

Perbandingan Random Forest, K-Nearest Neighbor, Support Vector Machine, dan Multi-Layer Perceptron untuk Deteksi Postur Duduk Berdasarkan Ekstraksi Pose MediaPipe

Tegar Risky Nugrahanto¹, Irsyad Badruddin², Muhammad Dzakirin Amrulloh³,
Rajnaparamitha Kusumastuti*⁴

¹²³Prodi Informatika, ⁴Teknologi Informasi, ¹²³⁴STMIK Amikom Surakarta

¹²³⁴Sukoharjo, Indonesia

Email: ¹tegar.10486@mhs.amikomsolo.ac.id,

²irsyad.10503@mhs.amikomsolo.ac.id, ³muhammad.10489@mhs.amikomsolo.ac.id,

⁴rajna@dosen.amikomsolo.ac.id

Abstract

Poor sitting posture has the potential to cause musculoskeletal disorders, yet image-based automatic detection is still rarely applied in ergonomic contexts. This study aims to develop and compare the performance of four classification algorithms Random Forest, K-Nearest Neighbor (KNN), Support Vector Machine (SVM), and Multi-Layer Perceptron (MLP) in identifying good and bad sitting posture. A total of 483 images were processed using MediaPipe Pose to extract 132 landmark features for each sample, which were then divided into training, validation, and test sets (60:20:20). Evaluation on the test set showed that Random Forest achieved the best performance with an accuracy of 87.63% and an F1-score of 0.8947, followed by MLP, KNN, and SVM. These findings indicate that combining pose extraction using MediaPipe with ensemble-based methods such as Random Forest can produce an accurate sitting posture classification system and serve as a foundation for developing computer vision-based ergonomic monitoring applications.

Keywords: Sitting posture, MediaPipe, Classification, Random Forest, Machine Learning.

Abstraksi

Postur duduk yang buruk berpotensi menimbulkan gangguan muskuloskeletal, namun deteksi otomatis berbasis citra masih jarang diterapkan pada konteks ergonomi. Penelitian ini bertujuan mengembangkan dan membandingkan performa empat algoritma klasifikasi, yaitu Random Forest, K-Nearest Neighbor (KNN), Support Vector Machine (SVM), dan Multi-Layer Perceptron (MLP) dalam mengidentifikasi postur duduk baik dan buruk. Sebanyak 483 citra diekstraksi menggunakan MediaPipe Pose sehingga menghasilkan 132 fitur landmark untuk setiap sampel, yang kemudian dibagi menjadi data latih, validasi, dan uji (60:20:20). Hasil evaluasi pada test set menunjukkan bahwa Random Forest memberikan performa terbaik dengan akurasi 87,63% dan F1-score 0,8947, diikuti MLP, KNN, dan SVM. Temuan ini menunjukkan bahwa kombinasi ekstraksi pose menggunakan MediaPipe dan metode ensemble seperti Random Forest mampu menghasilkan sistem klasifikasi postur duduk yang akurat serta dapat menjadi dasar pengembangan aplikasi monitoring ergonomi berbasis visi komputer.

Kata Kunci: Postur duduk, MediaPipe, Klasifikasi, Random Forest, Machine Learning.

1. PENDAHULUAN

Postur duduk yang tidak ergonomis dapat memicu gangguan muskuloskeletal seperti nyeri punggung, kelelahan otot, dan gangguan pada tulang belakang [1], [2]. Studi sebelumnya melaporkan bahwa 69% responden mengalami nyeri punggung akibat posisi duduk yang salah dalam durasi yang panjang [2]. Kondisi ini menunjukkan pentingnya sistem yang mampu mendeteksi postur duduk secara akurat dan *real-time* untuk mencegah risiko tersebut.

MediaPipe merupakan *framework* visi komputer yang mampu mendeteksi 33 titik pose tubuh manusia secara *real-time* menggunakan kamera [3], [4]. Teknologi ini telah banyak digunakan dalam penelitian untuk mendeteksi postur duduk, berdiri, maupun pose tubuh lainnya [4], [5]. Dibandingkan sensor fisik seperti ultrasonik dan flex sensor, *MediaPipe* menawarkan fleksibilitas yang lebih tinggi karena tidak membutuhkan perangkat keras tambahan dan dapat bekerja hanya dengan citra video [6].

