



TESIS - EE185401

**KLASIFIKASI GERAKAN PENCAK SILAT
MENGUNAKAN *CONVOLUTIONAL NEURAL
NETWORK* BERBASIS *BODY POSE***

VIRA NUR RAHMAWATI
07111950050005

DOSEN PEMBIMBING
Dr. Eko Mulyanto Yuniarno, S.T., M.T.
Dr. Supeno Mardi Susiki Nugroho, S.T., M.T.

PROGRAM MAGISTER
BIDANG KEAHLIAN JARINGAN CERDAS MULTIMEDIA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2023



TESIS - EE185401

**KLASIFIKASI GERAKAN PENCAK SILAT
MENGUNAKAN *CONVOLUTIONAL NEURAL
NETWORK* BERBASIS *BODY POSE***

VIRA NUR RAHMAWATI
07111950050005

DOSEN PEMBIMBING
Dr. Eko Mulyanto Yuniarno, S.T., M.T.
Dr. Supeno Mardi Susiki Nugroho, S.T., M.T.

PROGRAM MAGISTER
BIDANG KEAHLIAN JARINGAN CERDAS MULTIMEDIA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2023

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

Magister Teknik (MT)

di

Institut Teknologi Sepuluh Nopember

Oleh:

VIRA NUR RAHMAWATI

NRP: 07111950050005

Tanggal Ujian: 10 Juli 2023

Periode Wisuda: September 2023

Disetujui oleh:

Pembimbing:

1. Dr. Eko Mulyanto Yuniarno, S.T., M.T.
NIP: 196806011995121009

2. Dr. Supeno Mardi Susiki N., S.T., M.T.
NIP: 197003131995121001

Penguji:

1. Dr. Diah Puspito Wulandari, S.T., M.T.
NIP: 198012192005012001

2. Dr. Susi Juniastuti, S.T., M.Eng.
NIP: 196506181999032001

Kepala Departemen Teknik Elektro

Departemen Teknik Elektro dan Informatika Cerdas



Dedet Candra Riawan, S.T., M.Eng., Ph.D.

NIP: 197311192000031001

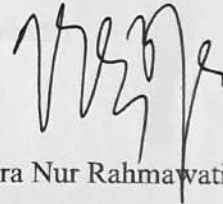
Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN TESIS

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul “**KLASIFIKASI GERAKAN PENCAK SILAT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK BERBASIS BODY POSE**” adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, 15 Juni 2023



Vira Nur Rahmawati

NRP. 07111950050005

Halaman ini sengaja dikosongkan

KLASIFIKASI GERAKAN PENCAK SILAT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK BERBASIS BODY POSE

Nama mahasiswa : Vira Nur Rahmawati
NRP : 07111950050005
Pembimbing : 1. Dr. Eko Mulyanto Yuniarno, S.T., M.T.
2. Dr. Supeno Mardi Susiki Nugroho, S.T., M.T.

ABSTRAK

Pencak silat selain bermanfaat untuk perlindungan diri, juga memiliki banyak manfaat lainnya, seperti meningkatkan kekuatan fisik, menjaga postur tubuh, dan menjaga kesehatan jantung. Karena pandemi yang belakangan terjadi ini, latihan pencak silat sulit dilakukan secara bersama-sama. Selain itu, jika ada materi pelajaran pencak silat di sekolah, guru olahraga kesulitan untuk mengajarkan gerak secara langsung. Tetapi latihan pencak silat yang dilakukan sendiri tanpa pelatih dapat menyebabkan cedera jika gerakannya tidak benar. Oleh karena itu, penelitian ini membangun sistem pengenalan gerakan pencak silat. Sistem dibangun menggunakan metode CNN berbasis *bodypose*. *Bodypose extraction* digunakan untuk mendeteksi *keypoint* tubuh manusia, kemudian *keypoint* tersebut digunakan sebagai fitur *input* ke CNN untuk mengenali gerakan pada setiap *frame*. Sistem ini menggunakan CNN karena membutuhkan parameter yang lebih sedikit dan daya komputasi yang lebih sedikit sehingga dapat lebih mudah diterapkan untuk studi selanjutnya. Akurasi yang diperoleh mencapai 77% saat diuji pada data yang belum pernah digunakan. Model ini dapat digunakan sebagai titik awal untuk membuat sistem yang mudah digunakan untuk membantu orang berlatih pencak silat dengan gerakan yang lebih banyak.

Kata kunci: (pencak silat, CNN, konvolusi, *body pose*)

Halaman ini sengaja dikosongkan

PENCAK SILAT MOVEMENT CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK BASED ON BODY POSE

By : Vira Nur Rahmawati
Student Identity Number : 07111950050005
Supervisor(s) : 1. Dr. Eko Mulyanto Yuniarno, S.T., M.T.
2. Dr. Supeno Mardi Susiki N., S.T., M.T.

ABSTRACT

Pencak silat, besides from being useful for self-protection, also has many other benefits, such as increasing physical strength, maintaining posture, and maintaining heart health. Due to the recent pandemic, practicing pencak silat is difficult to do together. Even when there is study material on pencak silat at school, it is difficult for the sports teacher to teach the movements directly. Pencak silat exercises that are practiced alone without a coach can cause injury if the movements are not correct. Therefore, this study builds a system to recognize pencak silat movements. The system was built using the bodypose-based CNN method. Bodypose estimation is used to detect human body keypoints, then these keypoints are used as a feature for input to CNN to recognize movement in each frame. This system uses CNN because it requires fewer parameters and less computing power so that it can be more easily applied for further studies. The accuracy obtained reaches 77% when tested on data that has never been used. This model can be used as a starting point for creating an easy-to-use system to help people practice pencak silat with more recognizable moves.

Key words: pencak silat, CNN, convolution, body pose, mediapipe

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Alhamdulillah, puji syukur kepada Allah SWT atas rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan laporan tesis dengan judul “KLASIFIKASI GERAKAN PENCAK SILAT MENGGUNAKAN CNN BERBASIS *BODY POSE*” sebagai salah satu syarat untuk lulus.

Semoga laporan ini dapat bermanfaat bagi kita semua.

Surabaya, 15 Juni 2023

Vira Nur Rahmawati

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN TESIS.....	iii
PERNYATAAN KEASLIAN TESIS.....	v
ABSTRAK.....	vii
ABSTRACT.....	ix
KATA PENGANTAR.....	xi
DAFTAR ISI.....	xiii
DAFTAR GAMBAR.....	xv
DAFTAR TABEL.....	xvii
BAB 1 PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan.....	3
1.4 Kontribusi.....	3
BAB 2 KAJIAN PUSTAKA.....	5
2.1 Kajian Penelitian Terkait.....	5
2.2 Beladiri.....	6
2.3 Pencak Silat.....	7
2.1.1. Sejarah Pencak Silat.....	7
2.1.2. Manfaat Pencak Silat.....	9
2.1.3. Gerakan Pencak Silat.....	10
2.4 <i>Pose Estimation</i>	11
2.2.1. PoseNet.....	11
2.2.2. MoveNet.....	12
2.2.3. MediaPipe.....	14
2.5 <i>Convolutional Neural Network (CNN)</i>	17
2.3.1. <i>Convolution Layer</i>	18

2.3.2.	<i>Pooling Layer</i>	18
2.3.3.	<i>Fully Connected Layer</i>	19
BAB 3	METODE PENELITIAN.....	21
3.1.	Dataset.....	21
3.2.	Ekstraksi pose.....	21
3.3.	Klasifikasi.....	23
BAB 4	HASIL DAN PEMBAHASAN.....	27
4.1	Dataset.....	28
4.2	Ekstraksi pose.....	29
4.3	Klasifikasi.....	33
BAB 5	KESIMPULAN DAN SARAN.....	35
DAFTAR	PUSTAKA.....	37
LAMPIRAN	41
DAFTAR	INDEX.....	43

DAFTAR GAMBAR

Gambar 2.1 <i>Keypoint</i> pada <i>Body Pose</i> PoseNet	12
Gambar 2.2 Arsitektur MoveNet	14
Gambar 2.3 Deteksi objek menggunakan MediaPipe	15
Gambar 2.4 <i>Keypoint</i> pada <i>body pose</i> MediaPipe	16
Gambar 2.5 Deteksi Landmark menggunakan MediaPipe	17
Gambar 2.6 Arsitektur CNN.....	18
Gambar 2.6 Contoh Operasi <i>Max Pooling</i>	20
Gambar 3.1 Blok Diagram Penelitian.....	21
Gambar 3.2 Model CNN.....	24
Gambar Error! No text of specified style in document. 1 Contoh Gerakan dari $t=1$ sampai $t=n$, untuk (a) Tendangan Lurus, (b) Tendangan Melingkar, (c) Tendangan T.....	28
Gambar Error! No text of specified style in document. 2 Hasil Ekstraksi Pose dari $t=1$ sampai $t=n$, untuk (a) Tendangan Lurus, (b) Tendangan Melingkar, (c) Tendangan T.....	30
Gambar 4.3 Hasil Pose Ekstraksi di Awal Gerakan (a) Tendangan Lurus (b) Tendangan Melingkar, (c) Tendangan T.....	31
Gambar 4.4 Hasil Pose Ekstraksi di Puncak Gerakan (a) Tendangan Lurus (b) Tendangan Melingkar, (c) Tendangan T.....	32
Gambar 4.5 <i>Loss</i> Model dari Proses Training.....	33
Gambar 4.6. <i>Confusion Matrix</i>	34

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Pencak silat adalah seni bela diri yang berasal dari Indonesia. Pencak silat tercipta dari cara nenek moyang Indonesia menjaga diri dan mempertahankan hidupnya dari tantangan alam. Pencak silat memiliki banyak manfaat, antara lain meningkatkan kekuatan fisik, menjaga berat badan ideal, menjaga postur tubuh, dan meningkatkan kesehatan jantung. Selain itu, pencak silat juga bermanfaat untuk menumbuhkan karakter anak, dengan cara menumbuhkan keberanian, kedisiplinan, percaya diri, sportivitas, dan keterampilan bersosialisasi. Untuk mendapatkan berbagai manfaat tersebut, latihan pencak silat harus rutin dilakukan tiga sampai empat kali dalam seminggu, baik di sekolah, di tempat kursus pencak silat, maupun di rumah. Namun karena berbagai alasan, terutama kesibukan, latihan empat kali seminggu sulit dilakukan, dan latihan sendiri di rumah tidak efektif karena tidak ada pemandu yang bisa menilai apakah gerakannya sudah benar atau belum. Selain itu, jika gerakannya dilakukan secara tidak benar, dapat menyebabkan cedera. Untuk itu diperlukan suatu sistem untuk mendeteksi dan mengklasifikasikan gerakan pencak silat.

