai hasil deteksi dan penghitungan yang baik menggunakan YOLOv2, gambar pelatihan harus menyertakan sampel pemandangan kendaraan yang berbeda seperti yang terlihat pada eksperimen III dan eksperimen II. Selain itu, telah disajikan bahwa informasi pelacakan meningkatkan akurasi Recall rata-rata sebesar 5,5% dan meningkatkan kinerja waktu rata-rata 93,3% untuk tujuh urutan yang berbeda (Anggi Priliani Yulianto & Darwis, 2021).

Penelitian yang dilakukan oleh Prykhodchenko & Skrush, 2022 dengan judul “Klasifikasi pemandangan jalan berdasarkan citra tingkat jalan dan data spasial” menunjukkan bahwa data spasial dapat digunakan bersama dengan pra-terlatih deep network dilatih sebelumnya pada dataset Places365 sebagai pendekatan semi-otomatis untuk melabeli tugas klasifikasi pemandangan jalan, alih-alih melakukan pelabelan secara manual. Sebagai dasar klasifikasi citra, kami

menggunakan residual neural jaringan dengan 50 lapisan dengan koneksi lewati untuk mendemonstrasikan akurasi 86% pada kumpulan data yang ditambah dan diperluas untuk klasifikasi pemandangan dengan tiga kelas. Berbagai faktor kontekstual harus diperhitungkan untuk prediksi ized dan percaya diri dari klasifikasi adegan jalan di mana gambar ini diambil. Faktor-faktor seperti cuaca, cahaya, geografis atau proses buatan manusia dapat memberikan pengaruh besar pada sistem persepsi berbasis penglihatan (Setiawan & Avianto, 2020). Mempertimbangkan semua faktor itu, direncanakan untuk bereksperimen dengan kumpulan data canggih lainnya di mana kondisi gambar mungkin berbeda dan lebih beragam. Arah lain yang menjanjikan adalah dengan menggunakan metode tanpa pengawasan untuk klasifikasi adegan berdasarkan teknik pengelompokan menggunakan fitur penyematan dari lapisan konvolusi. Kami percaya bahwa pelabelan kondisi pemandangan dapat digunakan untuk aplikasi online dan offline seperti pemetaan semantik dari kumpulan data otonom dan bantuan mengemudi.

Penelitian yang dilakukan oleh Zakiyamani et al., 2022 dengan judul “Deteksi Dan Pengenalan Plat Karakter Nomor Kendaraan Menggunakan OpenCV Dan Deep Learning Berbasis *Python*” Dari hasil penelitian deteksi dan pengenalan plat nomor kendaraan melalui proses mengekstrak plat nomor dari Citra kendaraan, segmentasi karakternya dan melatih model CNN untuk memprediksi karakter dari Citra telah berhasil. Dan dari hasil data latih model CNN didapatkan hasil akurasi mencapai 96% dengan tingkat kesalahan 11,78%. Adapun saran untuk penelitian selanjutnya yaitu memperhatikan : Perlunya dikembangkan penelitian lebih lanjut dengan metode deep learning lain, sehingga dapat dibandingkan hasil dari

metodenya. Posisi pengambilan, tingkat pencahayaan, kualitas dari citra sangat berpengaruh dalam akurasi sistem dalam mengenali karakter. Karena proses komputasi yang tinggi dalam melatih data diperlukan spesifikasi komputer yang tinggi agar dapat mencoba dengan tingkat kedalaman yang lebih baik.

