

BAB 2

DASAR TEORI

2.1 KAJIAN PUSTAKA

Dasar penulisan laporan skripsi mengambil dari penelitian yang dilakukan oleh Dongkyu 'Roy' Lee, Woong Gyu La, dan Hwangnam Kim dari School of Electrical Engineering, Korea University pada tahun 2018 dengan judul ***“Drone Detection and Identification System using Artificial Intelligence”***. Penelitian tersebut author membangun sistem deteksi drones berbasis *Machine Learning* dengan menggunakan metode *Haar Cascade Classification* untuk deteksi objek drone kemudian algoritma klasifikasi menggunakan *Convolutional Neural Network* (CNN). Dataset citra yang digunakan adalah 2088 untuk kelas *positive* dan 3019 kelas *negative*. Pada proses deteksi drone menggunakan *Haar Cascade*, dataset yang digunakan yaitu data citra sebanyak 2088 kelas *positive* dan menggunakan 829 data citra sebagai data *testing* untuk menguji performa sistem deteksi. Hasil yang diperoleh adalah sistem deteksi dapat mendeteksi objek kelas *positive* dengan akurasi rata-rata yang dicapai adalah 0,89 atau 89%. Sedangkan pada proses *identifier*, sebanyak 2088 data kelas *positive* dibagi menjadi 2 kelompok data yaitu 1777 gambar digunakan untuk pelatihan, dan 429 digunakan sebagai uji evaluasi model. Hasil yang diperoleh pelatihan model menunjukkan akurasi maksimum 91,6 persen. Dari penelitian ini, author membuktikan bahwa CNN sangat efisien untuk mengklasifikasikan drone untuk teknologi *Anti-Drone* [1].

Penelitian yang dilakukan oleh Bowon Yang, Eric T. Matson, dan Anthony H. Smith dari *Computer and Information Technology, Purdue University* di tahun 2019 yang berjudul ***“UAV Detection System with Multiple Acoustic Nodes Using Machine Learning Models”***. Pada penelitian ini author membuat sistem deteksi UAV berdasar sinyal akustik/suara menggunakan beberapa perangkat Raspberry Pi yang bertindak sebagai node sensor dan sebuah *control center*. Sistem yang dibangun memiliki cara kerja menjadikan node sensor sebagai pendeteksi suara yang dipasang di sekeliling zona yang dilindungi, data akustik yang dihasilkan dari deteksi sensor akan dikirimkan ke *control center* secara nirkabel untuk diolah dan kemudian diklasifikasikan. Transmisi data menggunakan fasilitas *Wide Area*

Network dan *WebSocket* sebagai antarmuka dengan pengguna untuk memantau hasil deteksi. Penelitian dilakukan dengan beberapa tahapan yaitu pengumpulan data, ekstraksi fitur, membangun Model Machine Learning, *training* dan *testing*. Pengambilan data dilakukan dengan beberapa skema antara lain pengambilan data pada cuaca cerah dan berangin, kemudian UAV diterbangkan pada ketinggian 0 – 10 meter dengan jarak radius adalah >20 meter dari node sensor. Kelas yang digunakan adalah “positif” yaitu pada saat suara UAV terdeteksi walaupun terdapat noise dan “negatif” pada saat tidak ada suara UAV terdeteksi atau hanya suara lingkungan. Skema ekstraksi fitur yang digunakan adalah *Short-Time Fourier Transform* (STFT) dan *Mel-Frequency Cepstrum Coefficient* (MFCC). Sedangkan Model machine learning yang digunakan adalah *Support Vector Machine* (SVM) dan *Convolutional Neural Network* (CNN). Hasil *training* dengan model machine learning SVM diperoleh *F1-Score* untuk ekstraksi fitur MFCC adalah 0.779 dan *F1-Score* untuk ekstraksi fitur STFT adalah 0.787 . Sedangkan hasil *testing* terbaik adalah menggunakan metode SVM dengan ekstraksi fitur STFT. Penelitian ini masih memiliki beberapa kekurangan diantaranya dataset yang digunakan masih terdapat derau, kualitas audio yang buruk dan belum diterapkan normalisasi [2].