Banyak peneliti telah melakukan dan mengeksplorasi sistem pengenalan gerakan manusia. Estimasi pose manusia digunakan untuk mengenali gerakan berdiri, jongkok, senam tubuh, dan jatuh. Ini digunakan terutama untuk orang yang tinggal sendiri, sehingga mereka bisa mendapatkan pertolongan dengan cepat jika terjadi kecelakaan [1]. Eksperimen pada lebih banyak gerakan juga telah dilakukan, untuk 20 kegiatan umum. Estimasi pose dilakukan dengan menggunakan regresi CNN dan menghasilkan 14 joint keypoints. Klasifikasi dilakukan menggunakan CNN yang diimplementasikan menggunakan caffe berbasis AlexNet. Metode ini dapat mencapai akurasi sebesar 80,51% [2]. Gupta dkk. melakukan pengenalan beberapa aktivitas manusia, antara lain duduk, berdiri, berlari, menari, dan berbaring. Studi tersebut menggunakan pose terbuka dengan 18 titik kunci tubuh untuk mengekstraksi pose tubuh. Untuk klasifikasi, mereka membandingkan

beberapa algoritma, yaitu Multiple Logistic Regression, KNN, SVM, Decision Tree, dan Random Forest. Hasilnya, algoritma Multiple Logistic Regression, SVM, dan Random Forest memberikan hasil yang baik yaitu diatas 80% [3].

Seiring perkembangannya, pengenalan gerakan manusia juga digunakan dalam berbagai bidang, seperti seni dan olahraga. Dalam bidang seni dapat digunakan untuk membuat model generatif tari [4]. Dalam bidang olahraga paling banyak digunakan dalam yoga karena memiliki banyak gerakan yang unik [5][6]. Penelitian pengenalan postur yoga dilakukan oleh Kishore et al., postur yang digunakan adalah Ardha Chandrasana, Tadasana, Trikonasana, Veerabhadrasana, dan Vrukshasana. Dalam penelitiannya, ia membandingkan beberapa arsitektur deep learning yang digunakan untuk estimasi pose. Arsitektur yang dibandingkan adalah EpipolarPose, OpenPose, PoseNet, dan MediaPipe. MediaPipe memberikan akurasi estimasi terbaik, di atas 80% [7]. Hal ini membuat MediaPipe banyak digunakan untuk estimasi pose. Pengenalan gerakan yoga berdasarkan MediaPipe dilakukan oleh Tanugraha et al. Klasifikasi dilakukan menggunakan LSTM dengan Adam Optimizer. Gerakan yang dilakukan adalah T-Pose, Warrior Pose, dan Tree pose dalam yoga. Riset dilakukan dengan merekam gerakan dengan kamera, kemudian dilanjutkan dengan pendeteksian 33 keypoint dari postur tubuh manusia. setelah itu membuat klasifikasi pergerakan dengan LSTM secara real time dan mencapai akurasi 91% [8].

Penelitian tentang pengenalan gerakan silat telah banyak dikembangkan. Penelitian ini menggunakan mesin Neural Network Teachable dengan algoritma RNN, kemudian diintegrasikan dengan program aplikasi mobile menggunakan Flutter. Gerakan yang digunakan adalah jurus sempurna, jangkar kuda, jangkar katak, jurus 1 dan jurus 2. Akurasi yang didapat mencapai 70% saat objek dalam posisi diam, namun saat objek bergerak akurasinya hanya sampai 10% [9]. Oleh karena itu, untuk mendapatkan akurasi yang lebih baik, jurnal ini mengusulkan pendekatan baru untuk mengklasifikasikan gerakan pencak silat menggunakan video sebagai kumpulan data. Semua bagian video akan dimasukkan dalam proses klasifikasi, bukan hanya sepotong gambar. Penelitian ini menggunakan Convolutional Neural Network (CNN) sebagai arsitektur model dengan MediaPipe sebagai framework estimasi pose tubuh.

1.2 Rumusan Masalah

Berdasarkan analisis uraian dalam latar belakang, maka rumusan masalah dalam penelitian ini adalah bagaimana rancangan program untuk klasifikasi gerakan pencak silat dengan menggunakan *bodypose estimation* agar menghasilkan akurasi yang baik.

1.3 Tujuan

Tujuan dari penelitian ini adalah menerapkan konsep *bodypose estimation* pada gerakan pencak silat, kemudian diklasifikasikan menggunakan CNN untuk mendapatkan output berupa jenis gerakan.

1.4 Batasan Masalah

Penelitian ini diberikan Batasan masalah agar terpusat pada tujuan utama dan tidak melebar. Batasan masalah untuk penelitian ini adalah sebagai berikut:

1. Gerakan yang diklasifikasikan ada 3, yaitu tendangan lurus, tendangan melingkar, dan tendangan t.
2. Selama pengambilan data, posisi kamera tidak berubah.

1.5 Manfaat

Manfaat yang diperoleh dari penelitian ini adalah penelitian ini diharapkan dapat memicu perkembangan pengenalan gerakan pencak silat, juga memberikan kemudahan pada pengguna untuk berlatih melakukan gerakan silat dengan tepat secara mandiri.

Halaman ini sengaja dikosongkan

BAB 2

KAJIAN PUSTAKA

2.1 Kajian Penelitian Terkait

Banyak peneliti telah melakukan dan mengeksplorasi sistem pengenalan gerakan manusia. Estimasi pose manusia digunakan untuk mengenali gerakan berdiri, jongkok, senam tubuh, dan jatuh. Ini digunakan terutama untuk orang yang tinggal sendiri, sehingga mereka bisa mendapatkan pertolongan dengan cepat jika terjadi kecelakaan [1]. Eksperimen pada lebih banyak gerakan juga telah dilakukan, untuk 20 kegiatan umum. Estimasi pose dilakukan dengan menggunakan regresi CNN dan menghasilkan 14 joint keypoints. Klasifikasi dilakukan menggunakan CNN yang diimplementasikan menggunakan caffe berbasis AlexNet. Metode ini dapat mencapai akurasi sebesar 80,51% [2]. Gupta dkk. melakukan pengenalan beberapa aktivitas manusia, antara lain duduk, berdiri, berlari, menari, dan berbaring. Studi tersebut menggunakan pose terbuka dengan 18 titik kunci tubuh untuk mengekstraksi pose tubuh. Untuk klasifikasi, mereka membandingkan beberapa algoritma, yaitu Multiple Logistic Regression, KNN, SVM, Decision Tree, dan Random Forest. Hasilnya, algoritma Multiple Logistic Regression, SVM, dan Random Forest memberikan hasil yang baik yaitu diatas 80% [3].

Seiring perkembangannya, pengenalan gerakan manusia juga digunakan dalam berbagai bidang, seperti seni dan olahraga. Dalam bidang seni dapat digunakan untuk membuat model generatif tari [4]. Dalam bidang olahraga paling banyak digunakan dalam yoga karena memiliki banyak gerakan yang unik [5][6]. Penelitian pengenalan postur yoga dilakukan oleh Kishore et al., postur yang digunakan adalah Ardha Chandrasana, Tadasana, Trikonasana, Veerabhadrasana, dan Vrukshasana. Dalam penelitiannya, ia membandingkan beberapa arsitektur deep learning yang digunakan untuk estimasi pose. Arsitektur yang dibandingkan adalah EpipolarPose, OpenPose, PoseNet, dan MediaPipe. MediaPipe memberikan akurasi estimasi terbaik, di atas 80% [7]. Hal ini membuat MediaPipe banyak digunakan untuk estimasi pose. Pengenalan gerakan yoga berdasarkan MediaPipe dilakukan oleh Tanugraha et al. Klasifikasi dilakukan menggunakan LSTM dengan

Adam Optimizer. Gerakan yang dilakukan adalah T-Pose, Warrior Pose, dan Tree pose dalam yoga. Riset dilakukan dengan merekam gerakan dengan kamera, kemudian dilanjutkan dengan pendeteksian 33 keypoint dari postur tubuh manusia. setelah itu membuat klasifikasi pergerakan dengan LSTM secara real time dan mencapai akurasi 91% [8].

Penelitian tentang pengenalan gerakan silat telah dilakukan. Penelitian ini menggunakan mesin Neural Network Teachable dengan algoritma RNN, kemudian diintegrasikan dengan program aplikasi mobile menggunakan Flutter. Gerakan yang digunakan adalah jurus sempurna, jangkar kuda, jangkar katak, jurus 1 dan jurus 2. Akurasi yang didapat mencapai 70% saat objek dalam posisi diam, namun saat objek bergerak akurasinya hanya sampai 10% [9].

2.2 Beladiri

Beladiri adalah sebuah sistem atau alat yang digunakan untuk melindungi diri dari berbagai serangan lawan. Beladiri sudah ada sejak zaman kuno, dimana beladiri dibutuhkan untuk mempertahankan hidup dari binatang buas maupun serangan manusia lain saat memperebutkan makanan atau wilayah. Setiap daerah atau negara mempunyai beladiri dengan ciri khas yang berbeda. Hal ini disebabkan adanya perbedaan kondisi geografis wilayah, jenis fauna di sekitar wilayah, sampai postur tubuh manusia. Gerakan beladiri terbentuk secara alami dengan menyesuaikan kondisi dan mendapatkan hasil terbaik dengan usaha yang paling sedikit.

Indonesia mempunyai beladiri yang asli berasal dari Indonesia, yaitu pencak silat. Perbedaan pencak silat dengan beladiri lain yaitu pencak silat mengutamakan kelenturan, kelincahan, dan sasaran yang tepat untuk menguasai lawan. Pencak silat juga mengutamakan konsentrasi untuk dapat memanfaatkan kekuatan lawan untuk menyerang. Sementara itu, karate lebih mengandalkan kekuatan untuk menyerang lawan. Adapun taekwondo mengutamakan pergerakan kaki untuk menghancurkan dan melawan.

2.3 Pencak Silat

Pencak silat merupakan salah satu jenis seni bela diri yang berasal dari Indonesia. Menurut Ikatan Pencak Silat Indonesia (IPSI) bersama Badan Koordinasi Intelijen (BAKIN) pada tahun 1975, Pencak silat adalah hasil budaya manusia Indonesia untuk membela dan mempertahankan eksistensi (kemandirian) dan integritasnya (manunggalnya) terhadap lingkungan hidup atau alam sekitarnya untuk mencapai keselarasan hidup guna meningkatkan iman dan takwa kepada Tuhan Yang Maha Esa [12].

