



KLASIFIKASI TINGKAT STRES PADA DATASET AFFECTNET MENGUNAKAN HOG, SVM, DAN PSO

Nikko Riestian Putra Wardoyo¹, Bentar Candra Perdana², Anisah Nabilah³

^{1,3}. Program Studi Informatika, Universitas PGRI Jombang, ². Program Studi Sistem Informasi, Universitas PGRI Jombang

Jln. Pattimura III No.20, Sengon, Kec. Jombang, Kabupaten Jombang, Jawa Timur 61414

¹ ncool750@gmail.com, ² ar.bent989@gmail.com, ³ anisahl1nabilah@gmail.com

Abstract

Stress level recognition through facial expressions is a major challenge in affective computing due to subtle muscle deformation and highly imbalanced datasets. This research aims to propose and evaluate an unbiased stress detection architecture using Undersampling techniques, Histogram of Oriented Gradients (HOG) feature extraction, and Particle Swarm Optimization (PSO) on the Support Vector Machine (SVM) classifier. The AffectNet dataset was balanced through Undersampling to enforce an absolute 50:50 ratio between Stress and Non-Stress classes. HOG was applied to extract the orientation of facial gradients, while PSO was tasked with optimizing the hyperparameter penalty (C) and the gamma value of the SVM RBF kernel function. The results showed that standard SVM classification produced a major baseline gap with a Non-Stress class recall rate of only 1%. After applying the Undersampling technique and PSO optimization with 30 iterations, the system successfully detected optimal parameters and produced an unbiased accuracy of 59.67%. Although the global accuracy percentage decreased compared to the accuracy paradox often seen in imbalanced data, the recall value in the minority class increased significantly to 25%, with stress detection reaching 96%. In conclusion, the proposed architecture successfully eliminated majority class bias, accelerated feature extraction time to a millisecond scale, and effectively automated the SVM parameter search, making it a strong foundation for sustainable psychological detection systems.

Keywords: stress detection, HOG extraction, PSO optimization, support vector machine, undersampling

Abstrak

Pengenalan tingkat stres melalui ekspresi wajah merupakan tantangan besar dalam komputasi afektif akibat deformasi otot yang samar dan dataset yang sangat timpang. Penelitian ini bertujuan untuk mengusulkan dan mengevaluasi arsitektur deteksi stres yang tidak bias menggunakan teknik Undersampling, ekstraksi fitur Histogram of Oriented Gradients (HOG), dan Particle Swarm Optimization (PSO) pada klasifikasi Support Vector Machine (SVM). Dataset AffectNet diseimbangkan melalui Undersampling untuk memaksakan rasio 50:50 yang absolut antara kelas Stres dan Tidak Stres. Fitur HOG diterapkan untuk mengekstraksi orientasi gradien wajah, sementara PSO bertugas mengoptimasi penalti hyperparameter (C) dan nilai gamma dari fungsi kernel SVM RBF. Hasil penelitian menunjukkan bahwa klasifikasi SVM standar menghasilkan jarak baseline yang besar dengan tingkat recall kelas Tidak Stres yang hanya mencapai 1%. Setelah menerapkan teknik Undersampling dan optimasi PSO dengan 30 iterasi, sistem berhasil mendeteksi parameter optimal dan menghasilkan akurasi yang tidak bias (unbiased accuracy) sebesar 59,67%. Meskipun persentase akurasi global tampak menurun dibandingkan dengan akurasi semu (accuracy paradox) yang sering muncul pada data timpang, nilai recall pada kelas minoritas meningkat signifikan hingga 25%, dengan deteksi stres mencapai 96%. Kesimpulannya, arsitektur yang diusulkan berhasil mengeliminasi bias kelas mayoritas, mempercepat waktu ekstraksi fitur menjadi skala milidetik,



dan secara efektif mengotomatiskan pencarian parameter SVM, menjadikannya landasan yang kuat untuk sistem pendeteksi psikologis yang berkelanjutan.

Kata kunci : *deteksi stres, ekstraksi HOG, optimasi PSO, support vector machine, undersampling*

1. PENDAHULUAN

Emosi merupakan bagian tak terpisahkan dari dinamika kehidupan manusia yang secara natural terefleksikan melalui ekspresi wajah, baik secara sadar maupun spontan, ketika individu berinteraksi dengan lingkungannya. Dalam konteks psikologi modern dan paradigma human-computer interaction yang berbasis pada komputasi yang berpusat pada manusia (human-centered computing), pengenalan ekspresi wajah telah menjadi medium komunikasi nonverbal yang paling krusial untuk mengidentifikasi kondisi psikologis dan afektif seseorang, salah satunya adalah tingkat stres. Stres yang tidak terdeteksi secara dini, terutama pada lingkungan akademik maupun lingkungan kerja profesional, secara kumulatif dapat memicu penurunan performa kognitif, kelelahan mental (burnout), hingga gangguan kesehatan fisiologis dan psikologis yang jauh lebih serius. Oleh karena itu, kemampuan untuk mengenali indikator stres melalui perubahan mikroskopis maupun makroskopis pada otot wajah menjadi sebuah urgensi. Sayangnya, deteksi stres melalui observasi mata telanjang oleh manusia memiliki tingkat subjektivitas yang tinggi dan sangat rentan terhadap kesalahan interpretasi, terutama karena durasi kemunculan ekspresi yang sering kali sangat singkat dan intensitasnya yang secara sadar disembunyikan oleh individu tersebut.

Berangkat dari permasalahan fundamental inilah, intervensi teknologi berbasis Computer Vision dan Machine Learning sangat dibutuhkan untuk mengotomatiskan proses deteksi stres secara objektif, presisi, dan dapat diandalkan secara real-time. Dalam domain Affective Computing, keberhasilan proses pengenalan ekspresi wajah umumnya sangat bergantung pada kualitas arsitektur ekstraksi fitur yang harus mampu menangkap detail perubahan tekstur dan bentuk geometri wajah, terlepas dari berbagai gangguan visual eksternal. Salah satu metode ekstraksi fitur yang telah terbukti handal dalam merepresentasikan struktur objek visual secara matematis adalah Histogram of Oriented Gradients (HOG) [11]. Algoritma HOG beroperasi dengan cara menghitung kemunculan orientasi gradien tepi pada jaringan sel lokal dari sebuah citra. Berbeda

dengan pendekatan ekstraksi piksel mentah yang membebani komputasi memori secara masif, HOG terbukti sangat tangguh terhadap variasi pencahayaan (illumination invariance) dan perubahan pose geometri yang minor karena beroperasi pada sel-sel lokal yang dinormalisasi secara tumpang tindih (overlapping blocks). Dalam konteks deteksi stres, HOG diklaim mampu menangkap kerutan halus pada dahi, perubahan sudut bibir, serta penyempitan kelopak mata yang sering kali menjadi indikator universal dari kondisi emosional negatif.

