

BAB 2

TINJAUAN PUSTAKA

Kerangka teori yang digunakan terdiri atas tiga kelompok utama yang mencakup *grand theory*, *middle theory*, dan *applied theory*. *Grand theory* mencakup konsep kesegaran jasmani dalam konteks militer, pentingnya kesegaran jasmani serta standar kebugaran jasmani nasional. *Middle theory* melibatkan teknologi seperti *Artificial Intelligence* (AI), *Convolutional Neural Network* (CNN), *Computer Vision*, *MediaPipe*, *Deep Learning*, dan *Machine Learning* yang mendukung pengembangan sistem berbasis web untuk deteksi dan penilaian otomatis terhadap latihan fisik. *Applied theory* difokuskan pada analisis melalui metrik performa, pengujian respons aplikasi secara *real-time*, serta pengujian *blackbox* untuk memastikan keandalan dan efektivitas sistem yang dirancang.

2.1 *Grand Theory*

2.1.1 Definisi Kesegaran Jasmani dalam Lingkup Militer



Gambar 2.1 Tes Kesegaran Jasmani

Sumber : (Humas Resimen Korps Kadet, 2024)

Kesegaran jasmani merupakan kemampuan tubuh dalam melaksanakan tugas fisik dan mental secara optimal tanpa kelelahan berlebihan, dengan kemampuan pemulihan yang cepat. Pada lingkungan

pertahanan, kesegaran jasmani menjadi elemen utama dalam kesiapsiagaan prajurit untuk menghadapi berbagai tantangan fisik serta mental dalam pelaksanaan tugas militer . Pada gambar 2.1 merupakan pelaksanaan tes kesegaran jasmani yang ada pada Universitas Pertahanan. Kesegaran jasmani mencakup ketahanan fisik yang dibutuhkan untuk mempertahankan stamina dan daya tahan dalam situasi yang menuntut performa tinggi, terutama dalam medan operasi. Pada pelaksanaan tes kesegaran jasmani terdiri dari 3 baterai yaitu baterai a,b,dan c. baterai a meliputi lari 12 menit. Baterai b meliputi *push-up*, *sit-up*, *pull-up*, *chinning*, dan *suttle run*, sedangkan pada baterai c yaitu renang.

2.1.2 Pentingnya Kesegaran Jasmani pada Kadet UNHAN

Dalam lingkungan Universitas Pertahanan, kesegaran jasmani tidak hanya mendukung kesiapan operasional kadet tetapi juga menjadi bagian dari standar evaluasi dalam proses seleksi dan pembinaan calon kadet serta kadet mahasiswa. Individu yang memiliki kesegaran jasmani yang baik terbukti memiliki ketahanan lebih tinggi dalam menghadapi pelatihan intensif dan memiliki risiko cedera yang lebih rendah. Kesegaran jasmani pada kadet penting untuk memastikan bahwa mereka siap menjalankan latihan berat secara berkelanjutan dan adaptif terhadap tekanan fisik dan mental yang diberikan (Indiarto, 2024).

2.1.3 Baterai B Tes Kesegaran Jasmani dalam Seleksi dan Pembinaan Kadet UNHAN



Gambar 2.2 Pelaksanaan Tes Kesegaran Jasmani

Sumber : (Humas Resimen Korps Kadet, 2024)

Baterai B dalam tes kesegaran jasmani di UNHAN meliputi *push-up*, *sit-up*, *pull-up*, dan *chinning*, dan juga *suttle run*, yang secara khusus dirancang sebagai tolak ukur kemampuan kekuatan, daya tahan, serta kelenturan tubuh kadet mahasiswa. Setiap elemen tes dalam baterai kesegaran jasmani, seperti *push-up*, *sit-up*, *pull-up*, dan *chinning*, dan *suttle run* yang dirancang dengan standar yang mempertimbangkan kebutuhan fisik prajurit dalam berbagai kondisi operasional. Gambar 2.2 memuat tentang pelaksanaan tes kesegaran jasmani baterai B, dimana mencakup jumlah repetisi, teknik pelaksanaan, serta durasi waktu yang diadaptasi dari tantangan fisik yang mungkin dihadapi kadet di lapangan.

Dalam operasi militer, seorang prajurit sering kali harus mempertahankan kekuatan dan ketahanan fisik yang tinggi untuk mendukung tugas-tugas berat, termasuk membawa peralatan yang berat, bertahan dalam situasi darurat, dan bergerak cepat dalam waktu lama. Oleh karena itu, setiap elemen tes tidak hanya menilai kekuatan otot dan daya tahan kardiovaskular, aspek lain yang dinilai adalah aspek ketahanan mental. Pelaksanaan tes ini dengan standar yang ketat diharapkan dapat membantu kadet memiliki kesiapan fisik dasar yang kuat, serta kemampuan

bertahan terhadap stres dan kelelahan dalam kondisi yang ekstrem. Dengan demikian, tes ini berfungsi sebagai dasar penilaian awal yang dapat mengidentifikasi individu yang memiliki ketangguhan fisik dan mental yang dibutuhkan untuk melaksanakan tugas-tugas militer dengan baik (Dodi, 2018; Indiarto, 2024).

2.1.4 Standar Pelaksanaan *Push-up*, *Sit-up*, *Pull-up*, dan *Chinning* dalam Tes Kesegaran Jasmani

Standar pelaksanaan tes kesegaran jasmani berikut berdasarkan aturan yang ditetapkan untuk memastikan kesiapan fisik seorang prajurit atau kadet :

1. *Push-up*:



Gambar 2.3 Pelaksanaan Tes Kesegaran Jasmani *Push-up*

Sumber : (Humas Resimen Korps Kadet, 2024)

- a. Posisi Awal: Bertumpu pada kedua telapak tangan dan ujung kaki, dengan tubuh lurus dari kepala hingga tumit untuk pria dan lutut ditempelkan untuk Wanita.
- b. Gerakan: Turunkan tubuh hingga dada hampir menyentuh lantai, lalu dorong kembali ke posisi awal hingga tangan lurus.
- c. Durasi: Dilakukan selama 1 menit.

- d. Standar : Tergantung kategori usia dan jenis kelamin, untuk nilai 100 adalah dengan melaksanakan 43 kali untuk kadet pria dan 28 kali untuk kadet wanita.