Penelitian yang dilakukan oleh Nurolan, 2019 dengan judul “Deteksi Dan Klasifikasi Jenis Kendaraan Berbasis Pengolahan Citra Dengan Metode *Convolutional Neural Network* (Cnn)” Perancangan pada sistem ini menggunakan metode *Convolutional Neural Network* (CNN) sebagai pengolah data citra. Seluruh database penelitian menggunakan citra gambar sebagai data input dan data output yang di antara nya adalah Mobil MVP, Mini bus, Bus, dan Mobil pickup. Metode *Convolutional Neural Network* (CNN) akan menghasilkan nilai parameter training sebagai acuan dalam deteksi dan klasifikasi jenis kendaraan.. Seluruh database penelitian menggunakan 200 gambar dari jenis kendaraan, data tersebut merupakan data training dan data uji, di mana data training menggunakan 200 gambar yang terdiri dari 40 gambar (Minibus), 40 gambar (Bus), 40 gambar (Mobil MVP), 40 gambar (Pick Up), dan 40 gambar campuran dari (Minibus, Bus, Mobil MVP, dan Pick Up) dan data uji 25 gambar (Minibus, Bus, Mobil MVP, Pickup, dan gambar campuran). Pada penelitian ini menunjukkan rata-rata akurasi sebesar 81,94% pada seluruh pengujiannya dengan iterasi sebesar 10.000.

Penelitian yang dilakukan oleh Setiawan & Avianto, 2020 dengan judul “Implementasi *Convolutional Neural Network* Untuk Pengenalan Warna Kendaraan” nilai akurasi pada proses pengujian memiliki akurasi sebesar 76.94% dari 360 data gambar yang dijadikan input sebagai data pengujian. Nilai precision

adalah rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif, kelas warna kendaraan putih memiliki nilai yang paling tinggi, pada nilai recall adalah rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif. Dan nilai f1-score yang merupakan perbandingan rata-rata precision dan recall. Pengenalan kendaraan memainkan peranan penting dalam aplikasi Sistem Transportasi Cerdas, investigasi kriminal dan sebagainya di. Tugasnya adalah untuk mengenali jenis, warna dan plat nomor kendaraan yang ditargetkan. Warna adalah salah satu atribut dasar kendaraan, Oleh karena itu, pengenalan warna memainkan peran penting dalam pengenalan kendaraan. Cnn banyak digunakan dalam klasifikasi yang data masukannya berupa gambar, didalam penelitian ini digunakan metode cnn untuk klasifikasi warna kendaran. hasil yang diperoleh cukup baik menunjukkan akurasi sebesar 78.61 % pada proses training.

Tabel II. 1 Penelitian Terkait

Judul	Metode	Data	Hasil
Rancang Bangun Klasifikasi Citra Dengan Teknologi <i>Deep Learning</i> Berbasis Metode <i>Convolutional Neural Network</i>	<i>Deep Learning, Convolutional Neural Network (CNN), Image, Clasification</i>	Data traning 30 data atau 85% dan 5 atau 15% sebagai data Testing.	akurasi sistem sebesar 96,64%.
Perancangan Sistem Pelacakan (Tracking) Dan Perhitungan Kendaraan Pada Citra Bergerak	<i>Convolutional Neural Network(CNN), Yolo</i>	3282 data gambar yang terdiri dari 675 gambar bis, 1070 gambar mobil, 700 gambar sepeda motor, 700	tingkat akurasi sebesar 83.33%.

Menggunakan Metode <i>Convolutional Neural Network</i>		gambar truk, dan 137 gambar gabungan.	
Klasifikasi Jenis Kendaraan Menggunakan Metode <i>Convolutional Neural Network</i> (CNN)	<i>Convolutional Neural Network</i> (CNN)	90 citra sebagai data latih dan 30 citra sebagai data uji.	akurasi sebesar 0.7333333.
Klasifikasi pemandangan jalan berdasarkan citra tingkat jalan dan data spasial	<i>Convolutional Neural Network</i> (CNN)	Dataset 1779 gambar, di mana 1419 gambar milik kereta, dan 177 gambar yang sama.	mendemonstrasikan akurasi 86%.
Deteksi Dan Pengenalan Plat Karakter Nomor Kendaraan Menggunakan OpenCV Dan Deep Learning Berbasis <i>Python</i>	<i>Deep Learning, Convolutional Neural Network</i> (CNN)	data training dan data latih 90% dan 10% dengan tingkat kedalaman epoch 10.	akurasi mencapai 96%.
Deteksi Dan Klasifikasi Jenis Kendaraan Berbasis Pengolahan Citra Dengan Metode <i>Convolutional Neural Network</i> (Cnn)	<i>Convolutional Neural Network</i> (CNN) Deteksi Objek, Droupout Regularization, Jenis Kendaraan, Tensorflow.	200 gambar sebagai input database.	akurasi sebesar 81,94%
Implementasi <i>Convolutional Neural Network</i> Untuk Pengenalan Warna	<i>Convolutional Neural Network</i> (CNN) Transportasi, MLP, warna	2000 data gambar, 1600 data gambar untuk data training dan 400 data gambar	akurasi sebesar 76.94%