Dalam pengolahan fitur hasil ekstraksi pose, algoritma pembelajaran mesin seperti *Random Forest* (RF), *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), dan *Multi-Layer Perceptron* (MLP) banyak digunakan. *Random Forest* dikenal *robust* terhadap *noise*, KNN cocok untuk dataset kecil, SVM efektif pada data berdimensi tinggi, sedangkan MLP mampu mempelajari pola non-linear yang kompleks [7], [8]. Namun, sebagian besar penelitian sebelumnya hanya menguji satu atau dua algoritma secara terpisah, sehingga belum tersedia evaluasi komprehensif yang secara langsung membandingkan keempat algoritma tersebut pada kasus pendeteksian postur duduk berbasis *MediaPipe*.

Berdasarkan hal tersebut, penelitian ini bertujuan membandingkan performa empat algoritma klasifikasi RF, KNN, SVM, dan MLP dalam mengidentifikasi dua kategori postur duduk, yaitu postur baik (*good form*) dan postur buruk (*bad form*). Evaluasi dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*.

Kontribusi utama penelitian ini adalah menyediakan evaluasi komprehensif terhadap performa keempat algoritma tersebut pada data postur duduk yang diekstraksi menggunakan *MediaPipe*. Penelitian ini menghasilkan baseline performa yang belum disajikan pada studi-studi sebelumnya, sehingga dapat menjadi acuan dalam pemilihan algoritma terbaik untuk sistem monitoring ergonomi berbasis citra dan memberikan rekomendasi model yang sesuai untuk mendukung implementasi sistem deteksi postur di lingkungan kerja maupun pendidikan secara *real-time*.

2. TINJAUAN PUSTAKA

Postur duduk yang buruk dapat memicu berbagai gangguan muskuloskeletal seperti nyeri punggung, ketegangan otot, dan kelelahan, terutama pada aktivitas duduk dalam waktu lama. Berbagai studi menunjukkan bahwa posisi duduk yang tidak ergonomis menjadi faktor risiko utama terjadinya low back pain sehingga diperlukan sistem monitoring postur yang mampu bekerja secara akurat dan berkelanjutan [1], [2].

MediaPipe merupakan *framework* visi komputer yang mampu mendeteksi 33 landmark tubuh manusia secara *real-time* hanya menggunakan kamera. Teknologi ini

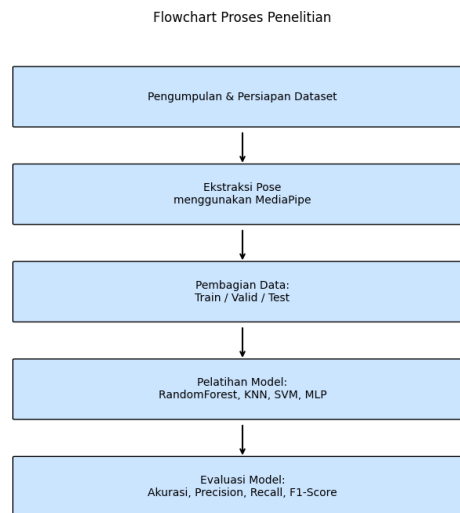
mulai banyak digunakan dalam penelitian terkait pendeteksian postur karena fleksibel, tidak membutuhkan perangkat keras tambahan, serta mampu menghasilkan data pose yang representatif untuk analisis berbasis pembelajaran mesin [3], [4], [5]. *MediaPipe* bekerja dengan mengekstraksi koordinat setiap landmark seperti bahu, pinggul, lutut, dan data ini dapat diolah lebih lanjut untuk mengidentifikasi apakah postur termasuk kategori ergonomis atau tidak [4], [5]. Keunggulan ini menjadikan *MediaPipe* lebih praktis dibanding pendekatan sensor fisik seperti ultrasonik atau flex sensor, yang memerlukan pemasangan perangkat khusus dan memiliki keterbatasan mobilitas [6].

Dalam proses klasifikasi berbasis *pose estimation*, beberapa algoritma pembelajaran mesin seperti RF, KNN, SVM, dan MLP umum digunakan. Sejumlah penelitian melaporkan bahwa *Random Forest* sering memberikan akurasi tertinggi pada tugas klasifikasi postur karena kemampuannya menangani fitur numerik berdimensi tinggi dan ketahanannya terhadap *noise* [5], [7], [8]. KNN diketahui memiliki performa *recall* yang baik, terutama dalam mengenali pola postur yang mirip, namun sensitif terhadap *outlier*. MLP mampu menghasilkan precision tinggi tetapi membutuhkan penyesuaian parameter yang tepat agar stabil. Sementara itu, performa SVM sangat bergantung pada pemilihan kernel dan parameter yang sesuai sehingga dapat lebih rendah jika tidak dilakukan tuning optimal [8], [9]. Penelitian lain juga menunjukkan bahwa kombinasi ekstraksi pose *MediaPipe* dengan algoritma *ensemble* seperti *Random Forest* efektif dalam mendeteksi pose tubuh secara otomatis [5], [9].