2. *Sit-up* :



Gambar 2.4 Pelaksanaan Tes Kesegaran Jasmani *Sit-up*

Sumber : (Humas Resimen Korps Kadet, 2024)

- a. Posisi Awal: Berbaring telentang dengan lutut ditekuk dan tangan di belakang kepala.
- b. Gerakan: Angkat tubuh ke arah lutut hingga dada mendekati paha, kemudian kembali ke posisi awal.
- c. Durasi: Dilakukan selama 1 menit.
- d. Standar: Tergantung kategori usia dan jenis kelamin, untuk nilai 100 adalah dengan melaksanakan 43 kali untuk kadet pria dan 32 kali untuk kadet Wanita

3. *Pull-up* (untuk Pria):



Gambar 2.5 Pelaksanaan Tes Kesegaran Jasmani *Pull-up*

Sumber : (Humas Resimen Korps Kadet, 2024)

- a. Posisi Awal: Bergantung pada palang horizontal dengan telapak tangan menghadap ke depan dan tangan selebar bahu.
- b. Gerakan: Tarik tubuh ke atas hingga dagu melewati palang, kemudian turunkan kembali hingga tangan lurus.
- c. Durasi: Dilakukan selama 1 menit.
- d. Standar : Nilai 100 dengan 18 kali Gerakan dalam waktu 1 menit.

4. *Chinning* (untuk Wanita):



Gambar 2.6 Pelaksanaan Tes Kesegaran Jasmani *Chinning*

Sumber : (Humas Resimen Korps Kadet, 2024)

- a. Posisi Awal: Berdiri di depan palang horizontal setinggi dagu dengan kedua tangan memegang palang, dengan bahu berada dibawah palang.
- b. Gerakan: Tarik tubuh ke depan hingga dada menyentuh palang posisi bahu ada diatas palang, lalu kembali ke posisi semula.
- c. Durasi: Dilakukan selama 1 menit.
- d. Standar Minimal: Untuk nilai 100 dengan 63 kali dalam 1 menit.

Standar pelaksanaan ini penting untuk memastikan bahwa setiap kadet memiliki tingkat kebugaran dasar yang dapat mendukung kinerja fisik dalam medan operasi. Pelaksanaan yang sesuai standar mendukung

pembentukan kekuatan otot serta ketahanan fisik yang dibutuhkan dalam kondisi taktis yang menuntut.

2.2 Middle Theory

2.2.1 Kecerdasan Buatan (*Artificial Intelligence*)

Kecerdasan Buatan atau *Artificial Intelligence* merupakan teknologi yang memungkinkan sistem untuk menjalankan tugas-tugas kompleks yang membutuhkan kecerdasan manusia, seperti analisis data, pengenalan pola, serta pengambilan keputusan. Melalui algoritma pembelajaran mesin (*machine learning*), AI memungkinkan komputer untuk belajar dari data historis dan membuat prediksi atau klasifikasi tanpa instruksi manual. Proses ini dicapai melalui pembelajaran dari data yang besar dan kompleks, yang melibatkan algoritma yang dapat mengenali pola dari data tersebut dan menerapkannya dalam situasi baru (Zhang, 2022).

Dalam pembelajaran mesin, AI menggunakan algoritma tertentu seperti contohnya *Convolutional Neural Networks* (CNN) untuk menangani data visual, seperti gambar atau video. CNN merupakan jenis jaringan saraf tiruan yang efektif dalam mengenali objek dalam gambar, misalnya mendeteksi titik-titik kunci tubuh manusia dalam latihan fisik. Teknologi ini membuat AI sangat berguna dalam aplikasi yang membutuhkan pemrosesan gambar atau pengenalan pola visual yang akurat (Kim *et al.*, 2023).

AI juga mampu meningkatkan performanya dari waktu ke waktu melalui proses iteratif, di mana model yang telah dilatih dapat beradaptasi dengan data baru dan memperbaiki kesalahan dari prediksi sebelumnya. Hal ini memungkinkan AI untuk menghasilkan hasil yang akurat secara konsisten dalam lingkungan yang berubah-ubah, menjadikannya teknologi yang andal untuk berbagai aplikasi yang menuntut ketepatan dan efisiensi.

2.2.2 Visi Komputer (*Computer Vision*)

Computer Vision merupakan teknologi dalam bidang kecerdasan buatan yang memungkinkan komputer untuk memahami serta melakukan

analisis informasi visual dari gambar atau video. Visi komputer memungkinkan komputer untuk mendeteksi, mengenali, dan menginterpretasikan objek dan pola dalam data visual, menjadikannya mampu melihat dan menafsirkan gambar dengan cara yang mirip dengan penglihatan manusia.

Dalam konteks *pose estimation* atau deteksi pose tubuh, visi komputer digunakan untuk mengidentifikasi posisi dan orientasi tubuh manusia dengan mendeteksi titik-titik kunci pada bagian tubuh seperti kepala, bahu, siku, pinggul, lutut, dan pergelangan tangan. Dengan menganalisis posisi dari titik-titik kunci ini, visi komputer dapat membentuk kerangka dasar tubuh manusia (*skeleton model*), yang memungkinkan sistem untuk mengenali postur atau gerakan pengguna secara otomatis dan *real-time* (Renaldi & Munir, 2022).

Kemampuan visi komputer untuk menganalisis data visual secara cepat dan akurat menjadikannya teknologi penting dalam berbagai aplikasi, termasuk pengukuran kesegaran jasmani dan pemantauan kebugaran. Dengan visi komputer, sistem dapat menilai gerakan atau pose secara langsung dan memberikan umpan balik yang akurat, mendukung pengguna untuk melakukan latihan atau aktivitas fisik dengan teknik yang tepat. Dalam aplikasi ini, visi komputer membantu memastikan bahwa setiap gerakan yang terdeteksi sesuai dengan standar, memberikan penilaian yang konsisten dan mengurangi kesalahan dalam evaluasi manual (Kim *et al.*, 2023).

2.2.3 Machine learning

Machine learning merupakan suatu metode dalam AI yang memungkinkan sistem komputer untuk belajar dari pengalaman atau data tanpa harus diprogram secara spesifik untuk setiap tugas. Dalam *machine learning*, komputer diberikan sejumlah besar data yang digunakan untuk melatih model, yang kemudian akan membuat prediksi atau mengambil keputusan berdasarkan pola yang ditemukan di dalam data tersebut (Zhang, 2022).

Proses *machine learning* terdiri dari tiga tahap utama: pelatihan (training), validasi (*validation*), dan pengujian (*testing*). Pada tahap pelatihan, algoritma *machine learning* memproses data historis dan mengenali pola atau aturan tertentu yang dapat diterapkan pada data baru. Setelah model dilatih, proses validasi dilakukan untuk menilai seberapa baik model tersebut dalam membuat prediksi. Terakhir, tahap pengujian dilakukan untuk mengukur performa model dengan menggunakan data yang belum pernah dilihat sebelumnya oleh sistem.