Kendaraan	kendaraan	sebagai data validation.	
-----------	-----------	--------------------------	--

II.2 Deep Learning

Deep Learning merupakan salah satu bidang dari *Machine Learning* yang memanfaatkan jaringan syaraf tiruan untuk implementasi permasalahan dengan dataset yang besar. Teknik *Deep Learning* memberikan arsitektur yang sangat kuat untuk *Supervised Learning*. Dengan menambahkan lebih banyak lapisan maka model pembelajaran tersebut bisa mewakili data citra berlabel dengan lebih baik. Pada *Machine Learning* terdapat teknik untuk menggunakan ekstraksi fitur dari data pelatihan dan algoritma pembelajaran khusus untuk mengklasifikasi citra maupun untuk mengenali suara. Namun, metode ini masih memiliki beberapa kekurangan baik dalam hal kecepatan dan akurasi (Coker et al., 2018). *Deep Learning* merupakan alat suatu bidang iranian *car eruditeness* yang memanfaatkan banyak bed pengolahan informasi yang bekerja nonlinier untuk dapat melakukan ekstraksi fitur, pengenalan pols dan klasifikasi. Menurut *goodfellow*, *deep learning* merupakan sebuah pendekatan dalam melakukan penyelesaian masalah pada sistem pembelajaran komputer dengan memakai konsep hierarki. Konsep hierarki ini mampu mempelajari konsep yang kompleks iranian penggabungan konsep-konsep yang lebih sederhana (Ahmed & Wang, 2023). Jika digambarkan dalam sebuah graf bagaimana konsep tersebut dibangun diatas konsep yang lain, maka graf ini akan dalam dengan banyak bed hal ini menjadi alasan mengapa disebut sebagai *deep learnin*. Aplikasi konsep jaringan syaraf tiruan yang dalam (banyak lapisan) dapat ditangguhkan pada algoritma


Machine Learning yang sudah ada sehingga komputer sekarang bisa belajar dengan kecepatan, akurasi, dan skala yang besar. Prinsip ini terus berkembang hingga *Deep Learning* semakin sering digunakan pada komunitas riset dan industri untuk membantu memecahkan banyak masalah data besar seperti *Computer vision*, *Speech recognition*, dan *Natural Language Processing*. (Eni, 1967).

II.3 Convolutional Neural Network (CNN)

Metode pengolahan data dua dimensi dalam bentuk citra menggunakan multilayer perceptron (MLP) dalam *Deep Neural Network* mengalami pengembangan menjadi *Convolution Neural Network* (CNN). Convolutional Neural Network adalah dengan memodifikasi perhitungan matematika untuk memproyeksikan gambar. Jika neural network biasa mengubah input melalui hidden layer, maka CNN bisa menggunakan komponen convolutional. metode MLP tetap digunakan dalam melakukan klasifikasi citra hanya saja dianggap memiliki kekurangan karena tidak dapat menyimpan informasi spasial dan menganggap bahwa setiap piksel yang ada dalam citra sebagai fitur yang independen sehingga mempengaruhi hasil yang di peroleh penemuan CNN ini pertama kali dilakukan oleh hubel dan wiesel (Agustien et al., 2021). Ada kesamaan struktur yang dimiliki CNN dengan *artificial neural network*. Pada klasifikasi citra, CNN mendapat masukan atau citra masukan untuk diproses dan diklasifikasi ke kategori tertentu. Perbedaan CNN dan ANN adalah pada arsitektur tambahan pada CNN yang dioptimisasi untuk fitur yang ada pada citra

masukan. Ada beberapa komponen utama yang ada dalam CNN yaitu diantaranya adalah:


1. *Convolution Layer*
2. *Pooling Layer*
3. *Fully Connected Layer*
4. *Dropout*



Gambar II.1 *Convolutional Neural Network (CNN)*

1. *Convolutional Layer*

Convolution layer adalah lapisan utama yang paling penting di metode CNN. Hasil dari *convolution layer* adalah citra baru yang menunjukkan fitur dari citra masukan. Setiap citra yang menjadi masukan, menggunakan filter *convolution layer* dalam proses tersebut. *Convolutional layer* terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (pixel). Sebagai contoh, *layer* pertama pada *feature extraction layer* adalah *convolutional layer* dengan ukuran 6x6x3. Panjang 6 pixel, tinggi 6 pixel, dan tebal/jumlah 3 buah sesuai dengan channel dari gambar tersebut. Ketiga filter ini akan digeser keseluruhan bagian dari gambar. Setiap pergeseran akan dilakukan operasi “dot” antara input dan nilai dari filter tersebut sehingga menghasilkan sebuah output atau biasa disebut sebagai activation map atau feature map.




Gambar II.2 Operasi Konvolusi

Kotak hijau secara keseluruhan adalah citra yang akan dilakukan konvolusi. Kernel bergerak dari sudut kiri atas ke kanan bawah. Sehingga hasil konvolusi dari citra tersebut dapat dilihat dari gambar di sebelah kanan. Tujuannya dilakukan konvolusi pada data citra yaitu untuk mengekstraksi fitur dari citra input. Konvolusi akan menghasilkan transformasi linear dari data input sesuai informasi spasial pada data. Bobot pada lapisan tersebut mengspesifikasi kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan input pada CNN.

2. Pooling Layer

Pooling layer adalah lapisan fungsi untuk *Feature Maps* sebagai masukan dan mengolahnya dengan berbagai operasi statistik nilai piksel terdekat. Pada model CNN, lapisan *pooling* biasanya disisipkan secara teratur setelah beberapa lapisan konvolusi. Lapisan *pooling* yang dimasukkan di antara lapisan konvolusi secara berturut-turut dalam susunan arsitektur model CNN dapat secara progresif mengurangi ukuran volume output pada *Feature Maps*, sehingga dapat mengurangi jumlah parameter dan perhitungan di jaringan, dan untuk mengendalikan *overfitting*. Hal penting dalam pembuatan model CNN adalah dengan memilih

banyak jenis lapisan *pooling* yang dalam hal ini dapat menguntungkan kinerja model. Lapisan *pooling* bekerja di setiap susunan *Feature Maps* dan mengurangi ukurannya. Bentuk lapisan *pooling* yang paling umum adalah dengan menggunakan filter berukuran 2x2 yang diaplikasikan dengan langkah sebanyak dua dan kemudian beroperasi pada setiap irisan dari input. Bentuk seperti ini akan mengurangi *Feature Maps* hingga 75% dari ukuran aslinya. Pada prinsipnya *pooling layer* terdiri dari sebuah filter dengan ukuran dan stride tertentu yang akan bergeser pada seluruh area *feature map*. *Pooling* yang biasa digunakan adalah *Max Pooling* dan *Average Pooling*. Sebagai contoh jika kita menggunakan *Max Pooling* 2x2 dengan stride dua, maka pada setiap pergeseran filter, nilai maximum pada area 2x2 pixel tersebut yang akan dipilih, sedangkan *Average Pooling* akan memilih nilai rata-ratanya. Tujuan dari penggunaan *pooling layer* adalah mengurangi dimensi dari *feature map* (downsampling), sehingga mempercepat komputasi karena parameter yang harus diupdate semakin sedikit dan mengatasi *overfitting*.