Meskipun berbagai studi telah membahas penggunaan *MediaPipe* dan algoritma pembelajaran mesin untuk pengenalan pose tubuh, penelitian yang secara khusus membandingkan performa empat algoritma tersebut pada konteks deteksi postur duduk masih terbatas. Selain itu, masih jarang ditemukan penelitian yang memanfaatkan dataset duduk statis berbasis citra dengan fitur pose berjumlah 132 nilai landmark seperti pada penelitian ini. Oleh karena itu, diperlukan studi komparatif yang memberikan gambaran performa setiap algoritma secara komprehensif sebagai dasar pengembangan sistem ergonomi berbasis citra yang lebih akurat dan mudah diimplementasikan.

3. METODE PENELITIAN

Penelitian ini dilakukan dalam beberapa tahapan: pengumpulan dan persiapan dataset, ekstraksi pose menggunakan *MediaPipe*, pembagian data, pelatihan model klasifikasi, serta evaluasi performa masing-masing model. Alur metodologi dapat dilihat pada Gambar 1.



Gambar 1. Flowchart

3.1. Dataset

Dataset yang digunakan dalam penelitian ini berasal dari *Roboflow Universe*, yaitu *Sitting Posture v2* dengan format anotasi *Pascal VOC* [10]. Dataset ini terdiri dari 1.086 gambar berformat *.jpg* dengan dua kelas yang seimbang, yaitu 543 gambar postur duduk baik (*good_form*) dan 543 gambar postur duduk buruk (*bad_form*). Dataset ini dipilih karena menyediakan variasi postur duduk dari berbagai sudut pengambilan gambar, kondisi pencahayaan, serta pose subjek, sehingga relevan untuk pengembangan model klasifikasi postur duduk berbasis citra.

Setelah dilakukan ekstraksi pose tubuh menggunakan *MediaPipe Pose*, hanya 483 gambar yang berhasil diproses dengan sempurna. Data yang tersisa terdiri dari 245 gambar kelas *good_form* dan 238 gambar kelas *bad_form*. Sebanyak 603 gambar lainnya gagal diproses karena *MediaPipe* tidak dapat mendeteksi *landmark* tubuh secara lengkap. Hal ini umum terjadi pada model *pose estimation* ketika sebagian tubuh tidak terlihat sepenuhnya di dalam frame, objek tertutup (*occlusion*), resolusi gambar rendah, atau sudut kamera yang ekstrem sehingga menyebabkan *landmark* sulit teridentifikasi. Kondisi-kondisi tersebut membuat proses ekstraksi pose tidak dapat menghasilkan 33 titik pose yang lengkap, sehingga gambar tersebut harus dikeluarkan dari dataset final.

3.2. Ekstraksi Fitur dengan *MediaPipe Pose*

Setiap gambar yang berhasil lolos proses seleksi kemudian diekstraksi menggunakan *MediaPipe Pose* untuk memperoleh 33 titik *landmark* tubuh manusia. Setiap *landmark* menghasilkan empat nilai berupa koordinat *x*, *y*, *z*, serta *visibility*, sehingga total diperoleh 132 fitur numerik dari setiap gambar. Seluruh fitur yang dihasilkan kemudian dikonversi dan disimpan dalam bentuk *array NumPy* untuk memudahkan proses pemrosesan data dan pelatihan model pembelajaran mesin.

MediaPipe dipilih sebagai metode ekstraksi pose karena memiliki kemampuan mendeteksi *landmark* tubuh secara cepat, akurat, dan stabil tanpa memerlukan

perangkat keras tambahan seperti depth sensor atau perangkat *wearable*. Selain itu, *MediaPipe* dapat bekerja hanya dengan input citra sehingga sesuai untuk sistem deteksi postur berbasis kamera biasa. Teknologi ini terbukti andal dalam berbagai penelitian visi komputer terkait deteksi pose tubuh, koreksi olahraga, serta pelacakan gerakan manusia [3], [11].

Untuk memastikan setiap fitur memiliki skala yang seragam, seluruh data hasil ekstraksi kemudian dinormalisasi menggunakan *StandardScaler*. Normalisasi ini penting terutama bagi algoritma seperti KNN, SVM, dan MLP yang sensitif terhadap perbedaan skala fitur dan dapat menghasilkan performa yang tidak seimbang jika data tidak melalui proses standarisasi. Dengan demikian, proses normalisasi dilakukan untuk meningkatkan stabilitas proses pelatihan dan membuat distribusi fitur lebih seragam sebelum digunakan pada tahap klasifikasi.