Seperti halnya seni bela diri lain, pencak silat mempunyai ciri-ciri umum sebagai berikut [10]:

- a. Mempergunakan seluruh bagian tubuh, mulai dari kepala sampai jari tangan dan jari kaki, bahkan sampai rambut juga dapat digunakan sebagai senjata.
- b. Dapat dilakukan dengan tangan kosong atau menggunakan senjata.
- c. Dapat menggunakan benda apapun sebagai senjata, tidak perlu senjata tertentu, seperti payung, ikat pinggang, tas, dll.

Untuk membedakan dengan seni bela diri lain, pencak silat mempunyai ciri-ciri khusus sebagai berikut [10]:

- a. Sikap tenang, seperti kucing waspada.
- b. Menggunakan kelenturan, kelincahan, kecepatan, dan ketepatan untuk menguasai lawan, bukan menggunakan kekuatan.
- c. Menggunakan permainan posisi dengan memindahkan titik berat badan.
- d. Memanfaatkan setiap serangan lawan dan tenaga lawan.
- e. Mengeluarkan tenaga sesedikit mungkin, seperti gerakan yang halus, langkah ringan, tidak melompat, tidak berguling, tidak banyak bersuara, banyak permainan rendah, dan tendangan tidak terlalu tinggi.

2.3.1 Sejarah Pencak Silat

Pencak silat terbentuk dari cara nenek moyang Bangsa Indonesia dalam melindungi diri dan mempertahankan hidupnya. Pada zaman primitif, manusia

hidup dengan cara berkelompok. Mata pencahariannya adalah dengan berburu. Mereka akan berpindah-pindah tempat untuk mencari tempat yang terdapat banyak hewan buruan. Bahkan mereka akan saling berebut wilayah kekuasaan dengan daerah yang terdapat banyak binatang buruan sampai terjadi perang antar kelompok. Selain perang antar kelompok, manusia primitive juga terancam oleh serangan binatang buas. Mereka akan berusaha melindungi diri dengan cara yang sesuai dengan keadaan alam sekitarnya. Dengan meniru gerakan binatang-binatang, mereka menciptakan suatu gerakan bela diri, seperti gerakan kera, harimau, ular, dan elang. [10]

Karena setiap daerah mempunyai kondisi alam yang berbeda, maka akan tercipta cara dan gerakan bela diri yang berbeda pula, inilah yang menjadi awal mula terbentuknya aliran pencak silat, seperti aliran Jawa, Sumatera, Kalimantan, Sulawesi, dan Maluku. Pada saat pulau-pulau mulai terhubung, para pendekar pencak silat akan saling menunjukkan kemampuannya. Kemudian mereka akan berusaha menyempurnakan teknik pencak silat mereka dengan memadukan berbagai teknik dari aliran lain. Pengetahuan dan Teknik pencak silat menjadi semakin berkembang dan menjadi kekuatan utama kerajaan-kerajaan di Indonesia.

Pada zaman kerajaan, pencak silat atau ilmu bela diri mulai diajarkan oleh guru, baik perorangan maupun dalam kelompok. Keterampilan bela diri yang diajarkan lebih diutamakan menggunakan senjata tajam. Tujuannya adalah untuk membentuk pasukan perang yang kuat dan ampuh. Pasukan perang bertugas untuk mempertahankan kerajaan dari serangan musuh. Seperti pada tahun 1292, saat Tentara Tartar menyerang Kerajaan Singosari dengan 20.000 orang prajurit, dapat dikalahkan oleh Raden Wijaya bersama para pasukannya dengan kemampuan bela diri yang tangguh.

Pada zaman penjajahan belanda, Bangsa Indonesia menggunakan ilmu bela diri pencak silat untuk melawan penjajah dan terus mengajarkannya ke berbagai kalangan. Tetapi, Belanda khawatir akan membahayakan dan mulai membatasi dan mengawasi dengan ketat. Perkumpulan-perkumpulan gerakan kemerdekaan dilarang. Hanya beberapa pendekar yang diizinkan melatih pencak silat, dan hanya boleh diberikan di kalangan pegawai pemerintahan, sekolah Pendidikan, polisi, dan pegawai sipil tertentu saja. Tetapi para pejuang tetap

mengajarkan dengan sembunyi-sembunyi melalui perkumpulan-perkumpulan, seperti olahraga dan kesenian. Selain itu, pencak silat juga diajarkan di pesantren-pesantren sebagai bagian dari Pendidikan jasmani dan Pendidikan mental para santri.

Sampai saat ini, Pendidikan pencak silat masih diajarkan di pesantren-pesantren sampai sekolah biasa. Kemudian muncul berbagai perguruan pencak silat yang menyebar luas di Indonesia. Hal ini membuat pencak silat masih bersifat egosentrisme perguruan, dengan menjaga dan mengembangkan perguruan pencak silat masing-masing. Bahkan banyak terjadi bentrokan antar perguruan pencak silat. Bentrokan tersebut mulai memunculkan kesadaran akan pentingnya nasionalisme pencak silat. Sehingga pada 18 Mei 1948, terbentuklah induk organisasi pencak silat yaitu IPSI (Ikatan Pencak Silat Indonesia). Sejak terbentuk IPSI, pencak silat mulai dipertandingkan dalam Pekan Olahraga (PON). Pencak silat mulai ikut dipertandingkan pada SEA Games ke-14 tahun 1987 di Jakarta.

2.3.2 Manfaat Pencak Silat

Pencak silat dapat memberikan banyak manfaat. Selain manfaat utama sebagai perlindungan diri, pencak silat juga mempunyai manfaat sesuai dengan unsur yang terkandung di dalamnya, yaitu unsur olahraga, unsur kesenian, unsur bela diri, dan unsur kerohanian atau kebatinan.

Seperti halnya olahraga lain, pencak silat sebagai olahraga juga mempunyai manfaat untuk mengembangkan dan membina kekuatan jasmani, seperti memelihara kesehatan jantung, meningkatkan kekuatan otot, memperbaiki postur tubuh, sampai meningkatkan imun tubuh.

Unsur seni pada pencak silat terletak pada gerakannya, terutama di daerah-daerah tertentu, pencak silat diiringi music khas daerah. Bahkan di daerah tertentu seperti Sumatera Barat dan Aceh, pencak silat ditampilkan sebagai seni tari, tetapi gerakan tari dapat diperagakan sebagai gerak bela diri yang efektif.

Selain manfaat yang bisa dirasakan tubuh, pencak silat juga bisa melatih ketahanan mental, mengembangkan kewaspadaan diri yang tinggi, meningkatkan

rasa percaya diri, sportifitas, disiplin, dan keuletan, juga dapat menanamkan penghayatan pada alam dan perjuangan hidup.

Setiap perguruan maupun tempat berlatih pencak silat mempunyai tujuan masing-masing, sehingga kadar unsur materi yang diajarkan juga berbeda. Misalnya di sekolah, pendidikan dan pengajaran pencak silat diutamakan pada unsur olahraga dan unsur kesenian. Di salah satu perguruan pencak silat, diutamakan unsur bela diri, sedangkan di perguruan silat lain lebih diutamakan unsur kebatinan. Tergantung manfaat yang ingin diperoleh.

2.3.3 Gerakan Pencak Silat

Dalam pencak silat, ada banyak sekali macam-macam gerakan, mulai dari teknik dasar sampai teknik lanjutan yang hanya diketahui oleh pesilat tingkat pendekar. Banyaknya gerakan diperlukan karena saat bertanding, diperlukan gerakan yang terencana, terarah, terkoordinasi, dan terkendali, untuk dapat mengalahkan lawan [11]. Perguruan-perguruan pencak silat dapat mengembangkan sendiri gerakan pencak silat selama tidak meninggalkan ciri-ciri khusus dari pencak silat. Pengembangan gerakan pencak silat dilakukan agar bisa mengungguli lawannya saat pertandingan. Setiap perguruan bisa mempunyai gerakan khas, terutama untuk gerakan Teknik serangan, baik tangan maupun kaki. Bahkan beberapa perguruan mempunyai teknik rahasia yang hanya diketahui oleh anggota perguruan tingkat pendekar [10]. Tetapi untuk pemula biasanya mempelajari Teknik dasar yang cenderung sama di banyak perguruan.

Beberapa teknik dasar pencak silat, antara lain Teknik kuda-kuda, Teknik pukulan dasar, Teknik tangkisan, Teknik guntingan, Teknik arah, Teknik tendangan, dan Teknik pola langkah. Masing masing Teknik juga memiliki jenis yang berbeda-beda. Seperti Teknik tendangan, ada Teknik tendangan lurus atau depan, Teknik tendangan sabit atau melingkar, dan Teknik tendangan T. Selain Teknik dasar, ada gerakan lain yang harus dipelajari pesilat pemula yaitu sikap dasar. Sikap dasar pencak silat adalah gerakan-gerakan statis yang dilakukan sebelum melakukan gerakan-gerakan dinamis. Tujuannya adalah untuk melatih otot tungkai dan kaki saat melakukan gerakan dinamis. Beberapa sikap dasar

pencak silat antara lain sikap berdiri, sikap pasang, sikap jongkok, sikap duduk, sikap berbaring, dan sikap khusus.

2.4 Pose estimation

Pose estimation atau estimasi pose adalah salah satu fungsi dari *Machine Learning* (ML) yang digunakan untuk memperkirakan pose seseorang dari gambar atau video dengan memperkirakan lokasi spasial dari sendi tubuh utama (*keypoint*) [12]. Misalnya pada sebuah gambar yang terdapat manusia di dalamnya, dengan pose estimasi, kita dapat menentukan dimana letak siku pada gambar tersebut. Begitu juga dengan *keypoint* yang lain, kita dapat mengetahui letak masing-masing *keypoint* pada gambar tersebut. Tetapi estimasi pose yang dihasilkan hanya perkiraan letak sendi tubuh, tidak dapat mengenali siapa yang ada dalam gambar tersebut. Titik kunci yang terdeteksi diindeks oleh ID bagian, dengan skor kepercayaan antara 0,0 dan 1,0. Skor kepercayaan menunjukkan probabilitas bahwa titik kunci ada di posisi itu.

Kami menyediakan implementasi referensi dari dua model estimasi pose TensorFlow Lite: MoveNet: model estimasi pose canggih yang tersedia dalam dua rasa: Pencahayaan dan Petir. Lihat perbandingan antara keduanya di bagian di bawah ini. PoseNet: model perkiraan pose generasi sebelumnya yang dirilis pada 2017.

2.4.1 PoseNet

PoseNet adalah model *tensorflow* dengan *deep learning* yang digunakan untuk estimasi pose. PoseNet merupakan *pre-trained* model yang dilatih dalam arsitektur *mobile-net*. *Mobile-net* sendiri merupakan *Convolutional Neural Network* (CNN) yang fungsi utamanya adalah untuk klasifikasi gambar dan estimasi target menggunakan skor kepercayaan. PoseNet menggunakan 17 *keypoints* mulai dari mata, hidung, telinga, bahu, siku, tangan, lutut, sampai kaki. *Keypoints* pada PoseNet ditunjukkan pada gambar 2.1.