Machine learning sangat bergantung pada algoritma statistik yang dapat menyederhanakan kompleksitas data besar menjadi pola yang dapat digunakan untuk menghasilkan prediksi. Dengan begitu, model *machine learning* dapat terus diperbaiki dan disesuaikan berdasarkan hasil prediksi dan umpan balik, sehingga meningkatkan akurasi serta keandalannya dari waktu ke waktu.

2.3.4 Deep learning

Deep learning merupakan sub-bidang dari *machine learning* yang menggunakan jaringan saraf tiruan (*artificial neural networks*) dengan lapisan-lapisan yang lebih dalam yang digunakan sebagai pemrosesan data kompleks dan menemukan pola secara otomatis. Sementara *machine learning* menggunakan algoritma yang dapat belajar dari data, *deep learning* memungkinkan pembelajaran yang lebih mendalam dengan memanfaatkan *multi-layer neural networks* atau jaringan saraf dengan banyak lapisan. Hal tersebut yang membuat *deep learning* menjadi efektif dalam menangani data yang tidak terstruktur, seperti gambar, suara, dan teks (Zhang, 2022).

Dalam *deep learning*, jaringan saraf tiruan tersusun dari berbagai *layer*, termasuk lapisan input, lapisan tersembunyi, serta lapisan output. Setiap lapisan tersembunyi memproses data dengan fungsi matematis yang kompleks, dan hasilnya diteruskan ke lapisan berikutnya. Lapisan-lapisan ini bekerja bersama untuk mengenali pola dan fitur yang semakin kompleks dalam data, dari bentuk sederhana hingga fitur yang lebih abstrak

pada lapisan lebih dalam. Proses ini memungkinkan sistem *deep learning* untuk mengekstrak informasi penting secara otomatis tanpa memerlukan fitur yang ditentukan secara manual (Kim *et al.*, 2023).

Salah satu keunggulan *deep learning* yaitu kemampuan dalam memproses data dalam jumlah besar dan menghasilkan hasil dengan tingkat akurasi tinggi. *Deep learning* terbukti efektif dalam tugas-tugas seperti pengenalan gambar, pemrosesan bahasa alami, dan analisis video, karena lapisan-lapisan dalam jaringan saraf dapat mengidentifikasi hubungan yang kompleks dalam data. Meskipun membutuhkan sumber daya komputasi yang tinggi, *deep learning* memberikan keunggulan signifikan dalam menghasilkan prediksi yang lebih akurat dan andal di berbagai aplikasi, termasuk visi komputer, pengenalan suara, dan kendaraan otonom.

2.2.5 MediaPipe



Gambar 2.7 *MediaPipe*

Sumber : (Irfan *et al.*, 2023)

MediaPipe merupakan framework yang dikembangkan oleh Google dan dirancang untuk melakukan deteksi dan pelacakan visual secara *real-time* pada berbagai perangkat, termasuk perangkat mobile dan desktop.

MediaPipe menyediakan alat pengolahan gambar dan video dengan efisiensi tinggi, yang mencakup berbagai fungsi dalam *pose estimation*, pelacakan tangan, dan deteksi objek. Dalam aplikasi pose estimation, *MediaPipe* menggunakan model *BlazePose*, yang ditunjukkan pada gambar 2.7 yang merupakan sebuah model pembelajaran mesin berbasis *Convolutional Neural Network (CNN)* yang telah dilatih secara ekstensif untuk mengenali titik-titik kunci tubuh manusia (Irfan *et al.*, 2023; Kim *et al.*, 2023).

MediaPipe dapat mendeteksi 33 titik kunci tubuh, yang terdiri dari bagian-bagian utama seperti kepala, bahu, siku, pergelangan tangan, pinggul, lutut, dan pergelangan kaki, serta beberapa titik tambahan untuk presisi yang lebih tinggi. Dengan titik-titik kunci ini, *MediaPipe* membangun model kerangka tubuh (*skeleton model*) yang dapat digunakan untuk menganalisis pose tubuh secara keseluruhan. Sistem ini sangat efisien karena memproses data visual dalam beberapa milidetik, memungkinkan aplikasi yang membutuhkan umpan balik cepat dan akurat, seperti sistem pengukuran repetisi latihan fisik dan pengukuran kesegaran jasmani (Zhang, 2022).


Keunggulan *MediaPipe* terletak pada kemampuannya untuk mendeteksi gerakan secara konsisten dan akurat, bahkan dalam kondisi lingkungan yang bervariasi. Hal tersebut menjadikan *MediaPipe* sangat efektif dalam aplikasi evaluasi fisik, seperti pengukuran repetisi *push-up*, *sit-up*, *pull-up*, dan *chin-up* pada tes kesegaran jasmani. Dengan mendeteksi sudut-sudut yang terbentuk antara titik-titik kunci tertentu (misalnya, siku dan bahu dalam *push-up*), *MediaPipe* dapat mencatat dan mengevaluasi gerakan sesuai dengan standar yang telah ditetapkan, mendukung penilaian otomatis pada gerakan repetitif yang dilakukan oleh pengguna (Kim *et al.*, 2023; Zhang, 2022).

2.2.6 Convolutional Neural Networks

Convolutional Neural Networks (CNN) merupakan jenis jaringan saraf tiruan yang dirancang untuk menganalisis data visual, seperti gambar

dan video. CNN sangat efektif dalam mengenali pola yang terdapat dalam data visual, menjadikannya alat yang kuat dalam berbagai aplikasi yang melibatkan pengenalan objek, deteksi wajah, dan analisis video. CNN bekerja dengan cara memproses data visual melalui serangkaian lapisan yang mengekstraksi fitur-fitur penting dari gambar, seperti bentuk, tepi, atau tekstur (Tian, 2020).

Salah satu kekuatan utama CNN adalah kemampuannya untuk mengotomatisasi proses ekstraksi fitur. Berbeda dengan metode tradisional di mana fitur-fitur dalam gambar harus ditentukan secara manual, CNN dapat belajar mengenali pola yang relevan dengan melatih model pada data gambar dalam jumlah besar. Dengan pelatihan ini, CNN mampu mendeteksi objek atau pola yang kompleks bahkan dalam kondisi pencahayaan, orientasi, atau sudut pandang yang bervariasi, sehingga menghasilkan prediksi atau klasifikasi yang akurat (Kim *et al.*, 2023). CNN telah menjadi standar dalam aplikasi *computer vision* karena kemampuannya untuk menangani data visual yang kompleks dan menghasilkan prediksi yang andal dalam berbagai tugas pengenalan dan deteksi. Selain itu, CNN dikenal efisien dalam hal pemrosesan data visual berkat struktur lapisannya yang dirancang untuk menyaring informasi dari data gambar secara bertahap, dari pola sederhana hingga fitur yang lebih kompleks.