3.3. Pembagian Data

Data yang telah berhasil diekstrak dibagi menjadi tiga bagian, yaitu data pelatihan (*train*), validasi (*validation*), dan pengujian (*test*) dengan rasio 60:20:20 menggunakan metode *train_test_split()* dari pustaka *Scikit-learn*. Hasil pembagian ini memberikan 289 data pelatihan, 97 data validasi, dan 97 data pengujian. Proses pembagian dilakukan secara *stratified*, yaitu mempertahankan proporsi distribusi label *good_form* dan *bad_form* agar tetap seimbang dalam masing-masing subset. Hal ini penting untuk menjaga konsistensi distribusi label pada model.

Data yang telah berhasil diekstraksi kemudian dibagi menjadi tiga subset, yaitu data pelatihan (*train*), validasi (*validation*), dan pengujian (*test*) dengan rasio 60:20:20. Pembagian data dilakukan menggunakan fungsi *train_test_split()* dari pustaka *Scikit-learn* dengan metode *stratified split* untuk memastikan proporsi kelas *good_form* dan *bad_form* tetap seimbang pada setiap subset. Penggunaan rasio 60 persen untuk pelatihan dipilih karena ukuran dataset relatif kecil, sehingga diperlukan jumlah data latih yang lebih besar agar model dapat mempelajari pola secara lebih optimal. Sementara itu, porsi 20 persen masing-masing untuk data validasi dan data uji dinilai cukup untuk mengevaluasi performa model selama proses tuning maupun pada tahap pengujian akhir.

Proses pembagian data dilakukan secara dua tahap. Pertama, seluruh dataset dibagi menjadi data pelatihan dan data sementara (*train temp*) dengan *test_size*=0.40. Selanjutnya, data sementara dibagi kembali menjadi data validasi dan data uji dengan porsi yang sama menggunakan parameter *test_size*=0.50. Seluruh proses pembagian data menggunakan *random_state*=42 untuk memastikan hasil yang konsisten dan dapat direproduksi.

Pada hasil akhir pembagian, diperoleh 289 data pelatihan, 97 data validasi, dan 97 data pengujian. Distribusi kelas pada ketiga subset tetap proporsional karena metode *stratified split* memastikan keseimbangan jumlah data *good_form* dan *bad_form*. Selain itu, proses normalisasi menggunakan *StandardScaler* dilakukan setelah pembagian data,

di mana scaler difit hanya pada data pelatihan untuk mencegah terjadinya data *leakage*, kemudian diterapkan (*transform*) pada data validasi dan data uji.

3.4. Pelatihan dan Evaluasi Model

Empat algoritma pembelajaran mesin digunakan pada penelitian ini, yaitu RF, KNN, SVM, dan MLP. Pemilihan keempat algoritma ini didasarkan pada karakteristik masing-masing model. *Random Forest* dipilih karena memiliki ketahanan terhadap *noise*, stabil pada dataset dengan fitur numerik berdimensi tinggi, serta mampu menangani hubungan nonlinear melalui mekanisme *ensemble*. KNN digunakan karena efektif pada dataset berukuran kecil dan bekerja baik pada data dengan pola jarak yang jelas. SVM dipilih karena mampu membentuk *hyperplane* optimal pada data berdimensi tinggi, sedangkan MLP digunakan untuk mengevaluasi kemampuan jaringan saraf tiruan dalam mempelajari hubungan nonlinear yang lebih kompleks.

Dalam penelitian ini, seluruh model menerapkan kombinasi parameter *default* dari pustaka *scikit-learn*, kecuali beberapa parameter yang secara eksplisit disesuaikan pada kode, seperti *n_estimators*, *hidden_layer_sizes*, dan *kernel*. Konfigurasi tersebut digunakan sebagai *baseline* tanpa proses *hyperparameter tuning* karena fokus penelitian adalah membandingkan performa dasar masing-masing algoritma.

Proses pelatihan model dilakukan menggunakan data yang telah dinormalisasi dengan *StandardScaler*, sebagaimana dijelaskan pada subbab 3.3. Normalisasi diterapkan untuk memastikan setiap fitur memiliki skala yang sebanding sehingga model berbasis jarak (KNN, SVM) maupun jaringan saraf (MLP) dapat beroperasi secara optimal tanpa dipengaruhi variasi rentang nilai fitur.

Parameter dasar untuk setiap model ditunjukkan pada Tabel 1. Parameter tersebut dipilih sebagai konfigurasi *baseline* yang umum digunakan dalam penelitian klasifikasi pose tubuh. Misalnya, nilai *n_estimators* = 100 pada *Random Forest* dipilih karena memberikan stabilitas performa tanpa biaya komputasi yang berlebihan. Kernel RBF pada SVM digunakan karena mampu menangani pola nonlinear, sedangkan konfigurasi *hidden_layer_sizes* = (100,) pada MLP dipilih sebagai arsitektur dasar yang sering digunakan dalam eksperimen awal.