Gambar 2.1 : Keypoint pada *Body Pose* PoseNet [13]

Keistimewaan dari PoseNet yaitu PoseNet menggunakan konvolusi yang dapat dipisahkan secara mendalam, sehingga mengurangi parameter dan beban komputasi yang kemudian akan dapat meningkatkan akurasi model. Dengan demikian, PoseNet menjadi model yang ringan yang dapat dijalankan di browser. Hal ini menyebabkan PoseNet terpisah dengan *library* lain yang bergantung pada API, sehingga model ini dapat digunakan oleh siapa saja meskipun memiliki laptop dengan konfigurasi yang terbatas.

2.4.2 MoveNet

MoveNet merupakan model deteksi pose yang diluncurkan setelah PoseNet. MoveNet menggunakan API deteksi pose di TensorFlow.js. MoveNet adalah model ultra cepat dan akurat untuk deteksi pose jika dibandingkan dengan PoseNet. [15] Ada dua varian MoveNet, yaitu Lightning dan Thunder. Lightning ditujukan untuk aplikasi yang membutuhkan kecepatan tinggi, sedangkan Thunder ditujukan untuk aplikasi yang membutuhkan akurasi tinggi. Kedua model bekerja


lebih cepat daripada *realtime* (30+ FPS) di sebagian besar desktop, laptop, dan ponsel modern. MoveNet penting untuk perancangan aplikasi seperti kesehatan dan olahraga yang bersifat *live*. Aplikasi tersebut dijalankan oleh pengguna tanpa ada server.

Keypoint pada *body pose* yang dihasilkan MoveNet sama dengan *keypoint* pada *body pose* yang dihasilkan PoseNet, yaitu 17 *keypoint*. Kelebihan MoveNet terutama pada kecepatannya dan dapat digunakan di mana saja sehingga dapat digunakan di banyak aplikasi. MoveNet digunakan untuk merancang dan mengoptimalkan model yang memanfaatkan aspek terbaik dari arsitektur canggih, sekaligus menjaga waktu inferensi serendah mungkin. Hasilnya adalah model yang dapat memberikan *keypoint* yang akurat di berbagai macam pose, lingkungan, dan pengaturan *hardware*.

Gambar 2.2 merupakan gambar arsitektur MoveNet. Arsitektur MoveNet terdiri dari dua komponen, yaitu ekstraktor fitur dan satu set *prediction heads*. Ekstraktor fitur yang digunakan yaitu MobileNetV2 dengan *Feature Pyramid Network* (FPN) yang terpasang. Model ini memungkinkan untuk resolusi tinggi dengan output stride 4 dan fitur yang lebih banyak. Gambar arsitektur MoveNet ditampilkan pada gambar 2.2.

Satu set *prediction heads* terdiri dari empat buah *prediction head* yang terpasang pada ekstraktor fitur, antara lain:

- a. Person Center Heatmap : memprediksi pusat geometris tubuh seorang manusia
- b. Keypoint Regression Field: memprediksi satu set *keypoints* tubuh, digunakan untuk mengelompokkan *keypoints* menjadi seorang manusia.
- c. Person Keypoint Heatmap: memprediksi semua lokasi *keypoints*, terlepas dari bentuk seorang manusia
- d. 2D per-keypoint offset field: memprediksi offset lokal dari setiap piksel *feature map* ke lokasi subpiksel yang tepat dari setiap *keypoint*.



Gambar 2.2. Arsitektur MoveNet [15]

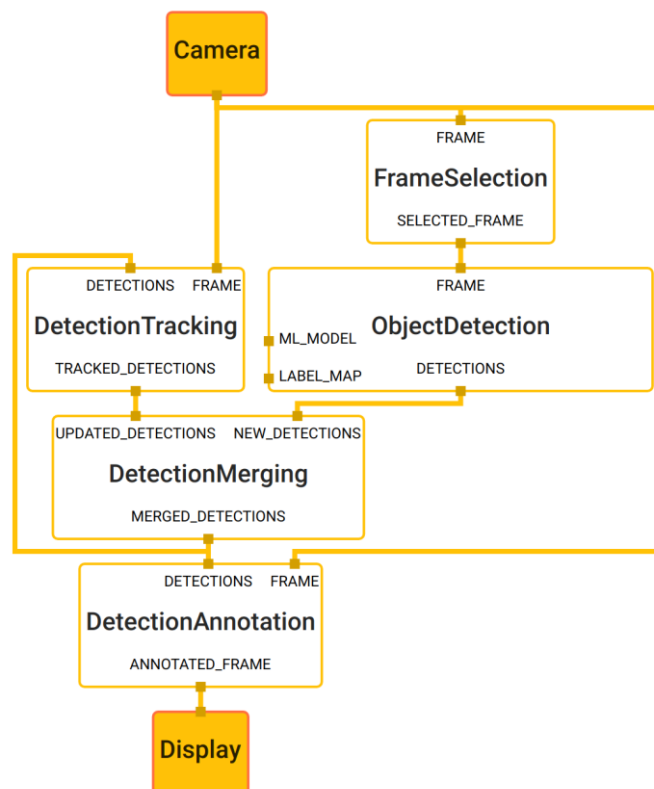
2.4.3 MediaPipe

MediaPipe merupakan sebuah *framework* untuk membangun suatu aliran persepsi untuk membuat kesimpulan dari data sensory yang berubah-ubah [15]. Aliran persepsi yang dimaksud seperti grafik modular komponen, termasuk model inferensi, algoritma pemrosesan media, dan transformasi data. Data sensori yang dimaksud yaitu seperti audio, video, ataupun deskripsi tentang lokalisasi atau landmark suatu objek. MediaPipe didesain untuk praktisi *Machine Learning* (ML), termasuk peneliti, siswa, pengembang software, yang mengimplementasikan aplikasi produk ML.

Kelebihan dari MediaPipe dapat diaplikasikan pada berbagai *platform*. Caranya dengan mengabstraksi dan menghubungkan model persepsi individu ke dalam alur yang dapat dipertahankan. Semua langkah yang diperlukan untuk menyimpulkan dari data sensorik dan mendapatkan hasil yang dirasakan ditentukan dalam konfigurasi pipa. Sangat mudah untuk menggunakan kembali komponen MediaPipe dalam pipeline yang berbeda di seluruh aplikasi yang berurutan karena komponen ini berbagi antarmuka umum yang berorientasi pada data deret waktu. Setiap pipeline kemudian dapat dijalankan dengan perilaku yang sama di berbagai platform, memungkinkan praktisi untuk mengembangkan aplikasi di workstation, dan kemudian menerapkannya di ponsel, misalnya.


Arsitektur MediaPipe memungkinkan pengembang membuat prototipe dari sebuah *pipeline* secara bertahap. *Pipeline* sendiri merupakan grafik yang terarah dari komponen-komponen di dalam arsitektur. Semua komponen di dalam arsitektur adalah *calculator*. Grafik ditentukan menggunakan buffer protokol *GraphConfig* dan kemudian dijalankan menggunakan *objek Grafik*. Dalam grafik, kalkulator dihubungkan oleh *data streams*. Setiap *streams* mewakili rangkaian waktu dari *packet data*. Bersama-sama, kalkulator dan aliran menentukan grafik aliran data. Paket-paket yang mengalir melintasi grafik disusun berdasarkan stempel waktunya dalam deret waktu.

Pipeline dapat disempurnakan secara bertahap dengan memasukkan atau mengganti *calculator* di manapun dalam grafik. Pengembang juga dapat menentukan *calculator* khusus. Karena grafik mengeksekusi kalkulator secara paralel, maka *calculator* mengeksekusi paling banyak satu utas dalam satu waktu. Hal ini juga ditambah dengan paket data yang tidak dapat diubah, sehingga memastikan bahwa *calculator* khusus dapat ditentukan tanpa keahlian khusus dalam pemrograman multithreaded.



Gambar 2.3 Deteksi objek menggunakan MediaPipe

Gambar 2.3 menunjukkan bagaimana *calculator* dalam MediaPipe bekerja secara mandiri dan dihubungkan oleh aliran stream. Aliran stream yang bercabang menunjukkan MediaPipe mampu menjalankan beberapa *calculator* secara bersamaan. Ketika data dari kamera masuk, maka akan dilakukan *detection tracking* dan *frame selection*. Setelah *frame selection*, dilanjutkan dengan *object detection*. Setelah itu, hasil *object detection* dan *detection tracking* akan digabungkan dengan *detection merging*. Hasil dari *detection merging* digunakan kembali ke dalam *detection tracking* sebagai data temporal dan digunakan untuk *detection annotating* Bersama dengan gambar asli dari kamera. Hasil inilah yang akan ditampilkan pada *display*.



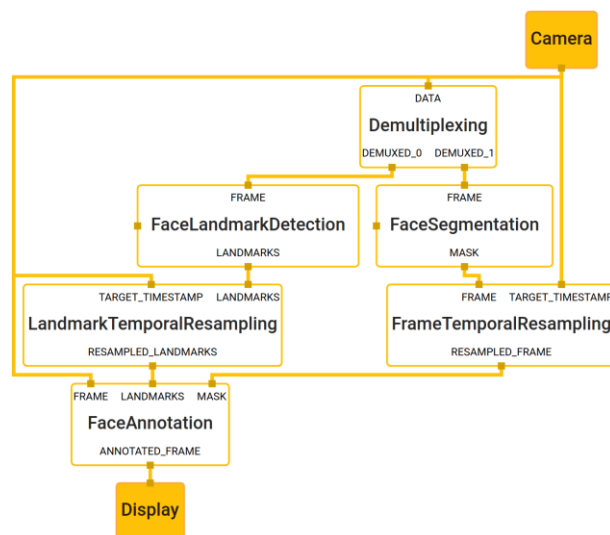
- | | | |
|-----------------------|---------------------|-----------------------|
| 0 - nose | 11 - left shoulder | 22 - right thumb |
| 1 - left eye (inner) | 12 - right shoulder | 23 - left hip |
| 2 - left eye | 13 - left elbow | 24 - right hip |
| 3 - left eye (outer) | 14 - right elbow | 25 - left knee |
| 4 - right eye (inner) | 15 - left wrist | 26 - right knee |
| 5 - right eye | 16 - right wrist | 27 - left ankle |
| 6 - right eye (outer) | 17 - left pinky | 28 - right ankle |
| 7 - left ear | 18 - right pinky | 29 - left heel |
| 8 - right ear | 19 - left index | 30 - right heel |
| 9 - mouth (left) | 20 - right index | 31 - left foot index |
| 10 - mouth (right) | 21 - left thumb | 32 - right foot index |

Gambar 2.4 Keypoint pada *body pose* MediaPipe [17]

Beberapa *pipeline* yang telah dibangun menggunakan MediaPipe, antara lain deteksi objek, *box tracking*, deteksi wajah, *face mesh*, deteksi tangan, deteksi pose, deteksi iris, *selfie segmentation*, *hair segmentation*. Pada penelitian ini, MediaPipe digunakan untuk deteksi pose. Pose tubuh manusia yang dihasilkan MediaPipe memiliki 33 *keypoint*. Gambar 2.4 menunjukkan jumlah dan posisi *keypoint* pada *bodypose* MediaPipe. Jumlah *keypoint* pada *body pose* MediaPipe lebih banyak daripada jumlah *keypoint* pada *body pose* PoseNet maupun MoveNet. Perbedaannya pada *keypoint* di daerah wajah dan telapak tangan dan telapak kaki.