Gambar 2.8 Lapisan CNN


Sumber : (Tian, 2020)

Pada gambar 2.8 menunjukkan bahwa pada CNN terdapat empat lapisan utama yang berperan penting dalam pembangunannya. Lapisan-

lapisan tersebut mencakup lapisan konvolusional (*convolutional layer*), lapisan aktivasi (*activation layer*), lapisan pengumpulan (*pooling layer*), serta lapisan yang sepenuhnya terhubung (*fully-connected layer*).

2.2.7 Convolutional layer

Convolutional Layer adalah lapisan dasar dalam *Convolutional Neural Networks* (CNN) yang berperan dalam mendeteksi fitur visual dalam data gambar, seperti tepi, tekstur, atau pola tertentu. Pada lapisan ini, jaringan saraf menerapkan filter atau kernel – yaitu matriks kecil dengan bobot tertentu – yang bergerak melintasi gambar untuk memproses area kecil gambar pada satu waktu. Setiap posisi filter menghasilkan nilai baru yang menunjukkan keberadaan fitur tertentu pada area gambar tersebut (Tian, 2022).



Gambar 2.9 Convolutional Layer


Sumber : (Tian, 2020)

Fungsi utama dari konvolusi adalah untuk melakukan operasi konvolusi antara gambar input dengan filter. Melalui proses ini, informasi pada gambar asli dapat ditingkatkan, sementara gangguan dari noise dapat ditekan. Proses konvolusi ini mencerminkan dua karakteristik utama, yaitu bidang reseptif lokal (*local receptive field*) dan pembagian bobot (*weight sharing*). Dalam konvolusi, jaringan secara otomatis mempelajari fitur-fitur

yang relevan tanpa perlu memilih fitur secara manual, sehingga menghemat waktu dan usaha (Tian, 2020). Sebagai contoh, misalkan terdapat gambar dengan ukuran 4×4 , kemudian digunakan kernel konvolusi dengan ukuran 2×2 , dan langkah geser (*stride*) dari kernel konvolusi adalah 1. Maka, proses operasi konvolusi dapat dijelaskan seperti yang ditunjukkan pada gambar 2.9.

2.2.8 Activation Layer

Activation Layer adalah lapisan dalam *Convolutional Neural Networks* (CNN) yang bertugas untuk memperkenalkan *non-linearitas* ke dalam model, memungkinkan jaringan untuk belajar dan mewakili pola-pola yang lebih kompleks dalam data. Tanpa *activation layer*, CNN hanya dapat menangkap pola linear yang sederhana, sehingga fungsi aktivasi sangat penting untuk membantu jaringan mengenali fitur yang lebih rumit (Vakalopoulo *et al.*, 2023).



Gambar 2.10 *Activation Layer*


Sumber : (Yunus, 2020)

Salah satu fungsi aktivasi yang paling umum digunakan adalah *Rectified Linear Unit* (ReLU). Fungsi ReLU bekerja dengan cara menyetel semua nilai negatif pada *output* menjadi nol dan mempertahankan nilai positif seperti gambar 2.10.

ReLU efektif karena:

1. *Non-linearitas*: Fungsi ini menambahkan kemampuan untuk menangkap pola yang tidak linear, yang sangat penting dalam visi komputer dan pemrosesan gambar.
2. Efisiensi Komputasi: Karena hanya melibatkan operasi sederhana, ReLU membantu meningkatkan kecepatan komputasi dibandingkan fungsi aktivasi lain, seperti sigmoid atau tanh (Kim *et al.*, 2023).

Selain ReLU, fungsi aktivasi lain seperti sigmoid dan tanh juga kadang digunakan, terutama dalam lapisan *output* untuk tugas klasifikasi.




Gambar 2.11 Merupakan contoh gambar yang melewati ReLU

Sumber : (Vakalopoulo *et al.*, 2023)

Activation layer memungkinkan CNN untuk belajar dari data yang kompleks dan tidak terstruktur, sehingga jaringan dapat mengenali pola visual yang lebih mendalam dan menghasilkan prediksi yang lebih akurat (Vakalopoulo *et al.*, 2023).

2.2.9 Pooling Layer

Pooling Layer merupakan lapisan dalam *Convolutional Neural Networks* (CNN) yang berguna mengurangi dimensi dari peta fitur, sambil mempertahankan informasi penting. Dengan mengurangi dimensi data, *pooling layer* membantu mengurangi jumlah parameter dan meningkatkan efisiensi komputasi, sehingga jaringan dapat memproses gambar lebih cepat dan menghindari risiko *overfitting* (Zhang, 2022).



Gambar 2.12 *Pooling Layer*

Sumber : (Vakalopoulo *et al.*, 2023)

Pooling layer bekerja dengan cara membagi peta fitur menjadi beberapa area kecil, seperti area 2x2 atau 3x3 piksel, seperti pada gambar 2.12 dan memilih satu nilai per area sebagai representasi. Metode *pooling* yang paling umum digunakan adalah *Max Pooling*, yang memilih nilai tertinggi dari setiap area kecil tersebut. *Max pooling* membantu jaringan untuk mempertahankan fitur yang paling menonjol dalam area tertentu, seperti tepi atau pola yang signifikan (Kim *et al.*, 2023).

Selain itu metode *Average Pooling*, yang mengambil rata-rata dari setiap area kecil dalam peta fitur. Meskipun average pooling tidak sepopuler *max pooling*, metode ini tetap digunakan dalam beberapa kasus, terutama ketika jaringan membutuhkan fitur yang lebih halus atau rata-rata intensitas piksel.

Pooling layer penting dalam CNN karena:

1. Mengurangi Dimensi Data: Dengan mengurangi ukuran peta fitur, *pooling layer* membantu meningkatkan efisiensi komputasi dan membuat model lebih ringan.
2. Menangkap Fitur yang Stabil: *Pooling layer* membuat jaringan lebih robust terhadap variasi kecil dalam gambar, seperti perubahan posisi atau orientasi objek, sehingga jaringan tetap mengenali fitur meskipun ada perubahan kecil.

Pooling layer bekerja sebagai penyaring tambahan dalam CNN, memungkinkan model untuk mengekstrak informasi penting tanpa kehilangan performa dan memastikan jaringan dapat mengenali pola-pola yang stabil dalam data visual.