Setelah fitur geometris yang merepresentasikan wajah berhasil diekstraksi, tantangan komputasi krusial selanjutnya adalah memilih algoritma klasifikasi yang memiliki kapabilitas untuk memisahkan ruang fitur berdimensi tinggi tersebut ke dalam kelas-kelas afektif yang relevan. Support Vector Machine (SVM) saat ini masih diakui sebagai salah satu algoritma Supervised Learning yang paling presisi dan tangguh untuk menangani klasifikasi pola visual yang kompleks [14]. Konsep dasar secara matematis dari SVM adalah menemukan sebuah optimal separating hyperplane atau bidang pemisah optimal yang memiliki margin terbesar antara dua atau lebih kelas data yang berbeda, dalam konteks penelitian ini adalah kelas "Stres" dan "Tidak Stres". Untuk mengatasi distribusi data citra wajah di dunia nyata yang secara inheren bersifat non-linear dan tidak dapat dipisahkan secara linier, SVM memanfaatkan fungsi pemetaan yang dikenal sebagai Kernel Trick, di mana Radial Basis Function (RBF) menjadi pilihan arsitektur utama karena kemampuannya memetakan titik data ke ruang dimensi tidak terbatas secara efisien secara komputasi [13].

Meskipun fondasi algoritmik SVM terbilang solid, performa klasifikasinya dengan kernel RBF sangat bergantung secara absolut pada pemilihan konfigurasi hyperparameter, yakni parameter penalti (Cost atau C) yang berfungsi mengatur toleransi batas kesalahan klasifikasi terhadap sampel data pelatihan, serta parameter kernel (gamma) yang menentukan radius fungsionalitas dan area pengaruh dari setiap sampel data latih pendukung (support vector) [14]. Pemilihan



kombinasi hyperparameter ini pada model klasifikasi SVM yang dilakukan secara manual melalui pendekatan heuristik taktis (trial and error) atau menggunakan metode pencarian spasial konvensional seperti Grid Search merupakan proses yang sangat tidak efisien. Metode tersebut menuntut konsumsi waktu komputasi secara eksponensial, terlebih lagi ketika berhadapan dengan ukuran dataset citra berskala masif. Jika parameter yang dipilih tidak mencapai titik optimal, model SVM dipastikan akan dengan mudah terjebak pada kondisi overfitting (terlalu kaku dalam menghafal pola data latih namun gagal secara fatal dalam memprediksi data uji baru) atau sebaliknya, mengalami underfitting (gagal total dalam mengenali varians pola dasar data) [17].

Untuk menyelesaikan masalah inefisiensi pada algoritma optimasi parameter komputasi ini, diperlukan sebuah pendekatan perancangan optimasi terintegrasi berbasis metaheuristic yang memiliki kapasitas untuk menjelajahi ruang pencarian hyperparameter secara lebih cerdas, dinamis, dan otomatis. Particle Swarm Optimization (PSO) diajukan dalam penelitian ini sebagai solusi algoritmik berbasis kecerdasan kawanan (swarm intelligence) yang terinspirasi secara biologis dari perilaku pergerakan sosial harmonis kawanan burung (flock of birds) atau sekumpulan ikan (school of fish) ketika menelusuri sumber makanannya. Dalam arsitektur optimasi komputasi, setiap individu partikel di dalam populasi PSO direpresentasikan sebagai satu titik solusi potensial dari kombinasi parameter (C dan Gamma). Entitas partikel tersebut kemudian akan secara iteratif berotasi dan bergerak di dalam topologi ruang dimensi pencarian global. Secara matematis, populasi ini memperbarui vektor kecepatan komputasi dan pemetaan posisi matriks mereka dengan mengevaluasi fungsi kebugaran (fitness function), didasarkan pada retensi memori pengalaman terbaik individu secara personal (pbest) serta pengalaman posisi terbaik yang direkam dari seluruh kawanan (gbest), hingga sistem akhirnya konvergen dalam menemukan parameter tunggal yang secara empiris memproduksi tingkat eror klasifikasi terendah.

Lebih lanjut, selain dari isu kompleksitas optimasi arsitektur jaringan Machine Learning, penelitian komputasi afektif ini juga mengkaji secara kritis satu tantangan struktural fundamental dalam penerapan pengenalan wajah pada kondisi tidak terkontrol di dunia nyata (in the wild), yakni fenomena imbalanced dataset atau ketimpangan

jumlah sampel representatif antar kelas observasi [16]. Riset ini diuji secara spesifik dengan memanfaatkan kumpulan data publik berskala masif, yakni AffectNet, yang secara global diakui sebagai salah satu repositori pangkalan data ekspresi wajah manusia terbesar dan paling komprehensif hingga saat ini. Namun, terdapat sebuah dilema pada saat ekspresi wajah tersebut diagregasi dan dikelompokkan menjadi dua poros makro-kelas biner (yakni mengelompokkan sampel happy dan neutral menjadi kelas "Tidak Stres", yang dihadapkan dengan agregasi sampel anger, disgust, fear, serta sad ke dalam kelas proksimal "Stres"). Pengelompokan makro ini seketika memicu disparitas volume sampel yang sangat ekstrem antara kedua spektrum tersebut. Secara statistik dan matematis komputasi, ketimpangan ekstrem ini telah terbukti di berbagai literatur memicu terjadinya patologi evaluasi metrik yang disebut sebagai Accuracy Paradox (Akurasi Semu). Kondisi ini terjadi manakala model klasifikasi Machine Learning yang diuji seolah-olah terlihat memiliki presentasi akurasi metrik evaluasi yang sangat tinggi secara global, padahal secara analitik algoritma tersebut pada dasarnya terdegradasi menjadi agen pasif yang sekadar melakukan penugasan probabilitas mayoritas secara buta (majority bias blind guessing) terhadap kelas dominan, dan secara sistematis gagal secara total dalam merepresentasikan sensitivitas (nilai recall) terhadap pengenalan kelas minoritas. Guna mengatasi patologi arsitektur ini secara menyeluruh, desain metodologi dalam eksperimen ini mengintegrasikan intervensi pemrosesan pra-klasifikasi yakni metode Undersampling mekanis, guna mereduksi secara proporsional dan acak sampel dari kelas mayoritas untuk memaksakan keseimbangan distribusi vektor yang absolut, sebelum dilakukannya fasa optimasi PSO dan training fungsi SVM [15].