Proses kerja MediaPipe saat melakukan *bodypose estimation* digambarkan pada gambar 2.5. MediaPipe melakukan deteksi landmark body pose bersama dengan segmentasi mask. Kedua tugas tersebut dikerjakan secara bersamaan pada dua subset frame yang terpisah dengan menggunakan node demultiplexing. Node demultiplexing akan membagi paket-paket dalam aliran input menjadi subset interleaving, kemudian setiap subset akan masuk ke aliran output yang terpisah.

Deteksi landmark dan segmentasi masing-masing akan diinterpolasi secara temporer untuk mendapatkan landmark dan mask pada semua frame. Timestamps target untuk interpolasi sesuai dengan frame yang masuk. Terakhir, untuk visualisasi, hasil dari dua tugas tersebut akan digabungkan dengan kamera frame sehingga menjadi 3 buah streams. Ketiga stream tersebut disinkronisasikan dengan input policy pada annotation node dan hasilnya ditampilkan pada display.



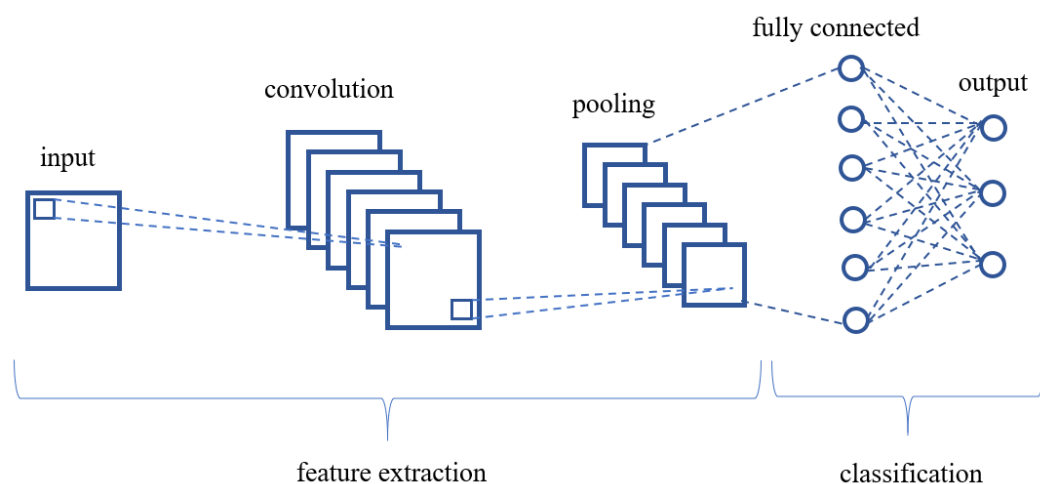
Gambar 2.5 Deteksi Landmark Wajah dan Segmentasi menggunakan MediaPipe

[16]

2.5 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN digunakan untuk mengklasifikasi data yang terlabel dengan menggunakan metode *supervised learning*. Cara kerja dari *supervised learning* adalah terdapat data yang dilatih dan terdapat variabel yang ditargetkan sehingga tujuan dari metode ini adalah mengelompokkan suatu data ke data yang sudah ada.

Lapisan-lapisan CNN memiliki susunan *neuron* 3 dimensi (lebar, tinggi, kedalaman). Lebar dan tinggi merupakan ukuran lapisan sedangkan kedalaman mengacu pada jumlah lapisan. Sebuah CNN dapat memiliki puluhan hingga ratusan lapisan yang masing-masing belajar mendeteksi berbagai gambar. Pengolahan citra diterapkan pada setiap citra latih pada resolusi yang berbeda, dan output dari masing-masing gambar yang diolah dan digunakan sebagai input ke lapisan berikutnya.



Gambar 2.6 Arsitektur CNN

2.5.1 Convolutional Layer


Convolutional *layer* terdiri dari *neuron* yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (piksel) Sebagai contoh, *layer* pertama pada *feature extraction layer* adalah *convolutional layer* dengan ukuran 5x5x3. Panjang 5 piksel, tinggi 5 piksel, dan tebal/jumlah 3 buah sesuai dengan channel dari gambar, misalnya gambar RGB, mempunyai 3 channel, yaitu *red*, *green*, dan *blue*.

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*.

2.5.2 Pooling Layer

Pooling layer berada setelah *convolution layer*. Pada prinsipnya *pooling layer* terdiri dari sebuah filter dengan ukuran dan *stride* tertentu yang bergeser pada seluruh area *feature map*. Pooling yang biasa digunakan adalah *Max Pooling* dan *Average Pooling*. Tujuan dari penggunaan *pooling layer* adalah mengurangi dimensi dari *feature map* (*downsampling*), sehingga mempercepat komputasi karena parameter yang harus di *update* semakin sedikit dan mengatasi *overfitting*.

Hal terpenting dalam pembuatan model CNN adalah dengan memilih banyak jenis lapisan *pooling*. Hal ini dapat menguntungkan kinerja model. Lapisan *pooling* bekerja di setiap tumpukan *feature map* dan mengurangi ukurannya. Bentuk lapisan *pooling* yang paling umum adalah dengan menggunakan filter berukuran 2x2 yang diaplikasikan dengan langkah sebanyak 2 dan kemudian beroperasi pada setiap irisan dari *input*. Bentuk seperti ini akan mengurangi *feature map* hingga 0,75 dari ukuran aslinya. Berikut gambar contoh operasi *Max Pooling*:



Gambar 2.6 Contoh Operasi *Max Pooling* [25]

Lapisan *pooling* akan beroperasi pada setiap irisan kedalaman volume *input* secara bergantian. Pada gambar di atas, menunjukkan ukuran *input* 4x4, kemudian dilakukan operasi maksimal dengan filter 2x2 dan stride 2, sehingga membuat ukuran *output* baru menjadi 2x2.

2.5.3 Fully Connected Layer

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

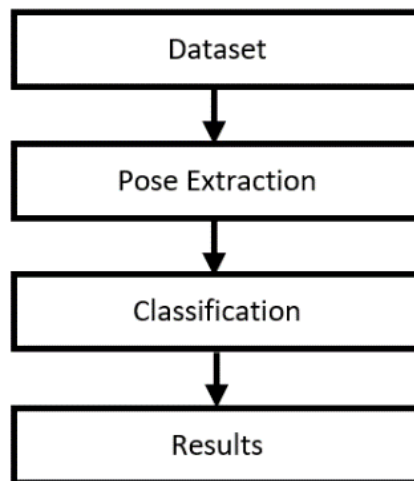
Fully Connected Layer adalah lapisan dimana semua *neuron* aktivitas dari lapisan sebelumnya terhubung semua dengan *neuron* di lapisan selanjutnya. Setiap aktivitas dari lapisan sebelumnya perlu diubah menjadi data satu dimensi sebelum dapat dihubungkan ke semua *neuron* di *Fully Connected Layer*.

Fully Connected Layer biasanya digunakan pada metode *multi layer perceptron* dan bertujuan untuk mengolah data sehingga bisa diklasifikasikan. Perbedaan anatar *Fully Connected Layer* dan lapisan konvolusi biasa adalah *neuron* di lapisan konvolusi terhubung hanya ke daerah tertentu pada *input*. Sementara *Fully Connected Layer* memiliki *neuron* yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoprasikan produk *dot*, sehingga fungsinya tidak begitu berbeda.

BAB 3

METODE PENELITIAN

Kerangka penelitian yang diusulkan untuk mengklasifikasikan gerakan pencak silat diilustrasikan pada Gambar 3.1. Metode ini terdiri dari 4 tahap, yaitu dataset, ekstraksi pose, klasifikasi, dan hasil.



Gambar 3.1 : Blok Diagram Penelitian

3.1 Dataset

Dataset yang digunakan untuk penelitian ini berupa video gerak. Video tersebut diambil secara langsung dan belum pernah digunakan untuk penelitian apapun. Partisipan dataset penelitian ini adalah anak-anak peserta ekstrakurikuler pencak silat di SD Cemandi. Proses pengumpulan dataset diawasi oleh seorang coach. Ini dilakukan dengan maksud untuk memastikan bahwa gerakannya benar. Video diambil dari depan peserta. Kamera dianggap sebagai lawan dan tendangan diarahkan ke kamera. Jarak peserta dengan kamera 2 meter dan tinggi kamera 85 cm. Frame video menampilkan seluruh tubuh peserta, mulai dari kepala, badan, tangan, hingga kaki. Durasi video tidak sama, tergantung pergerakan. Satu video dimulai dengan kedua kaki menapak di tanah, kemudian menendang, hingga

kembali ke posisi awal, di mana kedua kaki menapak di tanah. Dibutuhkan sekitar 1 sampai 2 detik.

Ada tiga gerakan yang akan diklasifikasikan dalam penelitian ini, yaitu tendangan lurus, tendangan melingkar, dan tendangan T. Jumlah total dataset yang digunakan dalam penelitian ini adalah 330 sampel dari ketiga kelas. Setiap kelas memiliki 110 sampel. Kemudian data tersebut dibagi menjadi tiga jenis data, yaitu data latih, data validasi, dan data uji. Data latih berisi 80 sampel, data validasi berisi 10 sampel, dan data uji berisi 20 sampel.

3.2 Ekstraksi Pose

Dataset akan diproses menggunakan ekstraksi pose. Ekstraksi pose mendapatkan pose tubuh manusia yang diartikulasikan, yang terdiri dari persendian dan bagian kaku menggunakan observasi berbasis citra [10]. Letak sendi-sendi tubuh manusia itu diperkirakan, kemudian diberi penanda yang disebut keypoint. Keypoint akan dihubungkan dengan garis sedemikian rupa sehingga terbentuklah pose tubuh manusia. Kemudian, gambar aslinya akan dihapus dan hanya pose tubuh yang tersisa. Letak keypoint akan berubah sesuai pergerakan, sehingga dapat dipelajari oleh CNN untuk proses klasifikasi.

