

BAB I

PENDAHULUAN

1.1 Latar Belakang

Teknologi *wearable* telah menghadirkan perubahan besar dalam cara kita memantau kesehatan dan kebugaran [1]. Perangkat *wearable* seperti *smartwatch* yang dilengkapi dengan *tracker* aktivitas kini memberikan informasi penting terkait kesehatan secara lebih mudah dan praktis. Berbeda dengan tes kesehatan secara konvensional pada fasilitas kesehatan yang hanya dilakukan beberapa kali dalam setahun, perangkat *wearable* memungkinkan akses secara kontinu ke data fisiologis secara *real-time* yang memudahkan pemantauan kondisi tubuh setiap saat [2].

Pada tahun 2020, sekitar 19% orang Amerika menggunakan perangkat *wearable* berupa *smartwatch* untuk memantau kebugaran, seperti Apple Watch dan Fitbit yang diperkirakan penjualannya akan meningkat dua kali lipat pada tahun 2022, sehingga pasar tersebut diproyeksikan mencapai lebih dari \$27 miliar [3]. Menurut laporan dari Gartner, Inc., pengeluaran global untuk perangkat *wearable* diperkirakan mencapai \$93,858 miliar pada tahun 2022, meningkat 15,14% dari \$81,499 miliar pada tahun sebelumnya. Sebagian besar pertumbuhan ini didorong oleh semakin banyaknya pengguna baru yang mulai memanfaatkan perangkat *wearable*, khususnya *smartwatch* yang penjualannya meningkat 21,33% dari tahun sebelumnya menjadi \$31,337 miliar pada tahun 2022 [4]. Meskipun pasar *smartwatch* telah ada selama bertahun-tahun, perangkat tersebut baru belakangan ini diterapkan dalam bidang layanan kesehatan [5].

Sebagian besar perangkat *smartwatch* awalnya hanya digunakan untuk mengumpulkan data langkah harian, namun dengan kemajuan teknologi yang pesat, kini pengguna dapat dengan mudah mengumpulkan berbagai informasi seperti, lama waktu berdiri, pergerakan tubuh, waktu dan jenis latihan fisik, pemantauan tidur, detak jantung (*heart rate*), jumlah kalori terbakar dan yang terbaru yaitu saturasi oksigen (SpO2) [6]. Kemampuan ini menjadikan *smartwatch* sebagai salah satu alat yang sangat potensial untuk mendukung penelitian kesehatan, termasuk dalam klasifikasi jenis aktivitas fisik menggunakan metode *machine learning*.

Machine Learning merupakan bidang ilmu yang mempelajari algoritma dan model statistik yang digunakan oleh sistem komputer untuk menyelesaikan tugas tertentu tanpa memerlukan instruksi langsung, melainkan mengandalkan pola dan inferensi [7]. Salah satu pendekatan utama dalam *machine learning* yaitu klasifikasi yang bertujuan untuk menentukan kategori atau kelas dari sekumpulan data berdasarkan ciri-ciri atau fitur yang dimilikinya. Metode ini biasanya digunakan untuk memprediksi label kelas dari objek berdasarkan informasi yang ada dalam kumpulan data [8]. Salah satu metode yang sering digunakan untuk klasifikasi adalah Support Vector Machine yang terbukti efektif untuk berbagai aplikasi klasifikasi, termasuk dalam bidang kesehatan. SVM memiliki kemampuan untuk mengolah data dengan dimensi tinggi dan menghasilkan model klasifikasi yang akurat dan tepat [9]. Metode tersebut memanfaatkan fungsi kernel untuk mencari *hyperplane* optimal yang memaksimalkan margin antar kelas dalam ruang fitur, sehingga dapat menghasilkan performa klasifikasi yang tinggi. Support Vector Machine sangat berguna dalam menangani data linear maupun nonlinear, serta data dengan dimensi tinggi, sehingga mampu mengatasi berbagai masalah klasifikasi yang kompleks [10].