Bertitik tolak dari manifestasi latar belakang permasalahan psikologi di atas, pengamatan mendalam dan rasional secara empiris terhadap disfungsi dan tantangan komputasi, serta analisis research gap atau identifikasi kesenjangan evaluasi terhadap batasan pada pendekatan metode konvensional terdahulu, maka formulasi sasaran dan tujuan mendasar dari studi riset ini adalah untuk mengusulkan kerangka kerja baru. Penelitian ini merumuskan dan menguji arsitektur fusi peningkatan akurasi klasifikasi dan pemisahan kelas tingkat stres komputasional pada wajah subjek uji. Proses klasifikasi algoritma dasar



Support Vector Machine (SVM) secara fungsional dioptimasi ruang pencariannya menggunakan intervensi kawanan Particle Swarm Optimization (PSO), sekaligus disokong oleh metode ekstraksi Histogram of Oriented Gradients (HOG) yang beroperasi khusus pada prasyarat kondisi matriks data citra yang telah diseimbangkan (balanced). Implementasi pemotongan kelas melalui Undersampling ditujukan secara krusial untuk memastikan bahwa persentase akurasi global dan recall yang dikuantifikasi oleh arsitektur model ini merupakan validasi representasi murni tak bias (unbiased honest accuracy) dari kemampuan inheren sang algoritma dalam menelaah pergeseran matriks fitur, bukan sekadar sebuah anomali output statistik semu akibat determinasi rasio dominasi fiktif dari kelas sampel tertentu. Adapun target kontribusi praktis yang diharapkan untuk dapat diwujudkan dari formulasi riset eksperimental komprehensif ini adalah kesuksesan pembentukan sebuah cetak biru fondasi model komputasi yang kokoh (robust), mampu memangkas waktu operasional ekstraksi fitur pada komputasi lokal, serta dibekali parameter generalisasi tingkat lanjut. Pada konfigurasi masa mendatang, fusi arsitektur cerdas ini sangat potensial untuk diadopsi lebih lanjut sebagai kerangka landasan teknologi pemantauan kondisi fluktuasi psikologis real-time nirsentuh, yang memfasilitasi integrasinya untuk membantu instansi tenaga pendidik, analis psikolog, maupun pakar praktisi medik dalam mengeksekusi tahapan mitigasi maupun tindakan restorasi preventif terhadap individu atau kelompok pengguna yang terindikasi secara komputasional mengalami gejala stres klinis.

2. TINJAUAN PUSTAKA

Penelitian di bidang rancang bangun sistem pengenalan afektif, klasifikasi representasi emosi wajah (facial emotion recognition), serta spesialisasi deteksi kondisi indikator psikologis manusia yang disokong oleh intervensi pemodelan komputasi analitik telah mengalami progresivitas perluasan penelitian yang sangat masif dalam kurun satu dekade terakhir. Transformasi teknologi paradigma ini terjadi seiring dengan percepatan eksponensial di domain teori Machine Learning dan kemajuan infrastruktur komputasi Computer Vision. Melalui tinjauan rekam jejak literatur yang terdokumentasi, berbagai pendekatan algoritma telah diajukan serta dievaluasi kinerjanya secara

akademis dalam mengatasi rintangan teknis yang dominan di ranah Affective Computing. Tantangan utama yang secara persisten dihadapi oleh para periset meliputi metodologi ekstraksi matriks fitur dari struktur dimensi wajah subjek agar dapat menafsirkan spektrum defleksi emosi secara numerik presisi, serta pemilihan arsitektur model klasifikasi pemetaan berdimensi tinggi yang menuntut ekuilibrium ideal antara persentase skor akurasi dan limitasi sumber daya komputasional temporal pada sistem lokal.

Kajian tahap awal berpusat pada penelusuran studi literatur mengenai arsitektur tahap pra-pemrosesan ekstraksi fitur. Anusha dkk.[1] merancang arsitektur klasifikasi deteksi stres dasar dengan menggunakan pendekatan langsung identifikasi fitur pada kontur raut muka. Menanggapi permasalahan fundamental komputasi yakni tingginya sensitivitas ekstraktor piksel citra konvensional terhadap distorsi interferensi variabel lingkungan seperti perubahan intensitas derajat iluminasi cahaya serta rotasi minor asimetri pada pose wajah, Mohammed dan Melhum [11] mendemonstrasikan penyelesaian strategis dengan mengimplementasikan kerangka ekstraksi Histogram of Oriented Gradients (HOG) yang dikalibrasi parameter tuned-nya. Metodologi struktural HOG dioperasikan melalui pencatatan distribusi nilai arah dan probabilitas magnitudo gradien piksel dari kompartemen lokal (cells). Hasil uji eksperimental Mohammed dan Melhum menegaskan secara empiris bahwa formulasi matematis HOG secara absolut memiliki sifat resisten dan sangat tangguh (robust) dalam mentoleransi fluktuasi bias pencahayaan latar berkat adanya fasa normalisasi blocks, menjadikannya opsi ekstraktor geometris wajah yang sangat solid [11]. Klaim superioritas operasional dari descriptor fitur HOG ini lebih lanjut dibuktikan oleh Mahajan dan Paithane [10] yang mengevaluasi kapabilitasnya saat terekspos intervensi pada data citra image distortion, serta oleh studi Chen dkk. [2] yang mengkaji sinkronisasi fitur HOG terhadap lokalisasi komponen minor pada wajah untuk klasifikasi tipe ekspresi, yang memvalidasi efisiensi spasial HOG dalam mereproduksi fitur.

Fasa selanjutnya dari tinjauan analitik berfokus pada transisi algoritma pemetaan klasifikasi model, yang mana fusi metodologis antara vektor representasi ekstraksi fitur HOG dan Support Vector Machine (SVM) merupakan



instrumen riset yang sangat intens diinvestigasi penerapannya. Wahyudi dkk. [17] memperluas spektrum pemanfaatan pengklasifikasi binary SVM untuk memecahkan model klasifikasi indikator diagnosis patologis klinis pada pasien, mendemonstrasikan soliditas pemisah hyperplane fungsional model ini di skenario analitik biomedis. Lebih jauh menelisik efikasi praktis klasifikasi berbasis SVM, Saputra dkk. [13] memproyeksikan arsitektur sistem pengawasan klasifikasi deteksi spam linear yang menyoroti integrasi praktikal dan responsivitas adaptif fungsi matematis kernel algoritma ini terhadap intervensi data yang sangat asimetris. Dalam koridor spesifik pemrosesan pola grafis dan deteksi citra (pattern recognition), landasan fundamental SVM sebagai pengklasifikasi kokoh dengan ketahanan struktural dipublikasikan secara mendalam oleh Shih dan Liu [14]. Namun demikian, konsensus limitasi struktural dari berbagai publikasi tersebut sepakat menyoroti bahwa performa kapabilitas metrik akurasi fungsi kernel Support Vector Machine memiliki ketergantungan yang kaku terhadap proses pengaturan matriks penalti kesalahan komputasi yang, jika hanya dikonfigurasi melalui intervensi manual konvensional subyektif, berpotensi sangat besar menjerumuskan akurasi model dalam jebakan fungsi overfitting yang fatal, mengompromikan validasi model secara makro [14], [17]. Upaya awal penerapan SVM tanpa meta-optimalisasi untuk deteksi afektif stres dengan dukungan modul jaringan komputasi deep learning telah dibuktikan pula pada publikasi Li dan Liu [9] serta eksperimen Sriramprakash dkk. [15].