Gambar II.3 *Max Pooling*

3. *Fully Connected Layer*

Feature map yang dihasilkan dari *feature extraction* masih berbentuk multidimensional *array*, sehingga harus melakukan “*flatten*” atau *reshape feature map* menjadi sebuah *vector* agar bisa digunakan sebagai input dari *fully-connected*

layer. Lapisan *Fully-connected* adalah lapisan dimana semua neuron aktivitas dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan syaraf tiruan bisa. Setiap aktivitas dari lapisan sebelumnya perlu diubah menjadi data satu dimensi sebelum dapat dihubungkan ke semua neuron di lapisan *Fully-Connected*. Lapisan *Fully-Connected* biasanya digunakan pada metode Multi lapisan Perceptron dan bertujuan untuk mengolah data sehingga bisa diklasifikasikan. Perbedaan antar lapisan *Fully-Connected* dan lapisan konvolusi biasa adalah neuron di lapisan konvolusi terhubung hanya ke daerah tertentu pada input. Sementara lapisan *FullyConnected* memiliki neuron yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoprasikan produk dot, sehingga fungsinya tidak begitu berbeda.




Gambar II.4 *Fully Connected Layer*

4. Dropout

Dropout adalah teknik regularisasi jaringan syaraf dimana beberapa neuron akan dipilih secara acak dan tidak dipakai selama pelatihan. Neuron-neuron ini dapat dibuang secara acak. Hal ini berarti bahwa kontribusi neuron yang dibuang akan diberhentikan sementara jaringan dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan *backpropagation*. *Dropout*

merupakan proses mencegah terjadinya *overfitting* dan juga mempercepat proses learning. *Dropout* mengacu kepada menghilangkan neuron yang berupa *hidden* maupun *layer* yang *visible* didalam jaringan. Dengan menghilangkan suatu neuron, berarti menghilangkannya sementara dari jaringan yang ada. Neuron yang akan dihilangkan akan dipilih secara acak. Setiap neuron akan diberikan probabilitas yang bernilai antara nol dan satu.



Gambar II.5 Contoh Implementasi *Dropout*

jaringan syaraf (a) merupakan jaringan syaraf biasa dengan dua lapisan tersembunyi. Sedangkan pada bagian (b) jaringan syaraf sudah diaplikasikan teknik regularisasi dropout dimana ada beberapa neuron aktivasi yang tidak dipakai lagi. Teknik ini sangat mudah diimplementasikan pada model CNN dan akan berdampak pada performa model dalam melatih serta mengurangi overfitting (Hudaya et al., 2020).

Strategi *deep Learning* lebih khusus lagi *Convolutional Neural Networks* (CNN) telah manunjukkan kemajuan signifikan dibandingkan pendekatan tradisional dalam banyak tugas visi komputer, termasuk deteksi klasifikasi objek. Deteksi dan pelacakan kendaraan biasanya dilakukan sebagai dua prosedur terpisah. Deteksi kendaraan mengandalkan fitur tampilan spasial serta gerak temporal. Teknik pendeteksian kendaraan yang berfokus pada karakteristik visual

dan tampilan domain spasial kendaraan sudah mulai jenuh. Berbagai metode telah telah diperkenalkan dalam literatur untuk mengatasi masalah deteksi dan perhitungan kendaraan dalam gambar dan video. Namun karena perubahan bentuk, skala, tampilan objek, bayangan, kondisi pencahayaan dan oklusi parsial (Zerizghy et al., 2009).

II.4 Image Processing

Image processing atau pengolahan citra merupakan suatu metode atau teknik yang dapat digunakan untuk memproses citra atau gambar dengan jalan memanipulasinya menjadi suatu data gambar yang diisikan untuk mendapatkan suatu informasi tertentu mengenai obyek yang sedang diamati (Putri, 2016).