2.2.10 Fully connected layer

Fully connected layer (Lapisan Sepenuhnya Terhubung) adalah lapisan dalam *Convolutional Neural Networks* (CNN) di mana semua neuron di satu lapisan terhubung ke semua neuron di lapisan berikutnya. Ini adalah lapisan akhir dalam jaringan CNN yang berfungsi untuk menggabungkan semua fitur yang telah diekstraksi oleh lapisan konvolusi dan *pooling* sebelumnya dan kemudian membuat keputusan akhir berdasarkan fitur-fitur tersebut. *Fully connected layer* ini sering digunakan untuk menghasilkan prediksi atau klasifikasi akhir dalam model CNN (Zhang, 2022).

Dalam *fully connected layer*, data visual yang sebelumnya berbentuk peta fitur dua dimensi diratakan menjadi vektor satu dimensi. Vektor ini berisi informasi penting tentang fitur-fitur yang telah dipelajari oleh jaringan selama proses konvolusi dan pooling. Setiap neuron dalam *fully connected layer* menghubungkan semua neuron dari lapisan sebelumnya dan memberikan bobot khusus pada setiap koneksi, memungkinkan jaringan untuk menggabungkan berbagai fitur dari seluruh gambar untuk menghasilkan prediksi.


Berikut adalah fungsi utama dari *fully connected layer*:

- a. Menggabungkan Fitur: Setelah lapisan konvolusi dan pooling mengekstraksi fitur-fitur visual utama, *fully connected layer* mengintegrasikan fitur-fitur ini untuk memahami hubungan antar fitur dalam konteks keseluruhan gambar.
- b. Menghasilkan Prediksi Akhir: Pada tahap akhir, *fully connected layer* menghasilkan skor untuk setiap kelas yang mungkin (misalnya, dalam klasifikasi objek, setiap kelas objek memiliki satu skor). Nilai

tertinggi dari skor ini menunjukkan prediksi jaringan untuk input tersebut. Fungsi aktivasi seperti *softmax* sering digunakan di lapisan akhir *fully connected* untuk menghasilkan probabilitas dari setiap kelas, yang memudahkan dalam proses klasifikasi.

- c. Memahami Hubungan Kompleks: *Fully connected layer* dapat mempelajari dan menggabungkan informasi yang lebih kompleks dengan menghubungkan semua neuron sebelumnya. Hal ini memungkinkan jaringan untuk menangkap pola yang lebih luas dan membangun representasi akhir dari data yang kompleks.

Fully connected layer berfungsi seperti lapisan pengambilan keputusan dalam CNN, memastikan bahwa semua informasi yang telah dipelajari jaringan dari gambar diterjemahkan ke dalam keputusan yang lebih spesifik, seperti klasifikasi atau pengenalan objek dalam konteks tertentu (Kim *et al.*, 2023).




Gambar 2. 13 *Fully connected layer*

Sumber : (Huang & Wang, 2022)

Gambar 2.13 menggambarkan struktur dari lapisan *fully connected layer*, di mana data yang telah melalui proses *flattening* menjadi input bagi lapisan ini. Lapisan ini sering disebut sebagai hidden layer atau lapisan tersembunyi, yang jumlahnya dapat disesuaikan secara fleksibel tanpa batas tertentu. Demikian pula, jumlah neuron dalam setiap hidden layer dapat ditentukan sesuai dengan kebutuhan, namun harus memperhitungkan kapasitas perangkat keras yang digunakan. Hal ini dikarenakan semakin banyak hidden layer dan neuron yang ditambahkan, semakin kompleks pula proses komputasinya, yang berujung pada waktu pemrosesan lebih lama dan peningkatan kebutuhan sumber daya komputasi (Vakalopoulou *et al.*, 2023).

2.2.11 Estimasi Pose Tubuh



Gambar 2.14 *Pose Landmark*

Sumber : (Kim *et al.*, 2023)

Estimasi pose tubuh, atau *pose estimation*, adalah teknik dalam visi komputer yang bertujuan untuk mendeteksi posisi dan orientasi tubuh manusia dengan mengenali titik-titik kunci pada tubuh. Dalam teknik ini, algoritma *pose estimation* mengidentifikasi bagian tubuh seperti kepala, bahu, siku, pergelangan tangan, pinggul, lutut, dan pergelangan kaki. Pada

gambar 2.14 terlihat bahwa setiap titik kunci ini disusun menjadi kerangka tubuh manusia, yang disebut sebagai *skeleton model*, untuk memberikan representasi visual dari pose atau gerakan tubuh.

Teknologi *pose estimation* yang digunakan oleh *MediaPipe*, sebuah framework pengembangan dari Google, memungkinkan deteksi hingga 33 titik kunci tubuh secara *real-time*. *MediaPipe* memanfaatkan algoritma jaringan saraf yang dilatih untuk mendeteksi titik-titik ini dengan cepat dan akurat, bahkan pada perangkat yang memiliki keterbatasan pemrosesan, seperti ponsel dan komputer tanpa GPU. Keunggulan *MediaPipe* terletak pada kemampuan deteksinya yang efisien sehingga cocok untuk aplikasi yang membutuhkan kecepatan dan ketepatan dalam pemantauan gerakan tubuh (Kim *et al.*, 2023).

Dalam konteks evaluasi fisik, *pose estimation* yang dilakukan oleh *MediaPipe* mendukung pengukuran gerakan repetitif, seperti *push-up* dan *sit-up*, dengan memantau pergerakan titik-titik kunci tertentu. Misalnya, dalam gerakan *push-up*, *MediaPipe* dapat memantau perubahan sudut pada siku dan bahu untuk menghitung jumlah repetisi secara akurat. Sistem ini juga dapat memvalidasi teknik gerakan pengguna berdasarkan posisi titik-titik kunci tubuh, yang memungkinkan evaluasi gerakan sesuai standar yang telah ditetapkan (Zhang, 2022; Kim *et al.*, 2023).

2.2.12 Data Training , Data Validation, Data Testing

Dalam pembelajaran mesin, termasuk dalam penerapan Convolutional Neural Networks (CNN), *data training* dan *data testing* memiliki peran yang penting dan berbeda:

- a. **Data training:** digunakan untuk melatih model dalam mengenali pola, fitur, dan hubungan dalam dataset. Selama proses ini, model secara iteratif menyesuaikan bobot (weights) pada jaringan CNN untuk meminimalkan kesalahan prediksi. Sekitar 80% dari keseluruhan data dialokasikan untuk pelatihan agar model memiliki cukup informasi untuk mempelajari representasi data yang

kompleks, terutama pada dataset dengan variasi tinggi (McAllister et al., 2018).