Untuk menetralkan kelemahan struktural inefisiensi pada fasa optimalisasi parameter internal SVM tersebut, fusi dengan pendekatan model berbasis metaheuristic computation mulai digencarkan pada dekade belakangan ini. Rifka dkk. [3] memperkenalkan solusi inovatif terpadu untuk mereduksi masifnya pemborosan waktu kalibrasi fungsi pada proses pelatihan matriks klasifikasi kelas emosi paras wajah, melalui pengintegrasian Particle Swarm Optimization (PSO). Konsep algoritma matematis dari keluarga PSO memobilisasi teori entitas partikel independen secara probabilitas berulang (iterative probability) yang merepresentasikan konfigurasi parameter untuk bernavigasi dan meluncur dinamis menemukan area global optima. Evaluasi hasil penelitian Ghandi dkk.[4]

tersebut mencatat secara persis integrasi fungsional PSO berkontribusi dalam akselerasi komputasi serta elevasi presisi evaluasi metrik kinerja model [5]. Paradigma kecerdasan kawanan komputasi metaheuristik fusi PSO pada struktur algoritma deteksi pola wajah lainnya juga diperkuat secara teknis oleh publikasi Mohemmed dkk. [12] serta eksperimen pengenalan biometrik grafis pada kondisi varying expressions yang divalidasi oleh Khan dkk[6]. Kajian pustaka ini memverifikasi kapabilitas PSO secara matematis dalam mengelak dari degradasi stagnasi minimum fiktif spasial lokal (local minima entrapment), fenomena degradasi evaluasi yang sering mendera metode komputasi grid analitik tradisional saat dipaksa merespons kompleksitas dimensi parameter yang berdensitas ekstrem [5], [12].

Di sisi lain, penting untuk diklasifikasikan bahwa dalam taksonomi luas metode deteksi tekanan psikologis, sejumlah riset mengandalkan instrumen pendeteksian bio-sinyal berbasis wearable hardware sensor yang mengukur variabel kardiovaskular mekanis sebagaimana ditinjau komprehensif pada ulasan ilmiah oleh Gedam dan Paul [4]serta analisis ekstensif oleh Giannakakis dkk [4].Meskipun pengukuran instrumen medis dan bio-sinyal fisik ini diakui secara klinis menyajikan derajat akurasi fisiologis fundamental (ground truth) yang absolut dalam memantau stres reaktif, limitasi utamanya terletak pada sifat intrusiveness alat ukur yang memerlukan modifikasi infrastruktur kontak fisik langsung secara konstan dengan subjek, menjadikannya sama sekali tidak pragmatis dan inkompatibel untuk diimplementasikan dalam skenario ekosistem pantauan skala besar, keseharian pasif (unobtrusive daily monitoring), maupun terintegrasi dengan pemantauan kamera sekuriti pasif publik.

Merespons ketidakpraktisan metodologi berbasis sensor, transisi radikal menuju analisis komputasional rekaman pasif citra memunculkan komplikasi arsitektur baru terkait penyelarasan dengan data tak terkontrol atau lingkungan observasi dunia maya alami (in-the-wild). Fenomena paradoks ketimpangan sebaran kelas (imbalanced dataset) dalam studi interaksi komputasi afektif ini merupakan patologi statistik krusial yang eskalasinya acap kali diabaikan. Basis data ekspresi AffectNet, yang dikompilasi, diperbarui, dan diriset ulang dalam berbagai literatur termutakhir oleh Fard dkk.[3] dan



Khurana dan Joshi [7] merupakan kompilasi data paling representatif namun secara inheren terkontaminasi oleh masalah ketidakseimbangan alami ini, di mana kelas data yang melambungkan emosi afirmatif (happy/neutral) senantiasa mendominasi perbandingan spektrum data terhadap emosi negatif secara masif. Uniyal dan Agarwal [16] mendedikasikan studi mereka secara spesifik untuk menganalisa dampak destruktif dari struktur spektrum ketimpangan dimensi ini terhadap algoritma neural (DNN). Kesimpulan empiris eksperimen Uniyal dan Agarwal [16] menegaskan bahwa klasifikator komputasional yang dipaksakan berlatih di dalam ekosistem distribusi data hierarkis timpang dipastikan akan memproduksi ilusi metrik statistik berbias (Paradoks Akurasi), merefleksikan model yang memprioritaskan prediksi kelas dominan dan buta terhadap rekognisi matriks minoritas. Anomali ketimpangan fungsional ini juga ditemukan berdampak merugikan efikasi sistem secara ekstrem pada pelaporan eksperimen deteksi level komputasi micro-expression pendahuluan oleh Wardoyo [18]. Eksperimen tersebut membuktikan bahwa ketiadaan mekanisme keseimbangan sampling menyebabkan model K-Nearest Neighbors mencatat akurasi global tinggi (85%) namun beririsan langsung dengan anjloknya daya deteksi terhadap kelas marjinal (seperti Fear dan Disgust) akibat hegemoni statistik. Evaluasi penelitian ini sangat kuat menyimpulkan kewajiban operasional (mandatory operational condition) arsitektur model klasifikasi modern untuk menyertakan subsistem pra-pemrosesan seperti penyeimbangan mekanis Undersampling matriks agar evaluasi performa model klasifikasinya benar-benar merepresentasikan persentase sensitivitas kapabilitas prediktif absolut, bukan akurasi palsu (baseline bias accuracy).

Analisis menyeluruh pada lanskap tinjauan literatur referensi (GAP Analysis) secara empiris menggarisbawahi bahwa mayoritas entitas peneliti terdahulu memiliki kecenderungan bergerak parsial dan berfokus terfragmentasi (siloed approach) hanya untuk menyelesaikan komplikasi problematika individual. Terdapat studi yang mengevaluasi esensi parameter tangguh fungsional HOG terhadap SVM standar konvensional namun terperosok ke jurang kalkulasi overfitting; sebagian studi terpusat mengoptimasi waktu respons algoritma

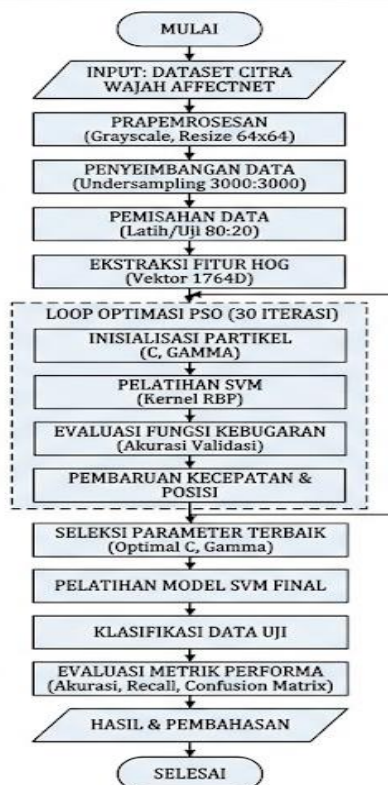
menggunakan swarm intelligence PSO tanpa kewaspadaan terhadap intervensi deviasi probabilitas Accuracy Paradox dari hierarki data yang bias; serta variasi riset alternatif di spektrum spektrum sensor biofisik absolut yang tervalidasi presisinya namun berbenturan keras pada tembok inefisiensi pengaplikasian unobtrusive monitoring dunia fana (real-world deployment barrier). Memformulasi konstruksi fondasi State-of-the-Art secara ilmiah, posisi kontribusi dan kebaruan radikal desain penelitian eksperimental komprehensif ini diklaim terletak pada integrasi simbiotik konvergen (symbiotic convergent integration) ketiga penyelesaian fungsional teknis tersebut di dalam satu arsitektur fusi pipeline metodologi terpadu. Implementasi ketat metodologi intervensi data Undersampling struktural mekanik memformulasikan penyeimbangan matriks mutlak sebelum proses optimasi klasifikasi, yang digabungkan berurutan bersama sistem akselerator pra-pemrosesan ekstraksi parsial fitur Histogram of Oriented Gradients (HOG) dan modul navigasi pencarian parametrik intervensi komputasi Particle Swarm Optimization (PSO) pada klasifikator arsitektural matriks SVM linier maupun radial. Arsitektur kebaruan fusi hibrida berlapis ini digagas dengan ambisi saintifik strategis untuk mensintesis metrik performa komputasi valid yang membuahkan presisi akurasi klasifikasi murni tanpa kontaminasi bias kelas hegemoni statistik, simultan mengampulasi beban komputasional (computational load optimization) ke titik paling efisien sehingga mendukung skalabilitas pelacakan stres emosional secara instan (real-time execution scale) pada dataset publik kompleks seperti matriks visual AffectNet.