Dalam penelitian ini [11], perangkat *wearable* seperti Apple Watch Series 2 dan Fitbit Charge HR 2 digunakan untuk memprediksi aktivitas fisik dengan tujuan untuk mendeteksi dan mengklasifikasikan berbagai jenis aktivitas, seperti berbaring (*lying*), duduk (*sitting*), berjalan santai (*self pace walk*), lari 3 METs, lari 5 METs, dan lari 7 METs. Perangkat *wearable* ini dilengkapi dengan sensor accelerometer yang memungkinkan pengumpulan data gerakan tubuh secara akurat. Data yang dikumpulkan kemudian dianalisis dengan menggunakan tiga metode *machine learning*, yaitu Support Vector Machine (SVM), Random Forest, dan Rotation Forest. Hasil penelitian menunjukkan bahwa SVM memiliki akurasi terendah pada kedua perangkat *wearable* dibandingkan dengan metode lainnya, dengan akurasi sebesar 50,87% untuk Apple Watch dan 56,66% untuk Fitbit.

Untuk mengatasi rendahnya akurasi yang diperoleh pada pemodelan Support Vector Machine (SVM), teknik optimasi dapat diterapkan untuk meningkatkan performa model. Optimasi adalah proses untuk menemukan solusi terbaik dengan mempertimbangkan berbagai batasan yang ada. Dalam *machine learning*, optimasi

sering digunakan untuk mencari *hyperparameter* terbaik agar model dapat mencapai akurasi yang maksimal. Oleh karena itu, optimasi sangat penting untuk meningkatkan efisiensi dan akurasi model [12].

Metode optimasi yang banyak digunakan yaitu metode metaheuristik yang merupakan jenis algoritma stokastik. Metode ini memberikan hasil yang lebih akurat dan andal untuk masalah optimasi kompleks dengan menggunakan strategi adaptif yang tidak bergantung pada masalah tertentu. Istilah '*meta*' dalam metaheuristik mengacu pada pendekatan yang lebih canggih dan kompleks dibandingkan dengan algoritma heuristik tradisional [13]. Pada metode heuristik awalnya iteratif dan dirancang untuk masalah tertentu. Namun, seiring berjalannya waktu, algoritma berbasis populasi terbukti lebih efektif dalam menyelesaikan berbagai jenis masalah. Hal ini menjadikan algoritma metaheuristik sebagai pilihan utama bagi banyak peneliti dalam dua dekade terakhir, berkat kinerjanya yang unggul dan aplikatif dalam berbagai bidang [14].

Salah satu metode metaheuristik yang paling banyak digunakan dan disitasi pada *Google Scholar* yaitu Particle Swarm Optimization (PSO) yang memiliki lebih dari 75.000 sitasi [15]. PSO merupakan sebuah algoritma optimasi yang terinspirasi dari perilaku sosial kelompok hewan. Dalam algoritma ini, sekelompok solusi kandidat yang disebut partikel bergerak dalam ruang pencarian multidimensi untuk menemukan solusi optimal. Setiap partikel memperbarui posisinya dengan mengacu pada pengalaman terbaik yang pernah dicapainya (*local best*) dan informasi posisi terbaik yang ditemukan oleh partikel lain dalam kelompok (*global best*). Melalui interaksi antar partikel dan pertukaran informasi, PSO akan menemukan solusi terbaik untuk permasalahan optimasi yang kompleks [16]. Selain itu, algoritma ini dapat mengoptimalkan bobot pada setiap atribut, termasuk dalam proses pemilihan atribut dan fitur yang saling terkait [17].

Menurut penelitian [18], penggunaan algoritma Particle Swarm Optimization (PSO) untuk meningkatkan kinerja klasifikasi penyakit jantung menggunakan K-Nearest Neighbor (KNN) dan C4.5 dengan dataset dari Kaggle. Hasil pengujian menunjukkan bahwa penggunaan PSO meningkatkan akurasi model KNN hingga 89,09% dan C4.5 hingga 86,91%. PSO juga membantu dalam seleksi fitur, meningkatkan presisi, recall, dan AUC, serta mengurangi kesalahan klasifikasi.

Penelitian ini menunjukkan bahwa PSO efektif dalam meningkatkan performa klasifikasi penyakit jantung, meskipun menggunakan alat sederhana seperti RapidMiner.