- b. **Data Validation:** berfungsi untuk mengevaluasi kinerja model selama proses pelatihan. Data ini tidak digunakan untuk melatih model secara langsung, tetapi untuk membantu mengatur parameter model dan mendeteksi potensi masalah seperti overfitting atau underfitting. Alokasi 10% data untuk validasi memungkinkan pemantauan performa model secara berkala.
- c. **Data Testing:** digunakan untuk menilai kinerja akhir model setelah pelatihan selesai. Data ini bersifat independen karena tidak digunakan selama pelatihan maupun validasi. Dengan menggunakan 10% dari total dataset, pengujian ini memberikan gambaran objektif tentang kemampuan model dalam menggeneralisasi terhadap data baru (Durdan et al., 2021).

Proporsi 80:10:10 sering digunakan dalam pembagian dataset pada pembelajaran mesin berbasis *Convolutional Neural Networks* (CNN) karena memberikan kerangka kerja yang seimbang antara pelatihan, validasi, dan evaluasi model. Dalam konteks CNN, sebagian besar data (80%) dialokasikan untuk melatih model agar mampu mempelajari pola dan fitur kompleks dari dataset. Sebagian lainnya (10%) digunakan sebagai data validasi untuk memantau kinerja model selama pelatihan, mendeteksi overfitting atau underfitting. Sisanya (10%) digunakan sebagai *data testing* untuk mengukur kemampuan generalisasi model terhadap data yang benar-benar baru. McAllister et al. (2018) menunjukkan bahwa pembagian 80:10:10 efektif saat melatih model ResNet-152 pada dataset gambar makanan Food-101, yang memiliki variasi tinggi dalam representasi visual. Penggunaan data validasi secara terpisah memungkinkan proses pelatihan berlangsung secara lebih adaptif dan terukur. Hal yang serupa juga ditemukan oleh Durdan et al. (2021) dalam penelitian klasifikasi fauna dasar laut menggunakan CNN, di mana keberadaan data validasi membantu menjaga stabilitas performa model selama pelatihan, sementara data

testing memberikan penilaian akhir yang objektif terhadap model. Dengan demikian, proporsi 80:10:10 dinilai optimal untuk membangun model CNN yang akurat, stabil, dan mampu beradaptasi dengan data dunia nyata.

2.3 *Applied Theory:*

2.3.1 Metrik Performa

Dalam sistem pengukuran kesegaran jasmani berbasis *MediaPipe*, metrik performa digunakan untuk mengevaluasi akurasi dan efisiensi deteksi gerakan. Metrik performa utama meliputi:

- a. Akurasi : Fokus pada akurasi deteksi gerakan standar seperti *push-up* dan *sit-up* sesuai ketentuan. Akurasi penting untuk memastikan bahwa hanya gerakan yang memenuhi standar dianggap valid, (Xu *et al.*, 2020).

$$\text{Akurasi} = \frac{\text{True Positives} + \text{True Negatives}}{\text{True Positive} + \text{False Positive} + \text{False Negative} + \text{True Negatives}} \quad (2.1)$$

- b. *Precision* dan *Recall*: *Precision* mengukur keakuratan dalam deteksi gerakan yang benar, sementara *recall* mengukur kemampuan sistem untuk mendeteksi setiap gerakan yang dilakukan dalam berbagai kondisi. Kedua metrik ini memastikan sistem sensitif terhadap berbagai variasi gerakan dan menghindari kesalahan deteksi (Xu *et al.*, 2020).

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \quad (2.2)$$

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}} \quad (2.3)$$

- c. F1 Score: Metrik gabungan dari *precision* dan *recall* untuk memberikan gambaran seimbang tentang keandalan sistem dalam mendeteksi seluruh gerakan dengan benar. F1 Score penting untuk menilai performa keseluruhan

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.4)$$

Dalam sistem yang dibuat maka :

- a. True Positive (TP): Gerakan yang terdeteksi dengan benar sesuai dengan kelas *positive*
- b. False Positive (FP): Gerakan yang terdeteksi namun tidak sesuai kelas *positive*.
- c. False Negative (FN): Gerakan yang terdeteksi namun tidak sesuai kelas *negative*.
- d. True Negative (TN): Gerakan yang terdeteksi dengan benar sesuai dengan kelas *negative*.

2.3.2 Pengujian *Black Box*

Pengujian *black box* digunakan untuk mengevaluasi fungsionalitas aplikasi dari perspektif pengguna tanpa melihat kode internal. Pendekatan ini penting untuk menilai apakah sistem berfungsi sesuai kebutuhan pengguna akhir. Beberapa aspek yang diuji dalam konteks ini meliputi:

- a. Pengujian Fungsionalitas Deteksi Gerakan: Pengujian ini memastikan bahwa aplikasi dapat mendeteksi gerakan yang sesuai dengan standar TNI, seperti *push-up*, *sit-up*, dan mencatatnya dengan tepat. Pendekatan pengujian fungsional ini bertujuan untuk mengidentifikasi batasan operasional yang relevan. (Nurudin *et al.*, 2019).
- b. Pengujian Keandalan dalam Kondisi Nyata: Pengujian ini menguji stabilitas sistem dalam berbagai kondisi lingkungan, sehingga aplikasi tetap andal dalam kondisi operasional yang bervariasi (Nurudin *et al.*, 2019).

2.4 Penelitian Terdahulu

Tabel 2.1 Penelitian Terdahulu

NO	Peneliti, Tahun, Judul	Tujuan Penelitian	Hasil	Ringkasan Penelitian	
				Persamaan	Perbedaan
1	Reagan L. Galvez <i>et al.</i> , 2018, <i>Object Detection Using Convolutional Neural Networks</i>	Menggunakan CNN untuk mendeteksi objek di lingkungan sebagai bagian dari sistem robotik.	Model SSD dan Faster-RCNN menunjukkan performa baik untuk deteksi objek <i>real-time</i> .	Sama-sama menggunakan CNN untuk analisis	Fokus pada deteksi objek, bukan kebugaran
2	Noveri Lysbetti Marpaung <i>et al.</i> , 2022, Rancang Bangun Program Aplikasi Tes Kesegaran Jasmani Indonesia Berbasis Android	Membangun aplikasi untuk mengukur tingkat kesegaran jasmani berdasarkan standar TKJI.	Aplikasi berhasil mengukur kesegaran jasmani secara efisien dan akurat.	Memiliki tujuan mengukur aspek kebugaran fisik.	Menggunakan aplikasi untuk mengukur TKJI, bukan CNN.
3	Irfan <i>et al.</i> , 2023, Pengiraan Pose Model Manusia Pada Repetisi Kebugaran AI	Mengestimasi pose manusia pada repetisi kebugaran menggunakan <i>MediaPipe</i> untuk deteksi pose.	<i>MediaPipe</i> efektif mendeteksi pose dengan akurasi tinggi pada jarak optimal 3 meter.	Menggunakan <i>MediaPipe</i> untuk deteksi pose pada kebugaran.	Fokus pada repetisi kebugaran, bukan pengukuran kebugaran keseluruhan.
4	Jong-Wook Kim <i>et al.</i> , 2023, <i>Human Pose Estimation Using MediaPipe Pose and Optimization Method Based on a Humanoid Model</i>	Mengembangkan metode estimasi pose manusia berbasis <i>MediaPipe</i> untuk aplikasi robot.	Metode estimasi pose 3D dengan <i>MediaPipe</i> efektif untuk mendeteksi posisi tubuh.	Menggunakan <i>MediaPipe</i> dalam deteksi pose manusia.	Difokuskan pada pose untuk aplikasi robotik, bukan kebugaran jasmani.
5	Youhui Tian, 2020, <i>Artificial Intelligence Image Recognition</i>	Meningkatkan kecepatan konvergensi dan akurasi pengenalan	CNN dapat meningkatkan akurasi dan efisiensi pengenalan gambar.	Sama-sama menggunakan CNN untuk pengenalan citra.	Fokus pada pengenalan gambar umum, bukan kebugaran jasmani.