Pada penelitian yang dilakukan oleh Sonain Jamil, Fawad, MuhibUr Rahman, Amin Ullah, Salman Badnava, Masoud Forsat dan Seyed Sajad Mirjavadi tahun 2020 dengan judul “***Malicious UAV Detection Using Integrated Audio and Visual Features for Public Safety Applications***” author menyatakan bahwa UAV memiliki sinyal suara yang khas, berbeda dengan suara lain pada lingkungan terbuka. Pada penelitian tersebut author membandingkan beberapa metode deteksi UAV yaitu deteksi citra/gambar dan deteksi audio. Langkah penelitian yang dilakukan author pertama adalah melakukan pengumpulan data suara dan gambar dari suatu *stasiun control* menggunakan beberapa sensor. Author memperoleh 506 data gambar dan 217 data suara. Langkah kedua yaitu author melakukan ekstraksi fitur data suara menggunakan *Descriptor* MFCC dan *Descriptor Histogram* (HOG) sebagai ekstraksi fitur untuk data gambar. Langkah ketiga adalah *split data* untuk data gambar dibagi menjadi 350 (70%) data latih dan 156 (30%) data tes, sedangkan data audio dibagi menjadi 157 (70%) data latih dan 60 (30%) data tes. Langkah keempat adalah membangun model pembelajaran dua algoritma klasifikasi yaitu

Support Vector Machine (SVM) dan *Convolutional Neural Network*. Dari Langkah penelitian yang sudah dilakukan, author memperoleh hasil akurasi untuk tiap algoritma klasifikasi. Pada klasifikasi data gambar metode SVM, akurasi yang dihasilkan untuk data gambar tertinggi adalah 82,7% saat kernel *Linear*. Dibandingkan dengan metode CNN, akurasi tertinggi yang diperoleh mencapai 97,4% saat menggunakan arsitektur AlexNet dengan kernel *Linear* dan *Polynomial*. Sedangkan pada klasifikasi audio menggunakan SVM, akurasi tertinggi dicapai adalah 98,3% saat menggunakan kernel Gaussian.

Pada penelitian ini penulis akan menggunakan metode MFCC untuk ekstraksi fitur audio dan CNN sebagai klasifikasi data citra karena pada penelitian yang dilakukan oleh Sonain Jamil dkk yang berjudul “*Malicious UAV Detection Using Integrated Audio and Visual Features for Public Safety Applications*” yang mana dengan menggunakan metode MFCC dan CNN sebagai metode untuk klasifikasi drone mampu menghasilkan tingkat akurasi yang tinggi ya itu di atas 95% [3].

2.2 DASAR TEORI

2.2.1 *Unmanned Aerial Vehicle (UAV)*

UAV awalnya digunakan untuk aplikasi militer untuk pengawasan, memantau aktivitas musuh, mengumpulkan informasi bahkan menyerang sasaran militer. Namun saat ini UAV juga dapat dimanfaatkan sebagai dalam beberapa kegiatan seperti kepolisian, pemadam kebakaran, inspeksi saluran listrik dan pipa gas hingga tim penyelamat SAR. Selain itu, UAV digunakan dalam aplikasi komersial seperti pertanian, penelitian, jalan raya, hingga pengiriman logistik ke lokasi yang sulit dijangkau.