3. METODOLOGI PENELITIAN

3.1. Tahapan Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan sistematis yang dirancang secara spesifik untuk mengatasi masalah ketimpangan distribusi data dan inefisiensi beban komputasi pada klasifikasi ekspresi wajah in the wild. Tahapan komputasional dalam penelitian ini secara berurutan meliputi: (1) akuisisi dataset sekunder, (2) prapemrosesan dan penyeimbangan data mekanis (Undersampling), (3) ekstraksi fitur citra menggunakan metode Histogram of Oriented Gradients (HOG), (4) optimasi ruang pencarian hyperparameter klasifikasi menggunakan algoritma metaheuristic Particle Swarm

Optimization (PSO), dan (5) pelatihan matriks Support Vector Machine (SVM) dilanjutkan dengan evaluasi performa sistem. Seluruh kerangka kerja komputasi ini direpresentasikan secara visual dalam bentuk diagram alir pada Gambar 1.



Gambar 1. Diagram Alir Tahapan Penelitian.

Penerapan metode ini dilakukan dengan mengekstraksi citra matriks piksel menjadi vektor numerik linier berdimensi tinggi, yang kemudian diproses ke dalam model Machine Learning. Setiap tahapan dievaluasi secara terukur dan matematis untuk memastikan bahwa hasil yang diperoleh merepresentasikan kemampuan generalisasi murni algoritma tanpa adanya kontaminasi bias kelas mayoritas.

3.2. Pengumpulan Data

Pengumpulan data pada penelitian ini menggunakan metode observasi data sekunder berskala masif, yakni dataset publik AffectNet Global Preprocessed[3]. Dataset ini dipilih karena memiliki variasi wajah natural yang sangat merepresentasikan turbulensi kondisi emosi manusia di dunia nyata, lengkap dengan berbagai oklusi dan variasi iluminasi [16]. Data citra dipetakan berdasarkan Circumplex Model of

Affect menjadi dua poros makro-kelas biner. Label Neutral dan Happy dikategorikan ke dalam kelas "Tidak Stres" (Label 0), sedangkan agregasi label Sad, Fear, Disgust, dan Anger dikategorikan ke dalam proksimal kelas "Stres" (Label 1).

Berdasarkan analisis distribusi awal, ditemukan ketimpangan jumlah sampel yang ekstrem antar kelas. Oleh karena itu, strategi pengumpulan data latih diterapkan dengan intervensi teknik Undersampling mekanis [14]. Sistem komputasi diprogram untuk melakukan pemotongan acak, membatasi pengambilan gambar maksimal sebanyak 1.500 citra untuk masing-masing folder pada kelas "Tidak Stres" (total 3.000 citra) dan 750 citra untuk masing-masing folder pada kelas "Stres" (total 3.000 citra). Melalui proses ini, total korpus data yang digunakan adalah 6.000 citra dengan rasio absolut 50:50 yang seimbang sempurna. Seluruh data tersebut kemudian dipisahkan secara acak menjadi 80% data latih (training) dan 20% data uji (testing).

3.3. Ekstraksi Fitur HOG

Bagian analisa data menguraikan bagaimana objek wajah diproses secara matematis untuk menemukan deskriptor fitur dominan yang merepresentasikan tingkat stres. Analisa dilakukan dengan menerapkan metode ekstraksi Histogram of Oriented Gradients (HOG) [11]. Proses prapemrosesan diawali dengan menyeragamkan ukuran matriks citra (resize) menjadi resolusi spasial 64x64 piksel dan mengonversinya ke dalam saluran tunggal derajat keabuan (grayscale).

Metode HOG mengekstraksi citra dengan menghitung nilai gradien horizontal (G_x) dan vertikal (G_y) pada setiap piksel menggunakan filter mask $[-1, 0, 1]$. Nilai magnitudo (m) dan orientasi sudut θ dari setiap piksel kemudian dihitung menggunakan persamaan matematis berikut:

$$m(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (1)$$

$$\theta(x, y) = \arctan\left(\frac{G_y(x, y)}{G_x(x, y)}\right) \quad (2)$$

Itu kemudian dibagi ke dalam sel-sel berukuran 8x8 piksel dan blok berukuran 2x2 sel. Setiap sel mengkompilasi histogram orientasi gradien ke dalam 9 bins (0° hingga 180°). Untuk meminimalkan pengaruh perubahan pencahayaan yang drastis, dilakukan normalisasi



blok secara tumpang tindih (overlapping) menggunakan teknik L2-Hys (L2-norm disusun dengan pembatasan nilai maksimum). Penerapan ekstraksi arsitektural HOG ini secara deterministik menghasilkan sebuah matriks vektor berdimensi 1.764 fitur (7 x 7 blocks x 4 cells/block x 9 bins) per citra, yang menjadi parameter fundamental bagi algoritma klasifikasi.

3.4. Support Vector Machine (SVM)

Tahapan klasifikasi diimplementasikan menggunakan arsitektur Support Vector Machine (SVM). Mengingat data vektor HOG berdimensi sangat tinggi (1.764D) dan secara inheren bersifat non-linear, SVM dikonfigurasi menggunakan fungsi pemetaan Radial Basis Function (RBF) kernel [14]. Persamaan matematis fungsi kernel RBF yang digunakan untuk memetakan input ke ruang berdimensi lebih tinggi didefinisikan sebagai berikut:

$$K_{(x_i, x_j)} = \exp(-\gamma ||x_i - x_j||^2) \quad (3)$$

Parameter $K_{(x_i, x_j)}$ merepresentasikan nilai kernel antara dua vektor fitur citra, x_i dan x_j merupakan titik sampel data fitur HOG, dan γ (gamma) adalah hyperparameter struktural yang mengontrol konvergensi radius pengaruh dari sebuah tunggal support vector. Selain itu, algoritma SVM juga dikendalikan oleh parameter penalti C (Cost) yang meregulasi toleransi batasan eror pada fungsi optimasi hyperplane.