II.5 Citra

Citra yang dimaksud adalah foto maupun gambaran bergerak sedangkan digital disini mempunyai maksud bahwa pengolahan citra/gambar dilakukan secara digital menggunakan komputer. Citra adalah gambaran yang terekam oleh sebuah kamera atau oleh sensor. Mengutarakan pengertian tentang citrayaitu:

1. Gambaran obyek yang dibuahkan olehsuatupantulan atau pembiasan sinar yang difokuskan padasebuah lensa atau sebuah cermin.
2. Gambaran rekaman suatu obyek (biasanya berupa gambaran pada foto) yang dibuat dengan cara optik, elektro-optik, optikmekanik atau elektronik. Pada umumnya gambar digunakan bila radiasi elektromagnetik yang dipancarkan atau dipantulkan dari suatu obyek tidak langsung direkam pada sebuah film. Sedangkan penginderaan jauh ialah ilmu dan seni untuk memperolehsebuahinformasi tentang obyek, daerah, dan gejala dengan jalan

menganalisis data yang diperoleh dengan menggunakan suatu alat tanpa kontak langsung terhadap obyek, daerah, atau gejala yang dikaji (Denta Sukma & Mukhaiyar, 2022)

II.5.1 Jenis-jenis Citra

Menurut seorang frank jefkins dalamseomirat dan elvinaro memilah citra dalam beberapa jenis, antara lain :

- a) *The mirror image* (cerminan citra), yaitu bagaimana taksiran (citra) manajemen terhadap public eksternal dalam melihat perusahaannya.
- b) *The current image* (citra masih hangat), yaitu citra yang terdapat pada publik eksternal, yang berdasarkan pengalaman atau menyangkut miskinnya informasi dan pemahaman publik eksternal. Citra ini bisa saja berbenturan dengan miror image.
- c) *The wish image* (citra yang diinginkan), yaitu manajemen mengharapakan perolehan prestasi tertentu. Citra ini diaplikasikan untuk sesuatu yang baru sebelum dipublikasikan secara eksternal untuk memperoleh informasi secara lengkap.
- d) *The multiple image* (citra yang berlapis), ialah sekelompok individu, kantor cabang atau perwakilan perusahaan lainnya dapat membentuk citra yang belum sesuai dengan kesamaan citra seluruh organisasi atau perusahaan.

II.6 Pengolahan Citra

Pengolahan citra digital merupakan salah satu ilmu pengetahuan yang mempelajari proses terbuatnya citra, pada prosesnya dilakukan sebuah analisa,

proses pengolahan dan analisa yang kemudian didapatkan hasil sebuah informasi yang bisa dipahami oleh manusia. Dalam pengolahan citra terdapat dua jenis yang bisa disebut dengan citra digital dan citra analog. Khusus dalam penelitian ini penulis akan menguraikan jenis citra digital yang sesuai dengan sistem yang akan dibuat. Citra digital merupakan bentuk representasi dari fungsi intensitas suatu cahaya yang diolah dalam bentuk diskrit pada bidang dua dimensi. Citra dapat berupa gambar, video atau sesuatu yang sifatnya digital dan dapat dimasukkan dalam memori penyimpanan. Setiap citra dapat diperoleh dengan cara akuisisi citra yaitu dengan proses yang dilakukan untuk mendapat suatu citra. Citra adalah representasi dua dimensi untuk bentuk-bentuk fisik nyata tiga dimensi. Citra dalam perwujudan dapat bermacam-macam, mulai dari gambar perwujudan nya dapat bermacam –macam, mulai dari gambar putih pada sebuah foto (yang tidak bergerak) sampai pada gambar warna yang bergerak pada televisi. proses transformasi dari bentuk tiga dimensi ke bentuk dua dimensi untuk menghasilkan citra akan dipengaruhi oleh bermacam-macam factor yang mengakibatkan citra penampilan citra suatu benda tidak sama persis dengan bentuk fisik nyatanya .faktor-faktor tersebut merupakan efek degradasi atau penurunan kualitas yang dapat berupa rentang kontras benda yang terlalu sempit atau terlalu lebar ,distorsi geometric kekaburan (blur), kekaburan akibat objek citra yang bergerak 9 motion blur, noisw atau gangguan yang disebabkan oleh interferensi pembuat citra ,baik itu pembuat tranduser ,peralatan elektronik maupun peralatan optik. karena pengolahan citra digital dilakukan dengan computer digital ,maka citra yang akan diolah terlebih dahulu ditranformasikan