	<i>Method Based on Convolutional Neural Network Algorithm</i>	gambar pada CNN.			
6	Rupesh Kumar <i>et al.</i> , <i>MediaPipe and CNNs for Real-time ASL Gesture Recognition</i>	Menggunakan <i>MediaPipe</i> dan CNN untuk mengenali gerakan ASL secara <i>real-time</i> .	Sistem mencapai akurasi 99.95% untuk deteksi ASL secara <i>real-time</i> .	Menggunakan <i>MediaPipe</i> dan CNN dalam analisis pose.	Difokuskan pada bahasa isyarat, bukan kebugaran jasmani.
7	Renaldi Arlin <i>et al.</i> , <i>The Development of Push Up Counter Android Application with Computer Vision</i>	Membuat aplikasi Android untuk menghitung repetisi <i>push-up</i> dengan deteksi pose tubuh.	Aplikasi mendeteksi <i>push-up</i> dengan akurasi	Menggunakan deteksi pose tubuh dalam aplikasi kebugaran.	Menggunakan K-NN, bukan CNN, untuk klasifikasi <i>push-up</i> .
8	Tzeico J. Sánchez-Vicinaiz <i>et al.</i> , 2024, <i>MediaPipe Frame and Convolutional Neural Networks-Based Fingerspelling Detection in Mexican Sign Language</i>	Mendeteksi huruf bahasa isyarat Meksiko menggunakan <i>MediaPipe</i> dan CNN.	Model mencapai akurasi 83.63% pada dataset bahasa isyarat Meksiko.	Menggunakan <i>MediaPipe</i> untuk deteksi pose tangan.	Difokuskan pada bahasa isyarat, bukan kebugaran jasmani.
9	Gagandeep Singh <i>et al.</i> , 2024, <i>Enhancing Sign Language Detection through MediaPipe and Convolutional Neural Networks (CNN)</i>	Menggunakan <i>MediaPipe</i> dan CNN untuk deteksi bahasa isyarat <i>real-time</i> .	Model mencapai akurasi 99.12% pada dataset ASL.	Menggunakan <i>MediaPipe</i> untuk analisis pose <i>real-time</i> .	Difokuskan pada bahasa isyarat, bukan kebugaran jasmani.
10	Yongyuan Zhang, 2022, <i>Applications</i>	Menggunakan <i>MediaPipe</i> untuk estimasi pose	<i>MediaPipe</i> Pose efektif dalam	Menggunakan <i>MediaPipe</i> untuk deteksi	Difokuskan pada estimasi pose 3D,

	<i>of Google MediaPipe Pose Estimation Using a Single Camera</i>	manusia dengan kamera tunggal.	estimasi pose dengan latensi rendah.	pose manusia.	bukan aplikasi kebugaran jasmani.
--	--	--------------------------------	--------------------------------------	---------------	-----------------------------------

Tabel 2.1 tersebut memberikan ringkasan dari sepuluh penelitian terdahulu yang terkait dengan penggunaan *MediaPipe* dan *Convolutional Neural Network* (CNN) dalam deteksi pose serta aplikasinya pada kebugaran jasmani dan bahasa isyarat. Penelitian (Galvez *et al.*, 2018) menggunakan CNN untuk mendeteksi objek di lingkungan sebagai bagian dari sistem robotik, menunjukkan bahwa model SSD dan Faster-RCNN memiliki performa tinggi dalam deteksi objek *real-time*. Penelitian (Marpaung *et al.*, 2022) merancang aplikasi Tes Kesegaran Jasmani Indonesia (TKJI) berbasis Android untuk mengukur tingkat kesegaran jasmani berdasarkan standar TKJI, memberikan kemudahan dan efisiensi dalam proses pengukuran.

Penelitian lain yang relevan adalah (Irfan *et al.*, 2023) yang menggunakan *MediaPipe* untuk mendeteksi pose manusia dalam repetisi gerakan kebugaran, dengan akurasi tinggi pada jarak optimal tiga meter, serta (Kim *et al.*, 2023) yang mengembangkan metode estimasi pose 3D berbasis *MediaPipe* untuk aplikasi robotik. Keduanya menunjukkan potensi *MediaPipe* untuk deteksi pose secara *real-time* dengan akurasi tinggi. Penelitian (Tian, 2020) berfokus pada peningkatan kecepatan konvergensi dan akurasi CNN dalam pengenalan gambar, yang mendukung efektivitas CNN dalam analisis citra.

Beberapa penelitian lainnya menggabungkan *MediaPipe* dan CNN untuk deteksi bahasa isyarat. Penelitian (Kumar *et al.*, 2023) mengembangkan sistem untuk deteksi American Sign Language (ASL) secara *real-time* dengan akurasi hingga 99.95%, sementara (Sánchez-Vicinaiz *et al.*, 2024) dan (Singh *et al.*, 2024) masing-masing mencapai akurasi 83.63% dan 99.12% dalam mendeteksi bahasa isyarat Meksiko dan ASL menggunakan *MediaPipe* dan CNN. Penelitian (Arlin *et al.*) memanfaatkan *MediaPipe* untuk menghitung repetisi *push-up* dalam aplikasi kebugaran, mencapai akurasi deteksi 84.7%. Penelitian (Zhang, 2022) juga menyelidiki aplikasi *MediaPipe* dalam estimasi pose menggunakan kamera tunggal, menunjukkan latensi rendah yang cocok untuk aplikasi *real-time*.