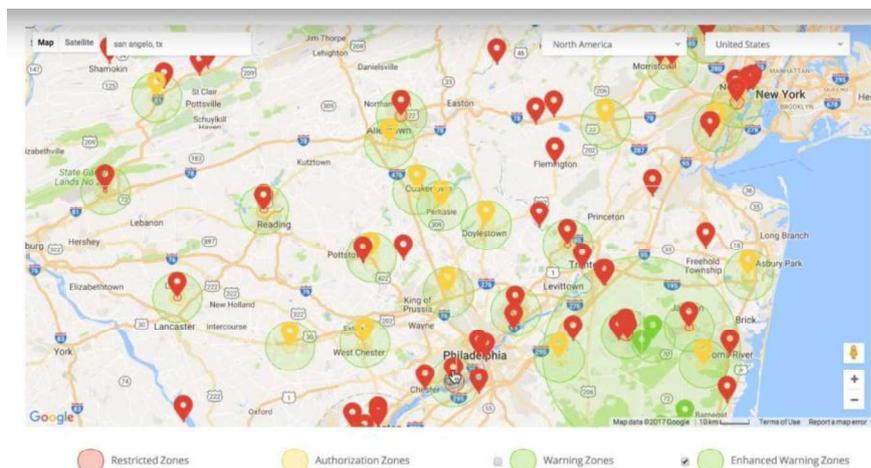
Saat ini teknologi UAV dirancang untuk memiliki daya tahan yang tinggi, mampu melakukan penerbangan secara otomatis hingga melakukan transmisi pesan. UAV modern terus dikembangkan sehingga dapat menghasilkan teknologi terbaik seperti desain aerodinamika, material, sistem kontrol, komputasi dan jaringan yang merupakan hasil inovasi oleh berbagai bidang seperti aerodinamika, telekomunikasi, kecerdasan buatan, dll [4].



Gambar 2.1 Unmanned Aerial Vehicle (UAV) [5]

2.2.2 Teknologi *Anti-Drone*

Meningkatnya penggunaan drone menimbulkan ancaman besar bagi keamanan publik dan pribadi. Misalnya, pengguna drone mungkin mengikat bahan peledak atau bahan berbahaya lainnya ke drone untuk melakukan serangan, menggunakan drone untuk menyelundupkan bahan-bahan terlarang, atau mengintai informasi pribadi seseorang. Berdasarkan pernyataan tersebut, maka perlu adanya pengaturan mengenai penggunaan drone seperti batas ketinggian, waktu terbang hingga batas kecepatan. Beberapa produsen drone telah menyematkan teknologi *geofencing* ke dalam drone untuk mencegah penggunaan drone untuk terbang di atas area sensitif keamanan (gedung pemerintah, bandara, dll.). Namun teknologi *geofencing* tidak memungkinkan untuk menutupi setiap tempat dan setiap drone.



Gambar 2.2 Peta *GeoFencing* [6]

Oleh karena itu, sangat penting untuk menerapkan sistem *anti-drone* di area yang bebas *geofencing* namun sensitif terhadap keamanan. Sistem *anti-drone* dirancang untuk mampu mendeteksi drone pada saat terbang ke area terlarang dan

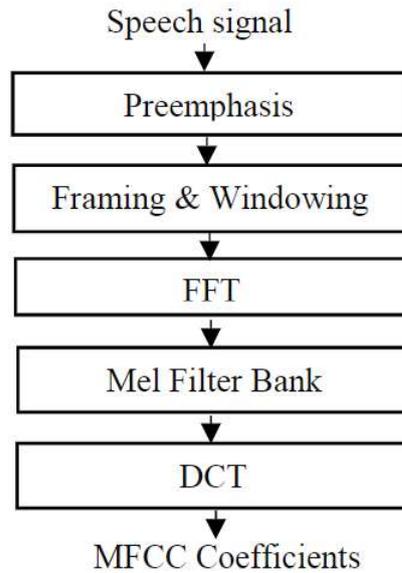
memperkirakan lokasinya untuk pertahanan drone (misalnya jamming, *drone catcher*, atau mengontrol drone yang terdeteksi). Namun, karena drone tersebut memiliki ukuran yang kecil dan kecepatan terbang rendah di ketinggian rendah merupakan tantangan bagi pengembang teknologi deteksi drone. Saat ini teknologi *anti-drone* menggunakan beberapa jenis deteksi seperti radar, audio, video, dan *radio frequency*. Setiap teknologi memiliki kelebihan dan kekurangan masing-masing. Beberapa sistem *anti-drone* telah dikembangkan berdasarkan satu atau beberapa teknologi tersebut. Kinerja sistem dan skenario penerapannya juga tergantung dengan teknologi yang digunakan dan tidak semua jenis deteksi yang apabila diaplikasikan secara bersamaan dapat mewujudkan deteksi, lokalisasi, dan pertahanan drone [7].