Tabel 1. Parameter utama model klasifikasi

Model	Parameter	Nilai
Random Forest	<i>n_estimators</i>	100
Random Forest	<i>max_depth</i>	None
KNN	<i>n_neighbors</i>	5
SVM	<i>kernel</i>	rbf
MLP	<i>hidden_layer_sizes</i>	(100,)
MLP	<i>max_iter</i>	500

Setiap model dilatih menggunakan data pelatihan, divalidasi menggunakan data validasi, dan diuji pada data uji. Evaluasi performa dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *f1-score*. Selain itu, *confusion matrix* digunakan untuk melihat

distribusi prediksi pada masing-masing kelas *good_form* dan *bad_form*. Seluruh proses pelatihan dan evaluasi dilakukan menggunakan pustaka *Scikit-learn*.

3.5. Skenario Percobaan

Skenario percobaan pada penelitian ini dirancang untuk membandingkan performa empat algoritma klasifikasi RF, KNN, SVM, dan MLP dalam mengenali dua kategori postur duduk berdasarkan fitur numerik hasil ekstraksi pose *MediaPipe*. Seluruh model diuji menggunakan dataset, *preprocessing*, rasio pembagian data, dan prosedur ekstraksi fitur yang sama agar proses evaluasi berlangsung secara adil (*fair comparison*). Pendekatan ini penting karena setiap algoritma memiliki karakteristik berbeda, sehingga penggunaan kondisi eksperimen yang konsisten memastikan bahwa variabel bebas satu-satunya adalah jenis model klasifikasi.

Variabel bebas pada percobaan ini adalah jenis algoritma yang digunakan, sedangkan variabel tetap mencakup dataset, metode *stratified split*, proses normalisasi *StandardScaler*, dan parameter ekstraksi pose pada *MediaPipe*. Penggunaan *stratified split* bertujuan menjaga konsistensi distribusi kelas pada data pelatihan, validasi, dan pengujian sehingga model tidak bias terhadap salah satu kelas. Normalisasi dilakukan untuk memastikan kesetaraan rentang nilai antar fitur, terutama bagi model berbasis jarak maupun jaringan saraf yang sensitif terhadap skala input.

Setiap model dilatih menggunakan konfigurasi baseline yang sama sebagaimana dijelaskan pada subbab 3.4. Pemilihan konfigurasi baseline bertujuan menyediakan titik acuan yang netral tanpa tuning berlebih, sehingga hasil perbandingan lebih objektif dan tidak dipengaruhi oleh optimasi parameter yang spesifik pada satu algoritma. Seluruh model kemudian divalidasi dan diuji menggunakan prosedur evaluasi yang seragam agar performa akhir menunjukkan kemampuan sebenarnya dari masing-masing algoritma dalam menangani data postur duduk berbasis *landmark*.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Evaluasi Model Klasifikasi

Penelitian ini mengklasifikasikan postur duduk menjadi dua kategori: *good_form* (postur baik) dan *bad_form* (postur buruk), berdasarkan fitur pose yang diekstrak dari citra menggunakan *MediaPipe*. Total data yang digunakan berjumlah 483 gambar hasil ekstraksi pose dari dataset *Roboflow* [10]. Data dibagi menjadi tiga subset: 60% data latih (289 gambar), 20% data validasi (97 gambar), dan 20% data uji (97 gambar), dengan metode *stratified split* agar distribusi label seimbang. Empat algoritma klasifikasi diuji yaitu RF, KNN, SVM, dan MLP. Evaluasi dilakukan menggunakan metrik klasifikasi: akurasi, *precision*, *recall*, dan *F1-score*. Hasil evaluasi pada data validasi ditampilkan pada Tabel 2.