Selanjutnya, dalam penelitian [19], membahas mengenai penerapan algoritma Particle Swarm Optimization (PSO) untuk mengoptimalkan *hyperparameter* pada model *machine learning* dalam memprediksi risiko COVID-19. Penelitian ini menggunakan dataset yang mencakup berbagai karakteristik klinis dan epidemiologis terkait dengan kasus COVID-19, dan menguji beberapa model *machine learning* seperti Random Forest, Decision Tree, SVM, KNN, MLP, dan Artificial Neural Networks. Hasil penelitian menunjukkan bahwa model yang dioptimasi dengan PSO memberikan akurasi yang lebih baik dibandingkan model dasar.

Pada penelitian [20], menguji efektivitas tiga algoritma klasifikasi yaitu ID3, Naïve Bayes, dan Support Vector Machine yang dioptimalkan dengan Particle Swarm Optimization (PSO) untuk mendeteksi serangan jantung. Hasil penelitian menunjukkan bahwa akurasi model ID3 setelah optimasi meningkat menjadi 80,49%, Naïve Bayes meningkat menjadi 83,94%, dan SVM meningkat menjadi 84,83%. Hasil ini menunjukkan bahwa PSO efektif dalam meningkatkan kinerja ketiga algoritma, dengan akurasi tertinggi dicapai oleh kombinasi SVM + PSO.

Dari beberapa penelitian yang telah dibahas sebelumnya, penelitian ini dibuat dengan tujuan mengoptimalkan *hyperparameter* metode Support Vector Machine menggunakan algoritma Particle Swarm Optimization untuk meningkatkan akurasi dalam klasifikasi aktivitas fisik berdasarkan data yang diperoleh dari perangkat Apple Watch dan Fitbit yang telah tersedia pada penelitian sebelumnya. Proses optimasi difokuskan pada pencarian konfigurasi *hyperparameter* terbaik, seperti pemilihan jenis kernel, nilai *hyperparameter* regularisasi (C), dan nilai gamma (γ) yang berperan penting dalam meningkatkan performa model. Performa klasifikasi sebelum dan sesudah optimasi akan dianalisis dan dibandingkan untuk mengevaluasi kontribusi algoritma Particle Swarm Optimization dalam meningkatkan akurasi klasifikasi aktifitas fisik.

1.2 Rumusan Masalah

Pada penelitian sebelumnya, metode SVM menunjukkan akurasi klasifikasi yang lebih rendah dibandingkan metode Random Forest dan Rotation Forest dalam memprediksi jenis aktivitas fisik. Hal ini disebabkan oleh pemilihan *hyperparameter* yang kurang optimal, sehingga berdampak pada performa model. Dalam penelitian ini, algoritma PSO diterapkan sebagai teknik optimasi *hyperparameter* untuk menghasilkan model SVM yang lebih akurat dalam klasifikasi aktivitas fisik.

Penelitian ini difokuskan pada klasifikasi aktivitas fisik berdasarkan data yang diperoleh dari website Harvard Dataverse, yang dikumpulkan menggunakan dua perangkat wearable yaitu Apple Watch dan Fitbit. Dataset yang digunakan terdiri dari 18 atribut dengan total 6.264 baris data dan memiliki variabel target berupa enam label aktivitas, yaitu *lying*, *sitting*, *self pace walk*, *running 3 METs*, *running 5 METs*, dan *running 7 METs*. Metode klasifikasi yang digunakan adalah SVM dengan kernel Radial Basis Function (RBF), dan *hyperparameter C* serta *gamma* dioptimasi menggunakan algoritma PSO selama 50 iterasi. Implementasi dilakukan menggunakan bahasa pemrograman Python dengan pustaka scikit-learn untuk SVM dan *pyswarm* untuk PSO. Evaluasi performa model dilakukan dengan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*.

1.3 Tujuan Penelitian

1. Mengoptimalkan pemilihan *hyperparameter* metode SVM menggunakan Algoritma PSO untuk meningkatkan akurasi dalam klasifikasi aktivitas fisik pada data Apple Watch dan Fitbit.
2. Membandingkan performa klasifikasi aktivitas fisik pada data Apple Watch dan Fitbit menggunakan model SVM tanpa optimasi dan SVM yang telah dioptimasi dengan PSO.

1.4 Manfaat Penelitian

Manfaat penelitian ini adalah memberikan wawasan mengenai penerapan algoritma PSO untuk mengoptimalkan *hyperparameter* model SVM dalam klasifikasi aktivitas fisik, serta menjadi referensi bagi penelitian selanjutnya di bidang kesehatan dan kebugaran.