Gambar 2.3 Radar Anti-Drone [8]

2.2.3 Mel-Frequency Cepstrum Coefficient (MFCC)

MFCC merupakan teknik ekstraksi fitur suara yang sering digunakan untuk *speech recognition* berbasis sinyal domain frekuensi menggunakan *Mel Scale* yang merepresentasikan telinga manusia. Teknik MFCC menggunakan teknik ekstrak parameter dari sinyal suara, mirip dengan pendengaran manusia.



Gambar 2.4 Proses Ekstraksi Fitur MFCC [9]

Dari gambar di atas, proses yang terjadi pada MFCC yaitu sinyal audio dilakukan *Preemphasis*, yaitu meningkatkan jumlah energi suara berfrekuensi tinggi dengan menerapkan rumus:

$$x'(t) = x(t) - \alpha x(t - 1) \quad (2.1)$$

Dengan $x(t)$ adalah masukan sinyal suara dan α bernilai diantara 0.9 sampai 1.0.

Kemudian hasil *Preemphasis* dibagi menjadi beberapa frame waktu (*Framming*), kemudian dilakukan *windowing* untuk menghilangkan diskontinuitas. Dalam proses *framing*, sinyal dibagi menjadi bagian yang lebih pendek. Panjang sinyal yang dibagi adalah sekitar 20-40 ms, dengan pergeseran *framing* sebesar 10ms. Proses *windowing* yang digunakan adalah *Hamming Windowing* terhadap sinyal yang sudah dilakukan *framing*.

Setelah proses *windowing*, setiap frame diubah menjadi domain frekuensi menggunakan *Fast Fourier Transform* (FFT). Selanjutnya adalah mengaplikasikan perhitungan logaritma *Mel-Scale filter bank*. MFCC menggunakan *Mel-Scale filter bank* pada saat frekuensi filter batas atas memiliki bandwidth yang lebih tinggi daripada frekuensi filter batas bawah, namun memiliki resolusi yang sama. Untuk memperoleh *mel-scale* dapat menggunakan rumus di bawah.

$$mel(f) = 2595 \log_{10}\left(1 + \frac{f}{700}\right) \quad (2.2)$$

Proses terakhir adalah mengubah output filter menggunakan *Discrete Cosine Transform* dengan menerapkan rumus sebagai berikut.

$$C_m = \sum_{k=1}^N \log(mel_k) \cos\left[m\left(k - 0.5\right) \frac{\pi}{N}\right] \quad (2.3)$$

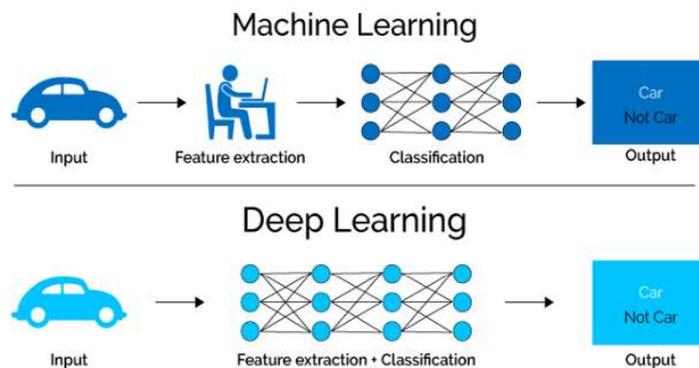
Dimana MFCC dinotasikan sebagai C_m dan m merepresentasikan fitur *coefficient* yang diekstrak sedangkan N merupakan jumlah mel filter.

Setiap frame audio, set koefisien dari MFCC dikomputasi dimana setiap set disebut dengan *acoustic vector* yang merepresentasikan karakteristik audio. Hasil vektor tersebut sangat berguna untuk kepentingan analisis maupun pemrosesan suara dalam *Speech Recognition* [9].

2.2.4 Neural Network

Machine Learning merupakan algoritma yang digunakan untuk mempelajari suatu kejadian atau masalah. Kejadian atau masalah yang dimaksud antara lain klasifikasi, prediksi dan *clustering*. Pada penelitian ini difokuskan pada masalah klasifikasi UAV dan benda terbang lain.