Tabel 2. Evaluasi model pada data validasi

Model	Akurasi	Precision	Recall	F1-Score
Random Forest	82.47%	0.88	0.81	0.84
K-Nearest Neighbor	78.35%	0.79	0.86	0.82
Multi-Layer Perceptron	80.41%	0.88	0.77	0.82
Support Vector Machine	70.10%	0.71	0.82	0.76

4.2. Hasil Evaluasi Model pada Data Uji (Test Set)

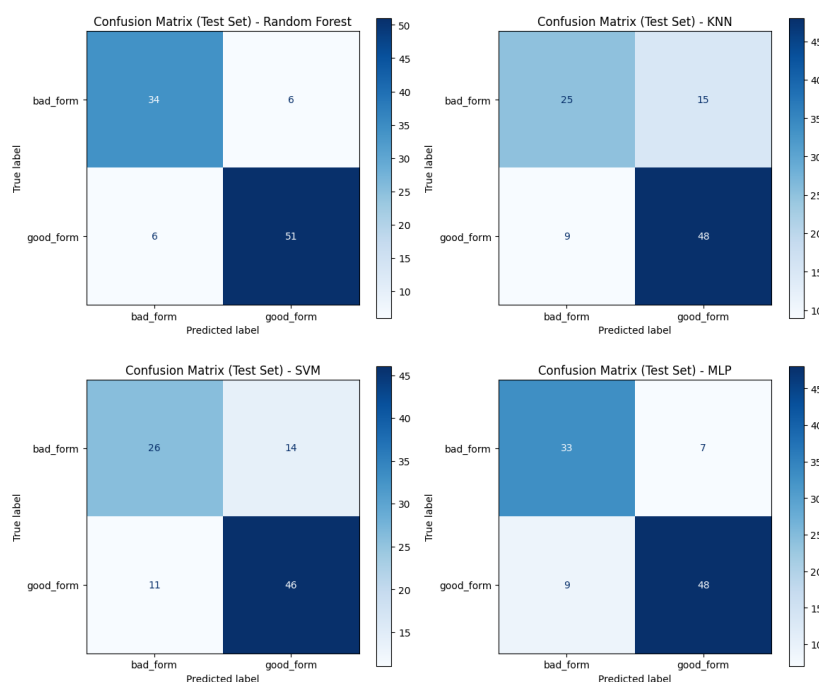
Setelah memperoleh hasil evaluasi pada data validasi, penelitian ini juga melakukan pengujian menggunakan 97 sampel *test set* untuk memastikan kemampuan generalisasi model. Evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil pada *test set* menunjukkan bahwa *Random Forest* memiliki performa terbaik dengan akurasi 87,63% dan *F1-score* 0,8947. Model MLP menyusul dengan akurasi 83,51%, sedangkan KNN dan SVM berada di bawahnya masing-masing dengan akurasi 75,26% dan 74,23%. Temuan ini mengindikasikan bahwa model *ensemble* seperti *Random Forest* lebih stabil dalam menangani variasi fitur pose tubuh dibandingkan metode lainnya. Hasil pengujian ditampilkan pada Tabel 3.

Tabel 3. Evaluasi model pada data uji

Model	Accuracy	Precision	Recall	F1-Score
Random Forest	0.8763	0.8947	0.8947	0.8947
K-Nearest Neighbor	0.7526	0.7619	0.8421	0.8000
Support Vector Machine	0.7423	0.7667	0.8070	0.7863
Multi-Layer Perceptron	0.8351	0.8727	0.8421	0.8571

4.3. Visualisasi Confusion Matrix


Untuk melihat pola kesalahan prediksi secara lebih mendalam, confusion matrix dari keempat model ditampilkan pada Gambar 2. Visualisasi ini memberikan gambaran seberapa baik masing-masing model membedakan kelas *good_form* dan *bad_form* pada data uji. Secara umum, *Random Forest* menunjukkan performa terbaik dengan jumlah kesalahan prediksi yang paling sedikit dan distribusi prediksi yang seimbang antar kelas. MLP juga menunjukkan kinerja yang stabil dengan hanya sedikit kesalahan pada kelas *bad_form*. Sementara itu, KNN dan SVM menghasilkan kesalahan prediksi yang lebih tinggi, khususnya pada kelas *bad_form*, dengan SVM menjadi model dengan performa terendah secara keseluruhan. Pola ini menunjukkan bahwa model *ensemble* seperti *Random Forest* lebih efektif dalam mengolah fitur pose tubuh dibandingkan pendekatan *nonensemble*.



Gambar 2. Confusion Matrix Model Random Forest, KNN, SVM, dan MLP

4.4. Perbandingan F1-score Antar Model

Pada grafik berikut menunjukkan bahwa *Random Forest* memperoleh *F1-score* tertinggi yaitu 0.8947, menandakan kinerjanya paling seimbang dalam mengklasifikasikan kedua kelas. MLP berada pada posisi kedua dengan *F1-score* 0.8571, menunjukkan performa yang stabil meskipun sedikit lebih rendah dari *Random Forest*. Sementara itu, KNN dan SVM memiliki *F1-score* yang lebih rendah, mengindikasikan bahwa kedua model tersebut kurang optimal dalam menangani variasi fitur pose tubuh dibandingkan model *ensemble* maupun jaringan saraf. Perbandingan nilai *F1-score* dari keempat model ditampilkan pada Gambar 3.