kedalam bentuk besaran – besaran diskrit dari nilai tingkat keabuan pada titik element citra .bentuk dari citra ini disebut citra digital. element-element citra digital apabila ditampilkan dalam layar monitor akan menempati sebuah ruang yang disebut Pixel (*picture element*).

II.7 Teknik Pengolahan Citra

Ada beberapa teknik dalam pengolahan citra yaitu sebagai berikut :

a. Image Enhancement

Suatu proses perbaikan citra dengan cara meningkatkan kualitas citra, baik kontras maupun kecerahan.

b. Image Restoration

Suatu proses memperbaiki model citra, senga menjadi bentuk citra yang sesuai.

c. Color Image Procesing

Suatu proses yang dikaitkan sengan citra warna, baik itu berupa image enhancement, image restoration ataupun yang lainnya.

d. Wavelet dan multiresolution Processing

Suatu Proses citra yang menyatakan dalam resolusi

e. Image Compression

Suatu proses yang dilakukan untuk mengubah ukuran data dalam suatu citra

f. Morphological Procesing

Proses untuk mendapatkan sebuah informasi yang menyatakan deskripsi suatu bentuk dari sebuah citra.

g. Segmentation

Proses untuk membedakan atau memisahkan objek-objek didalam suatu citra, seperti memisahkan objek dengan background

h. Object Recognition

Proses yang dilakukan untuk mengenali suatu objek apa saja yang ada didalam suatu citra.

II.8 Support Vector Machine (SVM)

Support Vector Machines (SVM) adalah metode pada machine learning yang dapat digunakan untuk menganalisis data dan mengurutkannya ke dalam salah satu dari dua kategori. metode pembelajaran terbimbing yang menganalisis data dan mengenali pola, digunakan untuk klasifikasi dan analisis regresi. Metode ini dikembangkan oleh Boser, Guyon, Vapnik, dan pertama kali dipresentasikan pada tahun 1992 di Annual Workshop on Computational Learning Theory. *SVM* termasuk klasifikasi yang memberi aturan untuk mengubah dokumen teks menjadi vector sebelum diklasifikasi. Biasanya teks dokumen diubah menjadi vector multidimensional tf-idf. (Buntoro, 2017)

Konsep SVM mencari hyperplane terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space*. *Pattern* yang merupakan anggota dari dua buah kelas: +1 dan -1 dan berbagi alternative garis pemisah (*discrimination boundaries*). *Margin* adalah jarak antara hyperplane tersebut dengan pattern terdekat dari masing-masing kelas. *Pattern* yang paling dekat ini disebut sebagai *support vector*. Usaha untuk mencari lokasi hyperplane ini merupakan inti dari proses pembelajaran pada SVM. Secara intuitif, model SVM merupakan representasi dari data sebagai titik dalam ruang, dipetakan sehingga kategori

contoh terpisah dibagi oleh celah jelas yang selebar mungkin. Data baru kemudian dipetakan ke dalam ruang yang sama dan diperkirakan termasuk kategori berdasarkan sisi mana dari celah data tersebut berada. (Adijaya, 2020).