Penelitian ini menggunakan MediaPipe untuk proses ekstraksi pose karena MediaPipe memberikan akurasi estimasi yang paling baik [7]. MediaPipe adalah kerangka kerja untuk membangun saluran pipa untuk melakukan inferensi atas data sensorik arbitrer. Kemudian pipeline dapat dibangun sebagai grafik komponen modular, termasuk inferensi model, algoritme pemrosesan media, dan transformasi data, dll [11]. Untuk ekstraksi pose, data sensori yang digunakan adalah video kemudian diekstraksi 33 landmark/keypoint pada tubuh manusia seperti pada gambar 2. Diantara 33 keypoint MediaPipe tersebut, penelitian ini menggunakan semua keypoint, karena pada saat melakukan gerakan, posisi dari semua titik kunci dipindahkan atau diubah.

3.3 Klasifikasi

Langkah selanjutnya adalah klasifikasi. Penelitian ini menggunakan model CNN untuk melakukan klasifikasi karena memiliki kemampuan untuk secara otomatis mengekstraksi pola dan representasi dari citra masukan dengan hasil yang lebih akurat [13-16]. CNN merupakan pengembangan arsitektur dari MLP (Multi-Layer Perceptron). Ini memiliki jaringan yang dalam yang terdiri dari beberapa lapisan. Jenis CNN yang umum digunakan, yang mirip dengan multi-layer perceptron (MLP), terdiri dari banyak lapisan konvolusi sebelum lapisan sub-sampling (pooling), sedangkan lapisan akhir adalah lapisan FC [17].

Untuk melakukan klasifikasi pada sekumpulan urutan gambar, diperlukan suatu metode untuk menggabungkan seluruh hasil klasifikasi. Jika klasifikasi dilakukan pada setiap frame secara terpisah, maka model tidak bisa melihat keseluruhan video, dan menyebabkan hasil prediksi berubah secara cepat dan fluktuatif. Pada penelitian yang dilakukan oleh Aruna mengenai *Human Activity Recognition using Single Frame CNN*, dilakukan *moving average* untuk mendapatkan hasil klasifikasi akhir, dan mendapatkan akurasi sebesar 95%. [26] *Moving average* adalah rata-rata dari seluruh hasil prediksi pada setiap frame. Metode ini mengambil frame-frame dari video dan membuat prediksi sesuai dengan aktivitas pada training model. Kemudian prediksi-prediksi tersebut dirata-rata dan hasil akhir output diberi label sesuai dengan hasil rata-rata prediksi. Perhitungan *moving average* menggunakan persamaan 3.1 [26]:

$$P_f = \frac{\sum_{i=-n+1}^0 P_i}{n} \quad (3.1)$$

P_f = hasil akhir prediksi

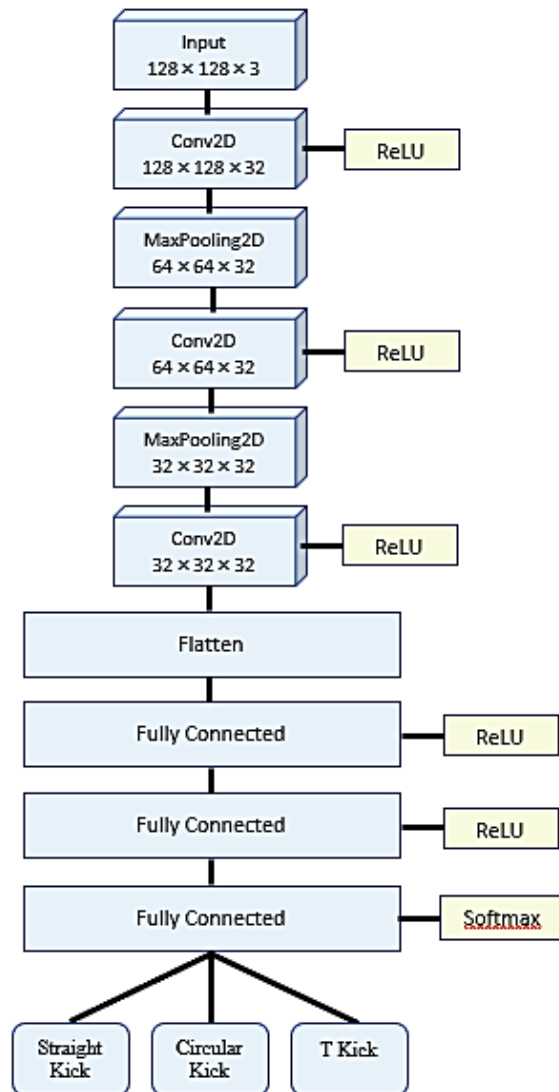
n = jumlah frame

P = hasil prediksi waktu sekarang

P_{-1} = hasil prediksi sebelumnya

P_{-2} = hasil prediksi kedua sebelumnya

P_{-n+1} = hasil prediksi pada satu frame sebelum frame terakhir



Gambar 3.2 Model CNN

Model CNN yang digunakan dalam penelitian ini terdiri dari tiga lapisan konvolusi dan dua lapisan terhubung penuh. Citra dataset berukuran 128×128 dengan tiga layer diproses menggunakan convolution layer dengan 32 filter, kernel berukuran 3×3 , dan fungsi aktivasi ReLU. Kemudian diproses dengan max pooling layer dengan pool size 2×2 . Setelah itu diproses menggunakan convolution layer dengan 32 filter, kernel berukuran 3×3 , dan fungsi aktivasi ReLU, kemudian max pooling layer dengan pool size 2×2 . Sebelum masuk ke lapisan yang terhubung sepenuhnya, diproses menggunakan lapisan konvolusi dengan 32 filter, ukuran

kernel 3×3 , dan fungsi aktivasi ReLU lagi. Output dari convolutional layer kemudian diratakan menjadi satu dimensi. Setelah menjadi satu dimensi, ia masuk ke lapisan yang terhubung penuh dengan fungsi aktivasi ReLU dua kali, lalu sampai di lapisan keluaran dengan fungsi aktivasi softmax. Output terakhir tergantung pada jumlah kelas dalam dataset, dalam penelitian ini ada tiga, yaitu tendangan lurus, tendangan melingkar, dan tendangan t. Model CNN ditunjukkan pada gambar 3.2.

Halaman ini sengaja dikosongkan

BAB 4

HASIL DAN PEMBAHASAN

Penelitian ini, dilakukan untuk mengembangkan sebuah metode untuk mengklasifikasi gerakan pencak silat. Gerakan yang ingin diklasifikasikan ada 3, yaitu tendangan lurus, tendangan melingkar, dan tendangan T. Langkah-langkah yang dilakukan yaitu, pertama, pengumpulan dataset. Dataset yang digunakan dalam penelitian ini berupa video gerakan pencak silat yang diambil atau direkam langsung oleh peneliti. Model untuk dataset penelitian ini adalah siswa anggota ekstrakurikuler pencak silat SDN Cemandi. Jumlah siswa sebanyak 11 anak dari kelas 4 dan 5. Setiap anak melakukan 3 gerakan, diulang sebanyak 10 kali, sehingga diperoleh 330 video. Variabel yang dikontrol dalam penelitian ini yaitu tempat atau latar belakang video, pencahayaan, sudut pengambilan video, jarak antara model dan kamera, dan ketinggian kamera.


Setelah dataset terkumpul, selanjutnya dilakukan *pose extraction*. *Pose extraction* dilakukan menggunakan MediaPipe, berdasarkan beberapa penelitian, MediaPipe memberikan akurasi estimasi pose yang terbaik. *Body pose* yang dihasilkan MediaPipe memiliki 33 *keypoint*. Penelitian ini menggunakan seluruh 33 *keypoint* tersebut karena ketika model bergerak, maka seluruh *keypoint* juga ikut bergerak.

Setelah terbentuk *body pose*, selanjutnya dilakukan klasifikasi. Klasifikasi dilakukan menggunakan Convolutional Neural Network (CNN) karena CNN bisa mengekstraksi fitur secara otomatis dan memberikan hasil yang lebih akurat. Sebelum digunakan untuk klasifikasi, model arsitektur CNN terlebih dahulu melalui proses *training*. Model di-*training* menggunakan data *training* untuk menghasilkan model CNN yang terlatih. Setelah CNN berhasil dilatih, barulah dapat digunakan untuk proses *testing*. Proses *testing* dilakukan menggunakan data *testing*, data yang belum pernah digunakan sebelumnya. Hasil dari proses *testing* yang akan dinilai sebagai hasil akurasi dari sistem.

4.1 Dataset

Dataset yang digunakan dalam penelitian ini berupa video gerakan pencak silat yang diambil atau direkam langsung oleh peneliti. Model untuk dataset penelitian ini adalah siswa anggota ekstrakurikuler pencak silat SDN Cemandi. Jumlah siswa sebanyak 11 anak dari kelas 4 dan 5. Setiap anak melakukan 3 gerakan, diulang sebanyak 10 kali, sehingga diperoleh 330 video. Variabel yang dikontrol dalam penelitian ini yaitu tempat atau latar belakang video, pencahayaan, sudut pengambilan video, jarak antara model dan kamera, dan ketinggian kamera.


Pengambilan video dilakukan di tempat parkir sepeda SDN Cemandi pada waktu siang hari. Tempat parkir tersebut memiliki atap, dan dindingnya hanya ada di sebelah belakang saja. Dinding tersebut sebagai latar belakang dari video data set untuk penelitian ini. Hal tersebut membuat proses pengambilan video tidak terkena matahari langsung, tetapi mendapatkan cukup pencahayaan. Video diambil menggunakan kamera dengan tripod. Jarak antara model dan tripod adalah 2 meter dan ketinggian tripod 85 cm. *Angle* yang digunakan yaitu dari arah depan model, kamera berada pada posisi lawan tanding.



(a)



(b)



(c)


Gambar 4.1 Contoh Gerakan dari $t=1$ sampai $t=n$, untuk (a) Tendangan Lurus, (b) Tendangan Melingkar, (c) Tendangan T

Gambar 4.1 menunjukkan contoh gerakan dari awal gerakan ($t=1$) sampai akhir gerakan ($t=n$). Dalam satu frame video, menampilkan seluruh tubuh dari model, mulai dari kepala, badan, tangan, sampai kaki. Satu video memiliki panjang yang tidak sama, tergantung dari gerakan yang dilakukan. Satu video dimulai dari posisi awal ketika kedua kaki masih berada di tanah ($t=1$), kemudian melakukan tendangan, dan kembali lagi ke posisi awal ($t=n$). Panjang satu video sekitar satu sampai dua detik.