Gambar 3. Grafik Batang Perbandingan F1-score pada Data Uji

4.5. Pembahasan Perbandingan Model

4.5.1. Random Forest

Random Forest menjadi model dengan performa terbaik pada penelitian ini, dengan akurasi 87,63% dan *F1-score* 0,8947. Keberhasilan model ini dipengaruhi oleh

kemampuannya menangani 132 fitur numerik hasil ekstraksi *MediaPipe* secara stabil, serta sifat *ensemble* yang membuatnya lebih tahan terhadap noise pada landmark. Selain itu, *Random Forest* mampu mempelajari pola *nonlinear* antar titik pose tubuh sehingga prediksinya lebih presisi. Hasil ini konsisten dengan penelitian sebelumnya yang menunjukkan bahwa model berbasis *ensemble* sangat efektif dalam klasifikasi pose tubuh dan analisis *landmark* manusia [11], serta dapat memberikan performa tinggi pada berbagai tugas pengenalan postur [9].

4.5.2. K-Nearest Neighbor

Model *K-Nearest Neighbor* mencatat nilai *recall* tertinggi, yaitu 0,8421, yang menunjukkan kemampuannya dalam mengenali pola lokal pada data pose tubuh. Meski demikian, akurasi dan *F1-score* KNN masih lebih rendah dibandingkan *Random Forest* dan MLP. Hal ini terjadi karena KNN sangat sensitif terhadap *outlier* serta bergantung pada distribusi jarak antar fitur yang dapat berubah ketika landmark tubuh memiliki variasi kecil, sudut berbeda, atau titik pose tidak terdistribusi secara *linear*. Ketergantungan pada kedekatan jarak ini menyebabkan KNN mudah mengalami kesalahan klasifikasi pada pose duduk yang kompleks atau bervariasi.

4.5.3. Multi-Layer Perceptron

Support Vector Machine menjadi model dengan performa terendah dalam penelitian ini dengan akurasi 74,23%. Salah satu penyebabnya adalah kernel *Radial Basis Function* (RBF) yang kurang mampu menangkap pola *nonlinear* kompleks pada data pose hasil ekstraksi *MediaPipe* ketika parameter tidak dituning secara optimal. SVM memerlukan pemilihan parameter C dan gamma yang tepat agar dapat membentuk batas keputusan yang sesuai dengan distribusi *landmark* tubuh. Penelitian terkait penggunaan *MediaPipe* dan klasifikasi gerakan tubuh sebelumnya juga menunjukkan bahwa performa SVM sangat dipengaruhi oleh konfigurasi parameter serta sensitivitasnya terhadap variasi fitur pose [5]. Hal ini menjelaskan mengapa SVM tidak mampu mengungguli model lainnya dalam penelitian ini.

4.5.4. Support Vector Machine

Multi-Layer Perceptron menempati posisi kedua dengan *F1-score* 0,8571. Model ini unggul dalam mempelajari pola *nonlinear* pada data yang berdimensi tinggi, termasuk 132 fitur pose yang dihasilkan oleh *MediaPipe*. MLP mampu menggeneralisasi hubungan kompleks antar *landmark* sehingga prediksinya cukup stabil dan presisi. Namun, performanya sedikit di bawah *Random Forest* karena MLP membutuhkan *tuning parameter* yang lebih mendalam, seperti jumlah neuron, fungsi aktivasi, tingkat pembelajaran (*learning rate*), dan jumlah iterasi. Tanpa pengaturan hiperparameter yang optimal, model ini berisiko memberikan prediksi yang terlalu konservatif atau mengalami ketidakstabilan selama pelatihan. Studi sebelumnya juga menunjukkan bahwa pada data pose tubuh, model jaringan saraf dapat bekerja baik asalkan konfigurasi parameternya disesuaikan dengan kompleksitas fitur yang diolah [5].

5. KESIMPULAN

Penelitian ini berhasil membandingkan performa empat algoritma klasifikasi, yaitu *Random Forest*, *K-Nearest Neighbor*, *Support Vector Machine*, dan *Multi-Layer Perceptron* dalam mendeteksi postur duduk baik dan buruk berdasarkan 132 fitur pose hasil ekstraksi *MediaPipe*. Berdasarkan evaluasi model pada data uji, *Random Forest* menunjukkan performa paling unggul dengan akurasi dan *F1-score* tertinggi, menandakan kemampuannya yang lebih baik dalam mempelajari hubungan *nonlinear* antar *landmark* tubuh. MLP menempati posisi kedua dengan stabilitas prediksi yang baik, sedangkan KNN memiliki kelebihan pada *recall* namun kurang konsisten akibat sensitivitas terhadap *outlier*. SVM menjadi model dengan performa terendah karena keterbatasannya dalam mengenali pola pose kompleks tanpa *tuning* parameter yang optimal. Secara keseluruhan, hasil penelitian menunjukkan bahwa metode *ensemble* seperti *Random Forest* lebih sesuai untuk sistem deteksi postur berbasis *landmark MediaPipe*.