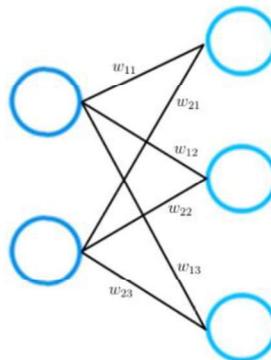
Perbedaan *Machine Learning* dengan *Deep Learning* adalah terletak pada arsitekturnya. Pada *Machine Learning* algoritma ekstraksi fitur dibangun secara terpisah dengan model pembelajarannya. Sedangkan *Deep Learning* merupakan arsitektur yang terdiri ekstraksi fitur dan model pembelajaran.



Gambar 2.5 Perbandingan Machine Learning dan Deep Learning [10]

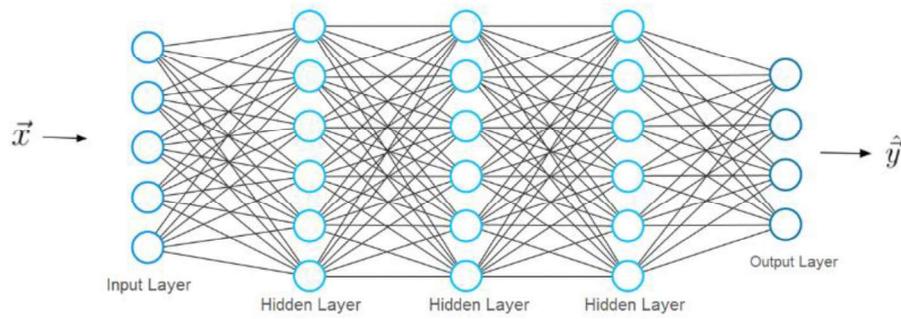
Dari Gambar 2.5, bagian *Classification* merupakan model pembelajaran. Pada penelitian ini, model pembelajaran yang digunakan untuk klasifikasi adalah *Artificial Neural Network* (ANN) atau sering disebut *Multi Layer Perceptron* (MLP) atau disebut juga *Fully Connected Layer*. *Artificial Neural Network* ini terinspirasi berdasarkan neuron pada otak manusia, sehingga cara kerja ANN ini mirip dengan cara kerja jaringan neuron pada otak namun lebih sederhana. Struktur ANN umumnya berisi beberapa node yang saling terhubung. Node inilah yang dinamakan neuron.

Antar neuron saling terhubung dengan sebuah jalur yang memiliki bobot (*weight*). Jalur ini merepresentasikan kekuatan koneksi antar neuron yang mana nilai bobot pada jalur penghubung ini akan berubah ketika jaringan neuron melakukan pembelajaran [10]. Pada proses pembangunan Model *Neural Network*, penentuan nilai awal bobot sangat penting untuk jaringan neuron bisa melakukan pembelajaran yang baik.



Gambar 2.6 Hubungan Antar Neuron [10]

Struktur *Neural Network* secara umum terdiri dari 3 layer antara lain *input layer*, *hidden layer* dan *output layer*. Pada Gambar 2.7 menunjukkan bahwa struktur *neural network* yang dibangun memiliki 1 *input layer*, 3 *hidden layer* dan 1 *output layer*.



Gambar 2.7 Struktur Layer Neural Network [10]

2.2.5 Metrics, Loss Function dan Optimizer

Pada saat melakukan proses pembelajaran *Neural Network*, akan muncul *accuracy* dan *loss* pembelajaran. *Accuracy* adalah parameter untuk mengukur kinerja model klasifikasi yang biasanya dinyatakan sebagai persentase. Akurasi adalah hitungan prediksi hasil perbandingan antara jumlah data yang prediksi benar sama dan jumlah data sebenarnya. *Accuracy* juga diperoleh selama fase pelatihan meskipun nilainya sering dikaitkan dengan akurasi model keseluruhan atau akhir. Nilai *accuracy* dapat diperoleh menggunakan rumus sebagai berikut:

$$Accuracy = \frac{\text{Data yang diprediksi benar}}{\text{Data yang diprediksi}} \quad (2.4)$$