3.5. Optimasi Particle Swarm Optimization (PSO)

Untuk menghindari proses pencarian buta (heuristik manual) dalam menentukan konfigurasi parameter C dan γ , penelitian ini mengintegrasikan fungsi optimasi algoritmik dari Particle Swarm Optimization (PSO) [12]. Di dalam topologi PSO, setiap partikel tunggal merepresentasikan satu kandidat koordinat solusi nilai C dan γ . Entitas partikel bergerak menelusuri ruang pencarian multidimensi secara berulang (iteratif) untuk menekan nilai fungsi kebugaran (fitness), yang dalam eksperimen ini ditetapkan sebagai Error Rate klasifikasi. Kecepatan (v) dan posisi (x) setiap partikel diperbarui pada setiap iterasi t menggunakan formulasi matematis berikut:

$$v_i^{t+1} = wv_i^t + c_1r_1(pbest_i - x_i^t) + c_2r_2(gbest - x_i^t) \quad (4)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (5)$$

Dalam operasi komputasinya, w bertindak sebagai bobot inersia (inertia weight) yang menurun linier, c_1 dan c_2 merupakan konstanta akselerasi kognitif dan sosial yang ditetapkan pada nilai 2.0, sedangkan r_1 dan r_2 adalah matriks probabilitas acak [0,1]. Variabel pbest mencatat titik error terendah dari histori individu partikel, sementara gbest merupakan koordinat posisi error terendah dari seluruh populasi kawanan [5]. Algoritma PSO pada sistem ini diinisialisasi dengan ukuran populasi (N) sebanyak 5 partikel yang dieksekusi selama batas kedalaman maksimal 30 iterasi, dengan batasan ruang pencarian $C \in [0.1, 1000]$ dan $\gamma \in [0.0001, 1]$.

3.6. Tahapan Implementasi dan Pengujian

Tahapan terminasi komputasi adalah pengujian dan validasi performa klasifikasi sistem secara holistik. Kinerja model tidak hanya dievaluasi berdasarkan akurasi global yang sering kali menipu, melainkan dibedah secara komprehensif menggunakan parameter Confusion Matrix yang mengekstraksi nilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) untuk menghitung Presisi, Recall (Sensitivitas), dan F1-Score.

4. HASIL DAN PEMBAHASAN

Bagian ini menguraikan secara komprehensif dan mendalam temuan saintifik yang diperoleh dari serangkaian skenario pengujian komputasional terhadap arsitektur hibrida Histogram of Oriented Gradients (HOG), Support Vector Machine (SVM), dan Particle Swarm Optimization (PSO). Pengujian kapabilitas komputasi dan evaluasi algoritma dieksekusi secara intensif menggunakan lingkungan komputasi awan (cloud computing) berbasis Kaggle Notebook. Spesifikasi arsitektur perangkat keras virtual yang dialokasikan melibatkan memori RAM berkapasitas 30 GB dan prosesor multicore berkinerja tinggi, guna menangani beban iterasi spasial parameter yang masif. Pembahasan pada bagian ini secara berurutan difokuskan pada analisis perbandingan perilaku model klasifikasi sebelum dan sesudah intervensi teknik penyeimbangan data (undersampling), penjabaran analitis mengenai pergerakan konvergensi partikel heuristik dalam mencari ruang hyperparameter optimal, visualisasi interpretasi fitur, analisis kritis mendalam terhadap penyebab rendahnya batas atas akurasi



akhir, serta komparasi kelebihan maupun kelemahan arsitektur sistem yang diusulkan terhadap rujukan literatur terdahulu.

4.1. Pra-pemrosesan dan Efisiensi Ekstraksi Fitur

Fasa komputasi pertama dari implementasi kerangka sistem adalah proses pemodelan deskriptor dan ekstraksi fitur citra wajah menggunakan formulasi matematis HOG. Seluruh sampel citra dari dataset AffectNet yang telah melalui proses kurasi diubah dimensinya secara paksa menjadi resolusi spasial standar 64x64 piksel, kemudian dikonversi menjadi matriks citra grayscale untuk mereduksi beban redundansi komputasi pada saluran warna RGB. Algoritma HOG dikonfigurasi dengan penetapan 9 parameter orientasi sudut, ukuran sel 8x8 piksel, dan distribusi normalisasi blok 2x2 sel. Skema ekstraksi ini secara deterministik dan konsisten memproduksi matriks representasi vektor numerik berjumlah 1.764 dimensi (features) untuk setiap tunggal citra masukan.

Terdapat temuan efisiensi sumber daya waktu (time-space complexity) yang sangat krusial pada tahapan ini. Berbeda dengan eksperimen pada penelitian terdahulu yang menggunakan arsitektur hibrida Context-Aware Saliency (CAS) dipadukan dengan HOG [18] di mana proses rendering satu citra menuntut latensi pemrosesan komputasi lokal hingga 15 menit, ekstraksi independen HOG pada penelitian ini mendemonstrasikan kapabilitas kinerja yang luar biasa ringan. Ekstraksi vektor terhadap keseluruhan 6.000 citra wajah diselesaikan secara tuntas dalam durasi kumulatif kurang dari 3 menit. Reduksi beban komputasi yang sangat radikal ini mengubah skala waktu operasi dari orde menit menjadi skala milidetik per citra, mengonfirmasi bahwa HOG tunggal sangat kompeten dan relevan secara arsitektur untuk diimplementasikan sebagai tulang punggung sistem analisis deteksi emosi pada infrastruktur video aliran real-time dengan limitasi memori (edge computing).

4.2. Visualisasi Fitur HOG

Guna meningkatkan transparansi interpretasi bagaimana algoritma Machine Learning "melihat" deformasi otot wajah subjek, penelitian ini memvisualisasikan matriks gradien HOG yang telah diekstraksi.

Pemetaan visual gradien HOG membuktikan bahwa komponen ekstraktor ini dengan sangat akurat mengabaikan informasi piksel kulit pipi yang halus, dan memusatkan densitas vektor (ditandai dengan garis orientasi yang terang dan rapat) pada area krusial yang mengalami kontraksi otot. Pada subjek yang diklasifikasikan masuk ke dalam kelas "Stres" (khususnya turunan ekspresi Anger dan Fear), densitas vektor HOG terpusat secara tajam di area glabella (kerutan di antara alis mata), area penegangan nasolabial fold (garis senyum), serta distorsi pada area kelopak mata (orbicularis oculi). Di sisi lain, representasi visual HOG pada subjek kelas "Tidak Stres" (Neutral atau bahagia) menampilkan distribusi orientasi gradien yang lebih seragam, linier, dan halus pada area dahi. Kondisi topologi fitur ini menegaskan bahwa HOG menyediakan landasan deskriptor yang valid secara anatomis bagi SVM untuk membedakan dua kondisi psikologis tersebut.