Kontribusi utama penelitian ini adalah penyediaan evaluasi komparatif yang komprehensif terhadap empat algoritma klasifikasi pada konteks deteksi postur duduk, sekaligus menawarkan baseline performa yang dapat menjadi acuan bagi pengembangan sistem monitoring ergonomi di masa mendatang. Untuk penelitian selanjutnya, disarankan penggunaan dataset yang lebih besar dan beragam, penambahan teknik augmentasi pose, serta eksplorasi model *deep learning* seperti CNN–LSTM atau *transformer pose-based* untuk menangani variasi postur yang lebih kompleks. Pengujian pada lingkungan nyata dan integrasi sistem secara *real-time* juga perlu dilakukan agar implementasi deteksi postur dapat diterapkan secara optimal pada konteks kerja maupun pendidikan.

DAFTAR PUSTAKA

- [1] M. M. Iskandar, F. Quzwain, P. W. Gading, and S. Tarawifa, “Penyuluhan Posisi Duduk Yang Benar Untuk Kesehatan Punggung Bagi Masyarakat Awam,” *MEDIC*, no. 2, pp. 121-125, 2020.
- [2] J. K. Wijaya, N. Sari, and M. Zulkarnain, “Analisis Risiko Postur Duduk dan Aktivitas Fisik Dengan Keluhan Low Back Pain pada Mahasiswa Universitas X Kota Batam Tahun 2023,” *Health Information : Jurnal Penelitian*, vol. 15, no. 2, 2023.
- [3] D. N. Hidayat, “Deteksi posisi gerakan duduk dan berdiri pada tubuh manusia dengan video realtime menggunakan *MediaPipe*,” Proyek Akhir (Diploma), Universitas Telkom, 2023.
- [4] A. N. N. Afifah and A. A. M. Suradi, “Sistem deteksi postur duduk berbasis *MediaPipe* untuk meningkatkan ergonomi dan kesehatan pekerja,” dalam *Prosiding Seminar Ilmiah Sistem Informasi dan Teknologi Informasi*, Pusat Penelitian dan Pengabdian kepada Masyarakat (P3M), Universitas Dipa Makassar, pp. 168-174, Feb. 2025.

- [5] I. Nurdiansyah, R. Utami, and M. Sandy, "Machine Learning System untuk Mendeteksi Gerakan Tubuh Menggunakan Library Mediapipe," *FORMAT: Jurnal Ilmiah Teknik Informatika*, vol. 14, no. 1, pp. 81-89, Jan. 2025.
- [6] S. Indayana and E. R. Widasari, "Sistem Deteksi Postur Duduk Menggunakan Sensor Ultrasonik Dan Flex Sensor Berbasis Arduino Uno," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 1, Jan. 2017, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [7] I. K. Hasan, R. Resmawan, and J. Ibrahim, "Perbandingan K-Nearest Neighbor dan Random Forest dengan Seleksi Fitur Information Gain untuk Klasifikasi Lama Studi Mahasiswa," *Indonesian Journal of Applied Statistics*, vol. 5, no. 1, pp. 58-66, May 2022, doi: 10.13057/ijas.v5i1.58056.
- [8] M. F. Naufal, "Analisis Perbandingan Algoritma Svm, Knn, Dan Cnn Untuk Klasifikasi Citra Cuaca," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 8, no. 2, pp. 311-318, Mar. 2021, doi: 10.25126/jtiik.202184553.
- [9] K. V. Tej, M. M. Krishna, K. S. Kumar, and T. K. Kumar, "Intelligent posture assessment using machine learning," *Journal of Computational Analysis and Applications*, vol. 33, no. 6, pp. 722-726, Jun. 2024.
- [10] Min, "Sitting Posture v2 Dataset," *Roboflow Universe*, 2025. [Online]. Available: <https://universe.roboflow.com/min-bnvzi/sitting-posture-v2>. [Accessed: Jan. 3, 2026].
- [11] E. Martinez-Martin and A. Fernández-Caballero, "Improved human emotion recognition from body and hand pose landmarks on the GEMEP dataset using machine learning," *Expert Systems with Applications*, 2025, doi: 10.1016/j.eswa.2025.126427.