Sedangkan *Loss* merepresentasikan memperhitungkan probabilitas atau ketidakpastian prediksi berdasarkan seberapa banyak prediksi bervariasi dari nilai sebenarnya. *Loss* digunakan untuk mengukur seberapa baik kinerja model. Tidak seperti *accuracy*, *loss* bukanlah persentase melainkan penjumlahan dari kesalahan yang dibuat untuk setiap sampel dalam set pelatihan atau validasi. *Loss* sering digunakan dalam proses pelatihan untuk menemukan nilai parameter "terbaik" untuk model (misalnya bobot dalam *neural network*). Selama proses pelatihan, tujuannya adalah untuk meminimalkan nilai *loss*. Nilai *Loss* dapat diperoleh menggunakan beberapa metode *Loss Function* sesuai dengan arsitektur *output layer Neural Network* yang dibangun.

1. *Regression*

Digunakan untuk prediksi kuantitas nilai real. *Loss Function* yang dapat diterapkan pada permasalahan ini adalah *Mean Squared Error* (MSE) dengan rumus:

$$MSE = \frac{1}{\text{jumlah data} \times \sum(\text{data asli} - \text{prediksi})^2} \quad (2.5)$$

2. *Binary Classification*

Untuk mengklasifikasi 1 data dari 2 kelas. *Loss Function* yang digunakan yaitu *Cross-Entropy* dengan rumus:

$$Cross\ Entropy = \frac{1}{\text{jumlah data} \times \sum \text{data asli} \times (\log 1e^{-15} + \text{prediksi})} \quad (2.6)$$

3. *Multiclass Classification*

Untuk mengklasifikasi 1 data dari beberapa kelas (lebih dari 2). *Loss Function* yang digunakan adalah *Cross-Entropy*, dengan rumus yang sama dengan persamaan 2.6 hanya saja sedikit dimodifikasi [11].

Saat melatih model *Neural Network*, perlu dilakukannya memodifikasi bobot setiap *neuron* dan meminimalkan *loss function*. Pemilihan bobot yang tepat untuk model merupakan suatu pekerjaan yang sulit, karena model *neural network* umumnya terdiri dari jutaan parameter. Sehingga memerlukan algoritma *Optimizer* yang sesuai untuk model yang dirancang. *Optimizer* adalah fungsi atau algoritme yang memodifikasi parameter jaringan saraf yang dibangun, seperti bobot dan kecepatan pembelajaran (*learning rate*). Sehingga membantu dalam mengurangi *loss* dan meningkatkan *accuracy*.

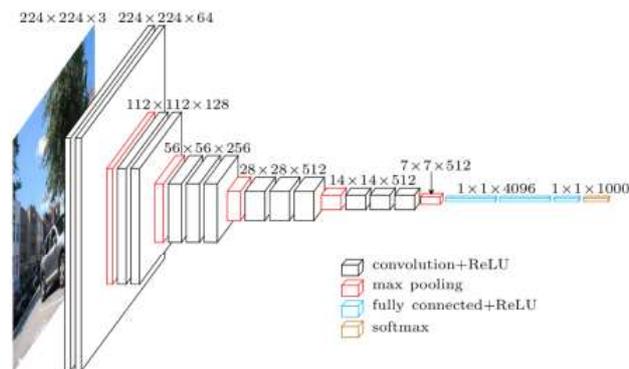
Terdapat beberapa jenis *optimizer* yang dapat digunakan untuk memodifikasi parameter jaringan syaraf tiruan antara lain *Gradient Descent*, *Stochastic Gradient Descent*, *Mini Batch Gradient Descent*, *Momentum*, *Adagrad*, *Adam*, *AdaDelta* [12].