Dataset yang diperoleh berjumlah 330 video untuk 3 gerakan. Masing-masing berjumlah 110 untuk gerakan tendangan lurus, 110 untuk tendangan melingkar, dan 110 untuk tendangan T. Kemudian data tersebut dibagi menjadi 3, yaitu data *training*, data validasi, dan data *testing*. Pembagian data pada masing-masing gerakan adalah sama. Dari 110 video, 80 digunakan sebagai data *training*, 10 sebagai data validasi, dan 20 sebagai data *testing*.

4.2 Pose Extraction


Pada penelitian ini, *pose extraction* dilakukan menggunakan MediaPipe. Berdasarkan beberapa penelitian, MediaPipe memberikan akurasi estimasi pose yang terbaik. *Body pose* yang dihasilkan MediaPipe memiliki 33 *keypoint*. Penelitian ini menggunakan seluruh 33 *keypoint* tersebut karena ketika model bergerak, maka seluruh *keypoint* juga ikut bergerak.



(a)



(b)

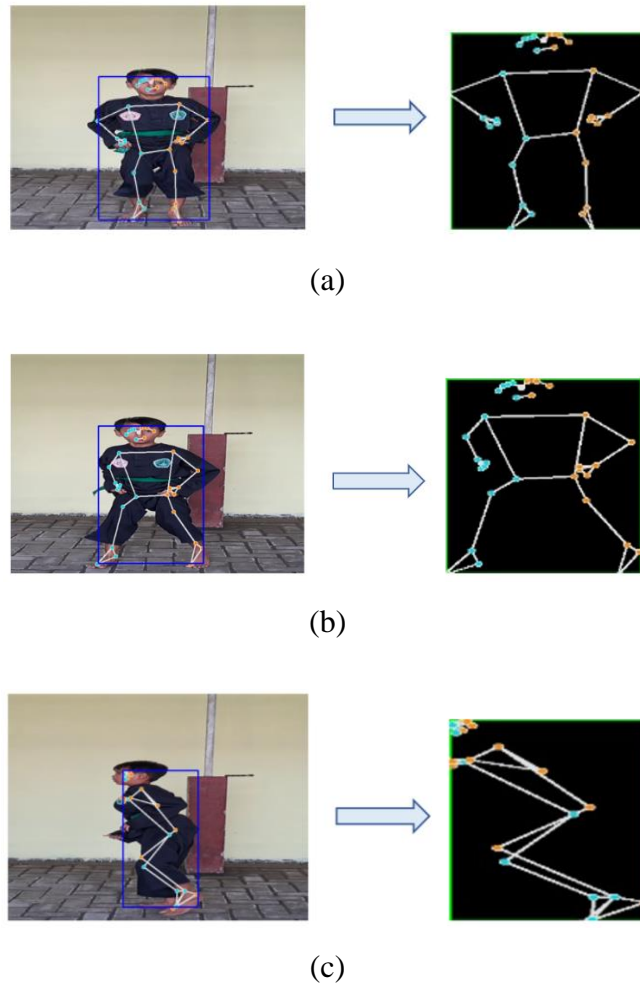


(c)

Gambar 4.2 Hasil Ekstraksi Pose dari $t=1$ sampai $t=n$, untuk (a) Tendangan Lurus, (b) Tendangan Melingkar, (c) Tendangan T

Gambar 4.3 menunjukkan hasil ekstraksi pose pada awal gerakan. Untuk tendangan lurus dan tendangan melingkar, semua *keypoint* pada *body pose* dapat terdeteksi dengan baik. Tetapi untuk tendangan T, beberapa *keypoint* tidak dapat terdeteksi. Pada Gambar 4.3(c), responden menendang dengan kaki kiri, *keypoint* kaki kanan tidak berada di tempat yang seharusnya, selain itu, *keypoint* pada tangan tidak dapat terdeteksi.

Hal ini terjadi karena, ketika melakukan tendangan lurus dan tendangan melingkar, posisi model menghadap ke depan atau ke arah kamera. Tetapi ketika melakukan tendangan T, posisi model menghadap ke arah samping. Ketika menghadap samping, posisi tubuh bagian kiri dan tubuh bagian kanan akan berada pada sumbu x dan y yang sama, sehingga beberapa *keypoint* akan berhimpitan dan sulit terdeteksi.

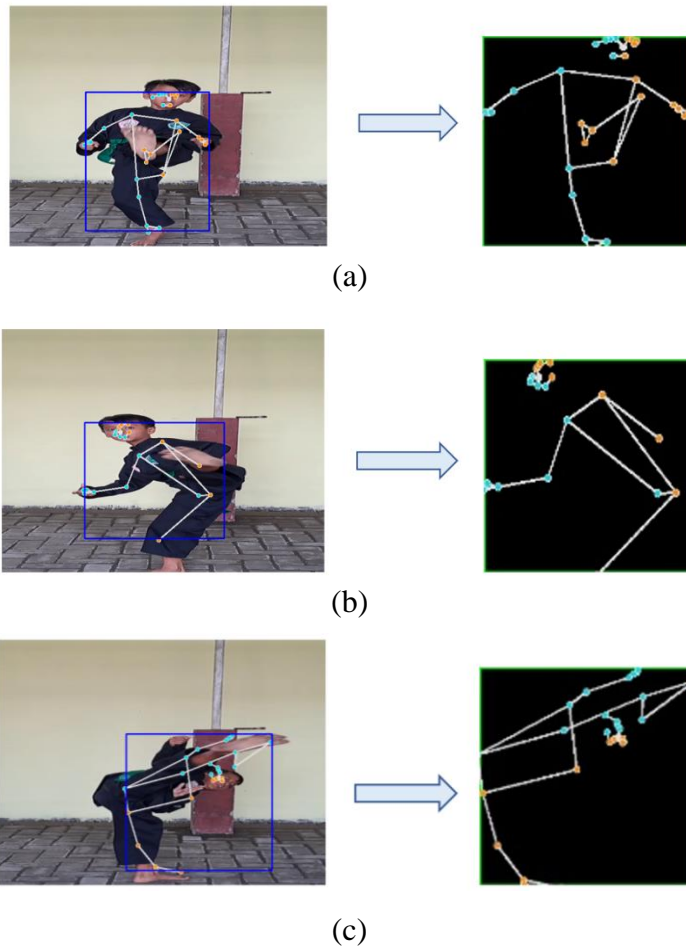


Gambar 4.3 Hasil Pose Ekstraksi di Awal Gerakan (a) Tendangan Lurus (b) Tendangan Melingkar, (c) Tendangan T

Pada puncak gerakan, ketika salah satu kaki (kaki yang digunakan untuk menyerang) berada pada posisi dekat dengan lawan (kamera), *keypoint* pada *body pose* juga tidak dapat terdeteksi dengan baik. Beberapa *keypoint* saling berhimpitan, saling tertukar, dan ada beberapa *keypoint* tidak dapat terdeteksi. Pada hasil ekstraksi pose di Gambar 4.4, untuk Tendangan Lurus (Gambar 4.3(a)), *keypoint* pada *body pose* dapat terdeteksi dengan baik, begitu juga untuk Tendangan T (Gambar 4.4 (c)) *keypoint* pada kaki dapat terdeteksi dengan baik, meskipun *keypoint* pada bagian lain tidak dapat terdeteksi dengan baik.

Hal ini terjadi karena pada saat kaki dalam posisi menyerang dan dekat dengan lawan maka posisi bagian tubuh lainnya akan bergerak sesuai pusat

gravitasi tubuh agar dapat tetap seimbang sehingga menyebabkan posisi *keypoint* kaki berada pada posisi sumbu x dan sumbu y yang sama dengan bagian tubuh lain sehingga membuat beberapa *keypoint* saling tumpang tindih.




Gambar 4.4 Hasil Pose Ekstraksi di Puncak Gerakan (a) Tendangan Lurus (b) Tendangan Melingkar, (c) Tendangan T

Ekstraksi pose dapat memiliki kinerja yang lebih baik dengan menambahkan variasi sudut pengambilan video sehingga *keypoint* dapat didistribusikan secara merata ke seluruh sumbu x dan pose tubuh dapat dideteksi dengan baik. Selain itu, kita dapat mengurangi jumlah *keypoint* yang digunakan. Ada beberapa *keypoint* yang bisa tidak digunakan, seperti *keypoint* di wajah, yaitu nomor 1 - 10, dan jari tangan, nomor 19 - 22 . Jika *keypoint* semakin sedikit, maka kemungkinan terjadinya *overlapping keypoint* juga akan semakin kecil.

4.3 Klasifikasi

Body pose yang sudah terbentuk dari hasil ekstraksi pose digunakan untuk proses klasifikasi. Pada penelitian ini, proses klasifikasi dilakukan menggunakan Convolutional Neural Network (CNN). Proses klasifikasi diawali dengan training. Training dilakukan menggunakan model arsitektur CNN seperti yang telah dijelaskan pada bab 3. Training dilakukan menggunakan data training.

Jumlah iterasi yang diperlukan sebanyak 10 iterasi. Jumlah iterasi ini ditentukan berdasarkan hasil training yang dicapai oleh model. Pada iterasi pertama, model CNN mendapatkan akurasi sebesar 0,60. Pada iterasi kedua mendapatkan akurasi sebesar 0,83 dan terus meningkat sampai pada iterasi ke-9. Pada iterasi ke-9, akurasi yang dihasilkan sebesar 0,99. Tetapi pada iterasi ke-10, akurasi menurun menjadi 0,98. Oleh karena itu, proses training dihentikan pada iterasi ke-10 agar tidak terjadi *overfitting*. Proses training bias dilihat pada gambar 4.4.