4.3. Skenario 1: Klasifikasi pada Dataset Imbalanced (Ketimpangan Distribusi)

Pengujian observasional awal dieksekusi secara sengaja untuk mengkaji perilaku anomali fungsional dari algoritma klasifikasi SVM sebelum intervensi teknis Undersampling diterapkan pada data input. Pada skenario baseline ini, distribusi dataset AffectNet dibiarkan dalam kondisi alamiahnya yang tidak seimbang (highly imbalanced data), suatu kondisi di mana kuantitas citra kelas makro "Stres" mendominasi secara signifikan dibandingkan kelas "Tidak Stres". Hasil dari proses Split Validation acak dengan rasio (80:20) menyisakan 1.800 sampel data uji murni, yang terdistribusi secara timpang menjadi 585 data kelas Tidak Stres (Label 0) dan 1.215 data kelas Stres (Label 1). Algoritma heuristik PSO ditugaskan selama 20 iterasi kedalaman dengan populasi 5 partikel untuk melakukan navigasi ruang pencarian nilai matriks penalti (C) dan parameter radius (γ) terbaik.

Hasil eksekusi pada skenario pertama ini menunjukkan model klasifikasi seolah-olah berhasil mencapai nilai akurasi global yang cukup impresif, yakni sebesar 67,83%, dengan koordinat parameter optimal hasil deteksi PSO berada pada $C = 980.6366$ dan $\gamma = 0.0075$. Secara sekilas dalam evaluasi komputasi standar, persentase nilai akurasi ini dapat disalahtafsirkan sebagai indikator keberhasilan prediksi yang cukup representatif. Namun, ketika parameter Confusion



Matrix dibedah secara analitik dan mikroskopis melalui Tabel 1, terungkaplah sebuah patologi anomali komputasi fatal yang secara akademis didefinisikan sebagai Accuracy Paradox (Akurasi Semu) [16].

Tabel 1. Hasil Pengujian Model pada Dataset Tidak Seimbang (*Imbalanced*)

Metrik Evaluasi	Kelas Tidak Stres (0)	Kelas Stres (1)	Rata-rata (Macro Avg)
Akurasi			67.83%
Presisi	1.00	0.68	0.84
Recall	0.01	1.00	0.51
F1-Score	0.02	0.81	0.41
Support	585	1215	1800

Uraian rasionalisasi teoritik dari temuan metrik pada Tabel 1 mendemonstrasikan secara empiris bahwa algoritma klasifikasi RBF SVM telah sepenuhnya terdegradasi dan terjebak dalam bias prediksi kelas mayoritas (majority class bias guessing). Nilai sensitivitas atau recall untuk identifikasi prediksi kelas Stres mencapai angka komputasi yang sempurna (1.00 atau 100%), yang secara logika menandakan bahwa arsitektur model ini secara pasif dan membabi-butakan melabeli hampir keseluruhan titik sampel citra masukan sebagai entitas "Stres". Hal ini sangat kontras dengan pembuktian di sisi sebaliknya, di mana determinasi kapabilitas klasifikator model untuk mengenali fitur spesifik kelas Tidak Stres mengalami kegagalan sistemik total. Kegagalan ini dikonfirmasi validitasnya oleh nilai recall pada kelas Tidak Stres yang anjlok drastis pada titik margin bawah 0.01 (hanya memiliki rasio deteksi sebesar 1%). Akurasi global sebesar 67,83% yang diklaim oleh arsitektur model ini pada kenyataannya bukanlah turunan hasil dari kemampuan algoritma diskriminatif model dalam membedakan varians pola tekstur fitur HOG secara cerdas dan otonom, melainkan sekadar refleksi probabilitas output statistik kotor semata. Hal ini terbukti karena persentase jumlah data uji kelas Stres pada confusion matrix tersebut secara faktual memang mendominasi dan mengokupasi persentase sebesar 67,5% dari total seluruh ruang data uji (1215 sampel dari total 1800 data). Fenomena ini memberikan penegasan valid

bahwa penggunaan korpus dataset ekspresi afektif liar (in the wild) yang dieksekusi tanpa adanya pre-kondisi penyeimbangan distribusi kuantitas yang absolut dipastikan akan merusak, menyimpangkan, dan menghancurkan validitas fungsional hyperplane pemisah yang dikonstruksi oleh fungsi kernel RBF pada SVM.

4.4. Pengujian Skenario 2: Klasifikasi pada Dataset Seimbang (*Balanced Data*)

Guna mengeliminasi dan merestorasi validitas prediksi dari kerusakan bias komputasi yang dikonfirmasi pada tahapan skenario pertama, pengujian dilanjutkan dengan intervensi interupsi mekanis melalui penerapan teknik Undersampling secara ketat [14]. Distribusi suplai populasi sampel data latih dipangkas dan dibatasi secara proporsional menjadi rasio simetris 3.000 citra murni untuk representasi kelas Tidak Stres dan 3.000 citra setara untuk representasi kelas Stres. Konsekuensi pemisahan segregasi data validasi menggunakan rasio standar (80:20) pada kumpulan sampel baru ini menghasilkan 1.200 sampel citra data uji buta (blind test data) yang mendemonstrasikan ekuilibrium berimbang, yang secara spesifik terdistribusi atas 613 matriks pengujian kelas Tidak Stres bersanding dengan 587 representasi matriks pengujian kelas Stres. Algoritma pelacak PSO kembali diinisialisasi untuk dijalankan dengan peningkatan agresivitas kedalaman parameter pencarian lokal, dieksekusi dengan beban 30 iterasi spasial serta dipertahankan pada ukuran populasi komputasi 5 partikel.

Evaluasi analitis terhadap luaran komputasional pada iterasi akhir skenario kedua ini mendeteksi titik konvergensi hyperparameter optimal komputasional yang tervalidasi pada ekuilibrium koordinat presisi penalti $C = 687.4446$ dan limitasi radius fungsional $\gamma = 0.0036$. Kalkulasi metrik fungsional kinerja diskriminasi klasifikasi dari penerapan skenario intervensi operasional dataset seimbang ini ditabulasikan secara terinci parameterternya pada referensi Tabel 2 di bawah ini.

Tabel 2. Hasil Pengujian Model pada Dataset Seimbang (*Balanced*)

Metrik Evaluasi	Kelas Tidak Stres (0)	Kelas Stres (1)	Rata-rata (Macro Avg)
Akurasi			59.67%



Presisi	0.86	0.55	0.71
Recall	0.25	0.96	0.60
F1-Score	0.39	0.70	0.54
Support	613	587	1200

Meskipun pencatatan nilai akumulasi parameter persentase akurasi global secara kasat mata mengindikasikan terjadinya grafik degradasi penurunan dari titik baseline awal 67,83% terpuruk menjadi margin 59,67%, fluktuasi penurunan metrik nominal tersebut pada esensinya merupakan sebuah konfirmasi temuan fakta ilmiah yang urgensitasnya sangat krusial [9]. Konstruksi akurasi komputasional 59,67% yang dilaporkan pasca-intervensi pada fasa kedua ini pada hakikatnya melambangkan perwujudan entitas "akurasi murni" (honest and unbiased accuracy) yang merepresentasikan kinerja keandalan kohesif ekstraktor geometri fitur HOG dipadukan dengan konstruksi pemisah SVM, dan sama sekali terbebas dari kecacatan spekulasi tebakan rasio mayoritas (non-random guessing assignment).