2.2.6 *Convolutional Neural Network (CNN)*

CNN atau sering disebut juga *convNet* merupakan Arsitektur *Neural Network* yang digunakan untuk *Image Processing*, *Speech Recognition*, Analisa

Dokumen, maupun Deteksi Objek. Arsitektur CNN tersusun dari *Convolutional Layer*, *Sampling Layer* atau sering disebut sebagai *Pooling* dan *Fully Connected Layer/Neural Network*. CNN bekerja dengan cara mempelajari fitur abstrak dari *Convolutional* dan *Pooling Layer*.

Convolutional Layer berisi filter/*feature detector* yang akan diterapkan pada citra masukan dengan cara mengambil subregion kecil pixel gambar/citra yang mana setiap subregion akan dijadikan sebagai *feature maps*. Kemudian *Pooling Layer* akan mengekstrak fitur dominan dari *feature maps* yang dihasilkan oleh *Convolutional Layer*. Setelah mendapatkan fitur dominan maka tahap selanjutnya adalah proses *training* pada *Fully Connected Layer* [13]. Salah satu arsitektur CNN yang sering digunakan untuk *Image Processing* adalah VGG16. Angka 16 pada VGG16 merupakan jumlah *layer* pada arsitektur yang terdiri dari 13 *Convolutional Layer* dan 3 *Fully Connected Layer* [14].



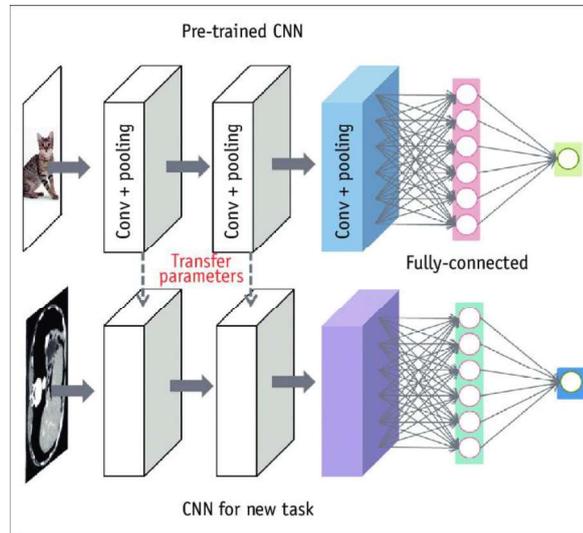
Gambar 2.8 Arsitektur VGG16 [14]

2.2.7 Transfer Learning

Transfer Learning merupakan proses mengambil model yang telah dilatih sebelumnya (*pre-trained*). Penggunaan CNN perlu menggunakan data yang sangat banyak untuk mendapatkan model yang memiliki performa belajar yang baik. Sehingga untuk beberapa kumpulan data target dengan jumlah dataset yang tidak seimbang dan berjumlah sedikit, teknologi *transfer learning* dapat digunakan untuk menyelesaikan masalah pelatihan model pada dataset dengan jumlah yang kecil [15].

Tujuan dari *transfer learning* adalah menggunakan model *pre-trained* yang akan bertindak sebagai pengekstrak fitur seperti garis tepi atau kurva untuk deteksi

objek dan klasifikasi gambar. Dengan menggunakan *transfer learning*, pengembangan model CNN untuk jumlah dataset yang sedikit dapat dilakukan karena jumlah parameter untuk pelatihan dapat menggunakan kembali parameter model yang telah dilatih sebelumnya [16].

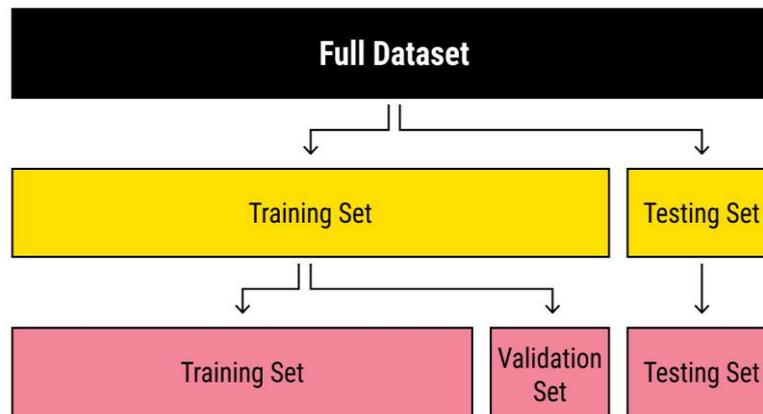


Gambar 2.9 Proses *Transfer Learning* [16]