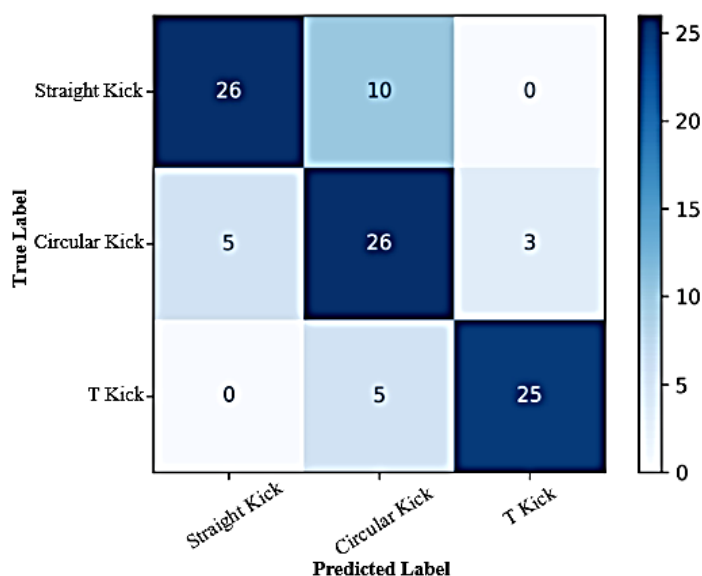


Gambar 4.5 *Loss Model* dari Proses Training

Model arsitektur CNN yang sudah ditraining akan diuji menggunakan data testing. Data testing adalah data baru yang belum pernah digunakan dalam proses sebelumnya. Hasil yang diperoleh dapat dilihat pada *confusion matrix* pada gambar

4.5. Dari 100 data testing, 77 diklasifikasi dengan benar, dan 33 diklasifikasi dengan salah, sehingga akurasi keseluruhan adalah 77%.

Untuk tendangan lurus, data yang diuji sebanyak 36. Hasilnya 26 benar dan 10 salah diklasifikasikan sebagai tendangan melingkar. Untuk tendangan T, data yang diuji sebanyak 30. Hasilnya 25 benar dan 5 salah diklasifikasikan sebagai tendangan melingkar. Untuk tendangan melingkar sendiri, data yang diuji sebanyak 34. Hasilnya 26 benar, 5 salah diklasifikasikan sebagai tendangan lurus, dan 3 salah diklasifikasikan sebagai tendangan T. Dari hasil tersebut, dapat dilihat bahwa semua kesalahan klasifikasi berhubungan dengan tendangan melingkar, baik tendangan melingkar yang salah diklasifikasikan sebagai tendangan lain, maupun tendangan lain yang salah diklasifikasikan sebagai tendangan melingkar.



Gambar 4.6. *Confusion Matrix*

Semua kesalahan klasifikasi berhubungan dengan tendangan melingkar karena *body pose* dari tendangan melingkar tidak dapat diekstraksi dengan baik. Pada hasil ekstraksi pose, dapat dilihat bahwa pada saat puncak tendangan, atau pada saat kaki mendekati lawan, *keypoint* dari kaki kanan, atau kaki yang digunakan untuk menendang, tidak dapat terdeteksi. Hal ini menyebabkan *body pose* yang dihasilkan tidak dapat merepresentasikan gerakan tendangan melingkar. Sehingga model CNN tidak bisa mendapatkan fitur yang tepat dan tidak dapat belajar dengan baik.

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini mengusulkan model klasifikasi gerakan pencak silat menggunakan Convolutional Neural Network (CNN). Gerakan-gerakan yang diklasifikasikan meliputi gerakan tendangan lurus, tendangan melingkar, dan tendangan T. Penelitian ini menggunakan dataset yang berbentuk video. Video akan diproses menggunakan MediaPipe sebagai kerangka ekstraksi pose untuk mengambil pose tubuh. Penelitian ini menggunakan MediaPipe untuk proses ekstraksi pose karena MediaPipe memberikan akurasi estimasi yang paling baik. Pose tubuh kemudian digunakan untuk klasifikasi menggunakan model CNN. Model CNN digunakan karena memiliki kemampuan untuk secara otomatis mengekstraksi pola dan representasi dari input dengan hasil yang lebih akurat. Model CNN ini dapat mencapai akurasi total 77%.

5.2 Saran

Akurasi yang dihasilkan pada penelitian ini sudah baik, namun masih bisa ditingkatkan dengan merevisi ekstraksi pose. Ekstraksi pose dapat memiliki kinerja yang lebih baik dengan menambahkan variasi sudut pengambilan video sehingga *keypoint* dapat didistribusikan secara merata ke seluruh sumbu x dan pose tubuh dapat dideteksi dengan baik. Selain itu, kita dapat mengurangi jumlah *keypoint* yang digunakan. Ada beberapa *keypoint* yang bisa tidak perlu digunakan, seperti *keypoint* di wajah dan jari. Jika *keypoint* semakin sedikit, maka kemungkinan terjadinya *overlapping keypoint* juga akan semakin kecil.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- [1] Kim, J.-W.; Choi, J.-Y.; Ha, E.-J.; Choi, J.-H. Human Pose Estimation Using MediaPipe Pose and Optimization Method Based on a Humanoid Model. *Appl. Sci.* **2023**, *13*, 2700.
- [2] Bearman, A., Dong, C., “Human Pose Estimation and Activity Classification Using Convolutional Neural Networks” <http://cs231n.stanford.edu/reports/2015/pdfs/cdong-paper.pdf>
- [3] A. Gupta, K. Gupta, K. Gupta and K. Gupta, "Human Activity Recognition Using Pose Estimation and Machine Learning Algorithm," 2021 International Semantic Intelligence Conference (ISIC), New Delhi, India
- [4] Zaman, Lukman, Sampeno, dan Hariadi. (2019). Analisis Kinerja LSTM dan GRU sebagai Model Generatif untuk Tari Remo. *JNTETI*, Vol. 8, No. 2, Mei 2019
- [5] Asshidiqy, R.A., Setiawan, Sasongko. (2022). Penerapan Metode PoseNet untuk Deteksi Ketepatan Pose Yoga. *JoYSC* Vol. 4 No. 1, ISSN 2714-7150 E-ISSN 2714-8912
- [6] Upadhyay, A.; Basha, N.K.; Ananthkrishnan, B. Deep Learning-Based Yoga Posture Recognition Using the Y_PN-MSSD Model for Yoga Practitioners. *Healthcare* **2023**, *11*, 609.
- [7] Kishore DM, Bindu S, Manjunath NK. Estimation of yoga poses using machine learning techniques. *Int J Yoga* 2022;15:137-43.
- [8] Tanugraha, F.D., Pratikno, Musayyanah, dan Kusumawati. (2022). Pengenalan Gerakan Olahraga Berbasis (Long Short-Term Memory) menggunakan MediaPipe. *JAIIT (Journal of Advances in Information and Industrial Technology)* Vol. 4, No. 1 Mei 2022, ISSN 2723-4371, E-ISSN 2723-5912
- [9] Taruna, I.P.J., Fredlina, dan Sudiatmika. (2022). Pengenalan Gerakan Sikap Dasar Pencak Silat Bakti Negara Berbasis Aplikasi *Mobile* menggunakan *Neural Network*. ISSN:2477-0043 ISSN ONLINE:2460-7908.

- [10] Sudiana, I Ketut, Ni Luh Putu Sepyanawati. Keterampilan Dasar Pencak Silat. - Rajawali Pers. N.p., PT. RajaGrafindo Persada, 2021. ISBN 978-602-425-178-9
- [11] Pratama, Rendra Yulia. (2018). Perkembangan Ikatan Pencak Silat Indonesia (IPSI) Tahun 1948-1973. Avatara e-Journal Pendidikan Sejarah Vol. 6 No. 3
- [12] Mizanudin, Muhammad, Andri s., Saryanto. 2018. Pencak Silat Sebagai Hasil Budaya Indonesia yang Mendunia. E-ISSN 2599-0519. Diakses melalui :
http://simkatmawa.kemdikbud.go.id/v3/assets/upload/foto_non_lomba_061016_1560703833049502000.pdf
- [13] https://www.tensorflow.org/lite/examples/pose_estimation/overview
- [14] Pandey, Sidhant. PoseNet Model in ML. Diakses melalui :
<https://iq.opengenius.org/PoseNet-model/>
- [15] Votel, Ronny, Na Li. 2021. Next-Generation Pose Detection with MoveNet and TensorFlow.js. Diakses melalui :
<https://blog.tensorflow.org/2021/05/next-generation-pose-detection-with-movenet-and-tensorflowjs.html>
- [16] Camillo Lugaresi, Jiuqiang Tang, Hadon Nash, Chris McClanahan, Esha Uboweja, Michael Hays, Fan Zhang, Chuo-Ling Chang, Ming Guang Yong, Juhyun Lee, Wan-Teh Chang, Wei Hua, Manfred Georg, Matthias Grundmann: MediaPipe: A Framework for Building Perception Pipelines. CoRR abs/1906.08172 (2019)
- [17] MediaPipe Pose. Available online:
https://developers.google.com/MediaPipe/solutions/vision/pose_landmarker/ (accessed on 21 June 2023).
- [18] T. L. Munea, Y. Z. Jembre, H. T. Weldegebriel, L. Chen, C. Huang and C. Yang, "The Progress of Human Pose Estimation: A Survey and Taxonomy of Models Applied in 2D Human Pose Estimation," in IEEE Access, vol. 8, pp. 133330-133348, 2020, doi: 10.1109/ACCESS.2020.3010248.
- [19] D. Dai, "An Introduction of CNN: Models and Training on Neural Network Models," 2021 International Conference on Big Data, Artificial Intelligence

- and Risk Management (ICBAR), Shanghai, China, 2021, pp. 135-138, doi: 10.1109/ICBAR55169.2021.00037.
- [20] S. Tripathi and R. Kumar, "Image Classification using small Convolutional Neural Network," 2019 9th International Conference on Cloud Computing, Data Science & Engineering (Confluence), Noida, India, 2019, pp. 483-487, doi: 10.1109/CONFLUENCE.2019.8776982.
- [21] A. Singh, S. Agarwal, P. Nagrath, A. Saxena and N. Thakur, "Human Pose Estimation Using Convolutional Neural Networks," 2019 Amity International Conference on Artificial Intelligence (AICAI), Dubai, United Arab Emirates, 2019, pp. 946-952, doi: 10.1109/AICAI.2019.8701267.
- [22] A. S. Dileep, N. S. S., S. S., F. K. and S. S., "Suspicious Human Activity Recognition using 2D Pose Estimation and Convolutional Neural Network," 2022 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), Chennai, India, 2022, pp. 19-23, doi: 10.1109/WiSPNET54241.2022.9767152.
- [23] Alzubaidi, L., Zhang, J., Humaidi, A.J. *et al.* Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data* 8, 53 (2021). <https://doi.org/10.1186/s40537-021-00444-8>
- [24] Yamashita, R., Nishio, M., Do, R.K.G. *et al.* Convolutional neural networks: an overview and application in radiology. *Insights Imaging* 9, 611–629 (2018). <https://doi.org/10.1007/s13244-018-0639-9>
- [25] <https://cs231n.github.io/convolutional-networks/>
- [26] Aruna, V. & Deepthi, Aruna & Leelavathi, R.. (2022). Human Activity Recognition Using Single Frame CNN. 10.1007/978-981-19-4831-2_17.

Halaman ini sengaja dikosongkan

LAMPIRAN

Halaman ini sengaja dikosongkan

DAFTAR INDEX