Tabel 2.2 Gap Penelitian

Aspek	Penelitian Terhadulu	Rencana Penelitian
Penulis dan Judul	Irfan <i>et al.</i> , 2023, Pengiraan Pose Model Manusia Pada Repetisi Kebugaran AI	Chadafa Zulti Noorta 2024, Implementasi Teknologi Machine Learning Berbasis CNN Menggunakan <i>MediaPipe</i> Pada Pengukuran Tes Kesegaran Jasmani Baterai B Pada Kadet Mahasiswa di Universitas Pertahanan
Topik Utama	Estimasi pose untuk menghitung repetisi Latihan kebugaran menggunakan <i>MediaPipe</i> dan logika sudut dengan python	Identifikasi tes kesegaran jasmani menggunakan <i>MediaPipe</i> untuk deteksi pose dan CNN untuk klasifikasi
Metode	Menggunakan <i>MediaPipe</i> dengan OpenCV untuk deteksi pose berdasarkan sudut siku dan landmark tubuh untuk menghitung repetisi	Kombinasi <i>MediaPipe</i> dan CNN untuk deteksi pose <i>real-time</i> dan CNN untuk meningkatkan akurasi klasifikasi dalam konteks tes kesegaran jasmani
Fokus Penelitian	Mengotomatiasasi hitungan repetisi kebugaran dengan estimasi pose sederhana dengan sudut dan landmark	Menilai hasil tes kesegaran jasmani berdasarkan pose tubuh dan pola gerakan yang terdeteksi
Konteks aplikasi	Peningkatan pengalaman Latihan kebugaran dirumah selama pandemi	Sebagai sarana monitoring serta evaluasi hasil tes kesegaran jasmani melalui teknologi machine learning
Keunggulan teknologi	Berfokus pada kemudahan implementasi dan aplikasi praktis berbasis python dengan <i>webcam</i> sebagai input utama	Penggunaan CNN untuk klasifikasi yang lebih kompleks berdasarkan data <i>MediaPipe</i>
Perbedaan	Tidak menggunakan model machine learning kompleks untuk klasifikasi dan hanya berfokus pada logika sudut sederhana	Berfokus pada pengintegrasian deteksi pose dengan klasifikasi berbasis machine learning untuk penilaian kesegaran jasmani yang dikemas dengan <i>web</i> secara <i>real-time</i>


Sumber : diolah oleh peneliti

Berdasarkan analisis terhadap perbandingan antara rencana penelitian yang akan dikembangkan peneliti dan penelitian Irfan *et al.* (2023), terdapat beberapa keunggulan serta perbedaan signifikan yang dapat diidentifikasi. Kedua penelitian sama-sama memanfaatkan *MediaPipe* untuk deteksi pose, namun fokus dan pendekatan yang digunakan berbeda. Pada rencana penelitian peneliti, pendekatan


berbasis CNN digunakan untuk klasifikasi yang lebih kompleks berdasarkan data *MediaPipe*. Hal ini memberikan keunggulan dalam mendukung aplikasi yang lebih akurat dan efisien untuk penilaian kesegaran jasmani.

Sementara itu, penelitian Irfan et al. (2023) lebih menekankan pada kemudahan implementasi dan aplikasi berbasis logika sudut sederhana, tanpa melibatkan model machine learning yang kompleks seperti CNN. Perbedaan mendasar lainnya terletak pada integrasi teknologi. rencana penelitian peneliti mengutamakan penggabungan sistem deteksi pose dengan *platform* berbasis *web* yang memungkinkan pengukuran kesegaran jasmani secara *real-time*. Hal ini memberikan kebaruan utama yang tidak ditemukan pada penelitian Irfan et al.

Secara keseluruhan, penelitian ini tidak hanya menawarkan pendekatan yang lebih kompleks melalui pengintegrasian *MediaPipe* dan CNN, tetapi juga memberikan kontribusi praktis dalam bentuk aplikasi berbasis *web*. Hasil dari penelitian ini diharapkan dapat memperkaya implementasi *MediaPipe* dalam konteks kebugaran jasmani, sekaligus memperkuat validitas pendekatan berbasis machine learning untuk tes kesegaran jasmani.



2.5 Kerangka Pemikiran



Gambar 2.15 Kerangka Pemikiran

Sumber : diolah oleh peneliti

Gambar 2.15 menggambarkan kerangka pemikiran yang menjadi dasar dalam penelitian pengembangan sistem deteksi kesegaran jasmani berbasis AI menggunakan *MediaPipe* dan CNN. Penelitian ini diawali dengan identifikasi masalah pada metode pengukuran kebugaran jasmani tradisional yang dinilai kurang efisien, baik dari segi akurasi, maupun

fleksibilitas. Masalah tersebut menjadi landasan utama untuk mengembangkan solusi berbasis teknologi yang mampu menjawab kebutuhan akan sistem pengukuran yang lebih modern dan efektif.

Langkah berikutnya adalah melakukan tinjauan literatur untuk memahami penelitian-penelitian terdahulu terkait penggunaan *MediaPipe* dan CNN dalam mendeteksi pose tubuh. Tinjauan ini bertujuan untuk menemukan celah penelitian yang dapat diisi dengan pendekatan baru, sekaligus memanfaatkan temuan sebelumnya sebagai dasar pengembangan konsep penelitian ini. Hasil tinjauan literatur kemudian digunakan untuk merancang konsep integrasi *MediaPipe* sebagai alat pendeteksi pose tubuh dan CNN sebagai penguat analisis data. Konsep ini dirancang secara khusus untuk mendukung proses penilaian kesegaran jasmani.

Tahap berikutnya adalah pengembangan sistem berbasis *web* yang dirancang untuk bekerja secara *real-time*. Sistem ini memungkinkan pengguna untuk mendeteksi dan menilai kebugaran jasmani dengan cepat dan efisien, sekaligus mempermudah proses monitoring. Setelah sistem dirancang, tahap implementasi dilakukan dengan mengintegrasikan *MediaPipe*, CNN, dan *platform web* untuk memastikan sistem dapat berjalan sesuai dengan konsep yang telah dikembangkan.

Setelah implementasi, dilakukan evaluasi terhadap sistem melalui pengujian akurasi, respon *real-time*, dan uji *blackbox*. Evaluasi ini bertujuan untuk memastikan sistem berfungsi dengan baik dan dapat diandalkan. Tahap akhir dari penelitian ini adalah menghasilkan sebuah sistem deteksi kesegaran jasmani berbasis *web* yang mampu bekerja secara *real-time*. Sistem ini diharapkan dapat menjadi solusi inovatif yang akurat, efisien, dan mudah diakses, sekaligus memberikan kontribusi nyata dalam digitalisasi tes kesegaran jasmani pada Universitas Pertahanan