SVM bekerja atas prinsip *Structural Risk Minimization (SRM)* dengan tujuan menemukan *hyperlane* terbaik yang memisahkan dua buah kelas pada input *space*. Prinsip dasar SVM adalah klasifikasikan linear. Pada SVM pemisahan yang baik dicapai oleh *hyperplane* yang memiliki jarak terbesar ke titik data *training* terdekat dari setiap kelas (margin fungsional disebut), karena pada umumnya semakin besar margin semakin rendah *error* generalisasi dari pemilah. Misalkan terdapat m data training $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ adalah sampel data dan $y_1 \in \{1, -1\}$ adalah target atau kelas dari sampel data. Misalkan juga bahwa data untuk kedua kelas terpisah maka ingin dicari fungsi pemisah (*hyperplane*) (Wu & Kumar, 2009).

$$f(x) = xw + b \quad (2.1)$$

di mana w adalah parameter bobot dan b adalah parameter bias.

Pattern $\vec{x}_i$ yang termasuk kelas +1 (sampel positif) dapat dirumuskan sebagai pattern yang memenuhi pertidaksamaan

$$x_i w + b > 0 \text{ untuk } y_i = 1 \quad (2.2)$$

Pattern $\vec{x}_i$ yang termasuk kelas -1 (sampel negatif) dapat dirumuskan sebagai pattern yang memenuhi pertidaksamaan

$$x_i w + b < 0 \text{ untuk } y_i = -1 \quad (2.3)$$

Masalah mencari parameter w dan b yang optimal agar diperoleh *hyperplane* yang optimal merupakan *quadratic programming*.

$$\min_{w,b} \frac{1}{2} w^T w + C \sum_{i=1}^m \mu_i \quad (2.4)$$

Masalah ini dapat dipecahkan dengan berbagai teknik komputasi, diantaranya dengan *Lagrange Multiplier*.

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \overline{x_i x_j} \quad (2.5)$$

α_i adalah *Lagrange multipliers*, yang bernilai nol atau positif ($\alpha_i \geq 0$). Dari hasil perhitungan ini diperoleh α_i yang kebanyakan bernilai positif. Data yang berkorelasi dengan α_i yang positif inilah yang disebut sebagai *Support Vector Machine*. SVM pada prinsipnya adalah klasifikasi linear. Tetapi SVM memiliki keunggulan dalam klasifikasi untuk problem non-linier. Pada prosesnya data diproyeksikan ke ruang vektor baru, sering disebut *feature space*, berdimensi lebih tinggi sedemikian hingga data itu dapat terpisah secara linier. Selanjutnya, di ruang baru, SVM mencari *hyperplane* optimal yaitu bekerja sebagai klasifier linear. Dapat diasumsikan bahwa kedua belah kelas dapat terpisah secara sempurna oleh *hyperplane* (*linear separable*). Akan tetapi, pada umumnya dua belah kelas pada *input space* tidak dapat terpisah secara sempurna (*non linear separable*). Untuk mengatasi masalah ini, SVM dirumuskan ulang dengan memperkenalkan metode *Margin Soft*. Cortes et al. (1995) menyarankan ide margin maksimal dimodifikasi yang memungkinkan untuk contoh *mislabeled*. Jika terdapat *hyperplane* yang dapat memecah contoh "ya" dan "tidak", metode

Margin Soft akan memilih hyperplane yang membagi contoh-contoh sebersih mungkin. Metode ini memperkenalkan variabel slack ξ_i ($\xi_i \geq 0$), yang mengukur tingkat kesalahan klasifikasi.

$$y_i(< \vec{w} \cdot \vec{x}_i > + b) \geq 1 - \xi_i \quad (i = 1, 2, \dots, l) \quad (2.5)$$

Sedangkan objective function (2.5) yang dioptimalkan menjadi.

$$\text{minimize } \frac{1}{2} ||\vec{w}||^2 + C \sum_{i=1}^l \xi_i \quad (2.6)$$

C merupakan parameter yang mengontrol *trade-off* antara margin dan error klasifikasi ξ . Semakin besar nilai C , berarti nilai akhir terhadap kesalahan menjadi semakin besar, sehingga proses training menjadi lebih ketat. Parameter C ditentukan dengan mencoba beberapa nilai dan dievaluasi efeknya terhadap akurasi yang dicapai oleh SVM. (Norwawi, 2020)