2.2.8 Dataset

Dataset memiliki pengertian yang berbeda-beda untuk bidang tertentu. Pada penelitian ini, *Dataset* yang dimaksud adalah *Dataset* pada *Artificial Intelligence* (AI). Yaitu sekumpulan data yang berisi banyak bagian-bagian data yang terpisah namun dapat digunakan untuk melatih algoritma dengan tujuan menemukan pola matematis yang dapat melakukan klasifikasi di dalam keseluruhan data. *Dataset* untuk AI dapat berupa tabel, gambar, suara hingga video yang memiliki ciri/fitur masing-masing untuk setiap jenis *Dataset*.

Umumnya *Dataset* tidak hanya untuk *training* model AI. Satu set data yang telah diproses dibagi menjadi beberapa bagian. Pembagian *Dataset* bertujuan untuk memeriksa seberapa baik pelatihan model AI yang sudah dibuat [17].



Gambar 2.10 Pembagian Dataset [17]

Pada penelitian ini *Dataset* yang digunakan adalah *Dataset* Gambar yang mana memiliki fitur khusus berupa nilai warna tiap pixel berupa Red, Green, Blue untuk 3 *channel* dan White, Black untuk 1 *channel* dengan rentang nilai 0 – 255. Selain gambar, pada penelitian ini menggunakan *Dataset* Suara dengan fitur yang digunakan adalah nilai frekuensi.

2.2.9 *Classification Evaluation Metrics*

Evaluation Metrics merupakan suatu proses untuk mengukur akurasi model dalam memprediksi data. Terdapat beberapa metode *Evaluation Metrics* untuk mengukur akurasi model *Deep Learning* tergantung dari jenis model yang dibuat, salah satu metode evaluasi adalah *Classification Evaluation Metrics*.

Metode tersebut berfungsi untuk evaluasi model pembelajaran yang berkaitan dengan masalah klasifikasi. Terdapat 4 variabel yang digunakan pada evaluasi ini yaitu *True Positive* (TP) yang berarti hasil prediksi benar sesuai dengan kelas sesungguhnya, *True Negative* (TN) atau hasil prediksi yang salah dan memang kelas yang sesungguhnya adalah salah, *False Positive* (FP) atau prediksi menunjukkan prediksi yang benar namun sesungguhnya salah dan *False Negative* (FN) yang berarti prediksi menunjukkan salah padahal kenyataannya benar. Variabel-variabel tersebut dapat diperoleh dari tabel *Confusion Matrix* [18].

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 2.11 Tabel *Confusion Matrix* [19]

Pada gambar di atas menunjukkan contoh *confusion matrix* untuk masalah klasifikasi biner (*Binary Classification*). Selain klasifikasi biner, *confusion matrix* juga berlaku untuk masalah klasifikasi multi kelas (*Multiclass Classification*). Dengan bantuan *Confusion Matrix*, performa suatu model klasifikasi dapat diukur dengan 4 parameter yaitu *Precision*, *Recall*, *F1-Score*, dan *Accuracy*.

- a. *Precision*, didefinisikan rasio prediksi *True Positive* dibandingkan dengan keseluruhan hasil yang diprediksi *Positive*.

$$Precision = \frac{TP}{TP+FP} \quad (2.7)$$

- b. *Recall*, merupakan rasio prediksi *True Positive* dibandingkan dengan keseluruhan data aktual yang *True Positive*.

$$Recall = \frac{TP}{TP+FN} \quad (2.8)$$

- c. *F1-Score*, didefinisikan sebagai tingkat keseimbangan antara *Precision* dan *Recall*.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.9)$$

- d. *Accuracy*, didefinisikan sebagai persentase prediksi yang benar untuk data tes [19]. Untuk menghitung *Accuracy* dapat menggunakan persamaan:

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (2.10)$$