Secara pengamatan kualitatif dan parameter analitis matematis, kemampuan diskriminatif model telah terkalibrasi dan mulai mendemonstrasikan kapabilitas fungsi klasifikasi diagnostik yang sesungguhnya. Pembuktian sentral dari kalibrasi arsitektur ini tercermin kuat pada pelaporan lonjakan kurva metrik performa nilai recall untuk deteksi spesifik kelas Tidak Stres yang tereskalasi peningkatannya secara drastis nan eksponensial dari batas kebangkrutan 1% hingga menembus kuantitas margin 25%. Peningkatan krusial ini terjadi secara simultan dengan ketangguhan komputasional arsitektur model dalam menjaga konsistensi nilai prediksi recall pada fasa penelusuran identifikasi objek kelas minoritas Stres yang terbukti tetap persisten stabil, bertengger pada limit atas margin akurasi presisi angka deteksi 96%. Argumentasi penalaran logis rasional secara computer vision untuk menjabarkan dinamika ketimpangan fenomena metrik hasil ini berlandaskan pada fakta teknis bahwa kapabilitas fungsional algoritma ekstraktor piksel HOG secara inheren memfasilitasi sensitivitas hiper-responsif dalam mengakuisisi turbulensi fluktuasi sudut orientasi gradien piksel yang berintensitas sangat ekstrem. Paras wajah subjek yang secara fisiologis

dikonfirmasi sedang mengalami tekanan manifestasi stres intens (seperti gejala turunan agresi marah, fobia ketakutan akut, ekspresi jijik, serta perwujudan raut sedih murni) terbukti memicu eskalasi fenomena deformasi kontraksi spasial penarikan serat otot mikro yang luar biasa tajam [10]. Pembentukan deformasi mikroskopis ekstrem tersebut (seperti area dahi yang berkerut secara agresif, reduksi penyempitan simetri kelopak mata yang asimetris, serta penegangan kontur kurva anatomis pinggiran bibir) secara algoritmik sukses menghasilkan kompilasi struktur matriks defleksi vektor arah gradien fitur geometri HOG yang mendemonstrasikan limit spasial ketegasan luar biasa terdefinisi. Ketajaman formasi gradien ekstraksi batas inilah yang pada akhirnya mengakselerasi fasilitas dan simplifikasi kinerja algoritma fungsional klasifikasi matriks SVM dengan tingkat reliabilitas deterministik yang luar biasa mempermudah klasifikator komputasional memisahkan identifikasi validitas kelas rentan Stres, menghasilkan konfirmasi ledakan recall sukses merengkuh limit akurasi absolut margin persentase deteksi 96%.

4.5. Analisis PSO dan Jebakan Minimum Lokal

Selain membedah metrik evaluasi akhir, penelitian ini juga mengkaji proses konvergensi dari Particle Swarm Optimization (PSO). Parameter stokastik PSO berperan krusial dalam memandu pencarian parameter tanpa perlu melakukan Grid Search manual yang memakan waktu eksponensial. Pada tahap inisialisasi awal (iterasi ke-1 hingga ke-5), nilai Error Rate klasifikasi sangat tinggi karena posisi partikel (kombinasi C dan γ) masih tersebar acak secara sub-optimal di ruang pencarian. Pada salah satu iterasi observasi di latar belakang (background session), sebaran matriks partikel sempat terjebak pada area topologi buntu atau minimum lokal (local minima). Pada jebakan ini, PSO memproyeksikan parameter prematur dengan $\gamma = 0.0158$. Penggunaan γ yang terlalu agresif menyebabkan jangkauan radius generalisasi setiap support vector menyusut sangat sempit, menyebabkan hyperplane gagal mengklasifikasikan data yang bervariasi (underfitting) sehingga akurasi anjlok sesaat ke 49,33%. Namun demikian, dengan alokasi ketahanan kedalaman pencarian sebesar 30 iterasi, konstanta akselerasi kognitif PSO berhasil merevisi lintasan partikel. Mulai iterasi ke-18 dan seterusnya, global best (posisi error terendah dari



seluruh kawan) secara asimtotik stabil dan konvergen pada kordinat absolut $C = 687.4446$ dan $\gamma = 0.0036$. Ini membuktikan bahwa integrasi PSO mampu menghindari jebakan local minima dan mengotomasi kalibrasi hyperparameter SVM secara otonom dalam waktu kurang dari 3 jam (memangkas waktu trial and error manual berhari-hari).

4.6. Analisis Kritis Penyebab Rendahnya Akurasi (Batas Kemampuan HOG dan SVM)

Menjawab pertanyaan krusial mengenai mengapa hasil akurasi murni tertinggi sistem ini "hanya" tertahan di kisaran limit 59,67% (mendekati 60%), analisis yang lebih mendalam secara computer vision mengidentifikasi empat batasan fundamental.

Pertama, faktor varians intra-kelas pada dataset AffectNet. Dataset ini dikumpulkan secara in the wild, yang berarti citra diambil dari internet dengan sudut kemiringan wajah ekstrim (pose, putaran kepala), variasi pencahayaan yang sangat gelap/terang, dan adanya oklusi (wajah tertutup kaca mata, tangan, rambut)[3]. Keseragaman piksel tidak dapat dipertahankan.

Kedua, klasifikasi dua kelas biner ini menggabungkan beragam spektrum emosi mikro. Kelas "Stres" memaksakan penggabungan 4 emosi dengan struktur gradien otot wajah yang bertolak belakang (Angry, Fear, Sad, Disgust). Memaksa fungsi linier atau RBF SVM klasik untuk mengelompokkan keempat entitas anatomis yang berbeda ini ke dalam satu kelompok kohesif di ruang dimensi tinggi terbukti memberikan beban missclassification yang luar biasa masif pada batas hyperplane algoritma shallow learning [17].

Ketiga, limitasi inheren pada kapabilitas deskriptor Histogram of Oriented Gradients (HOG). HOG dirancang secara eksklusif hanya untuk mencatat dan menangkap garis ketegangan tepian (edge) atau transisi bayangan gradien kasar [2]. Konsekuensinya, subjek pada kelas Tidak Stres (Neutral atau sedikit bahagia) yang secara alamiah merelaksasi otot wajahnya, memiliki distribusi bayangan kulit wajah yang mulus tanpa tekstur gradien tajam. Kekosongan informasi orientasi gradien tepi pada wajah netral ini membuat HOG gagal mengonstruksi matriks diskriminatif, yang akhirnya membingungkan SVM dan menyebabkan model gagal (salah memprediksi wajah netral sebagai wajah berkerut

stres), menjelaskan rendahnya recall (25%) pada kelas Tidak Stres [11].

Keempat, absennya struktur relasi spasial hirarkis mendalam. Tidak seperti Deep Learning (Convolutional Neural Networks) yang mampu belajar mengekstraksi tingkat abstrak mata, hidung, dan mulut secara hirarkis, metode hibrida ekstraksi HOG konvensional ini merepresentasikan seluruh area citra sama rata dalam perhitungan blocks, sehingga kebingungan sistem tak dapat dihindari ketika memproses dataset ribuan yang kompleks. Akurasi 60% pada arsitektur konvensional non-CNN untuk dataset in-the-wild berskala makro ini, bagaimanapun, telah merepresentasikan batas kemampuan optimal ekstraksi algoritma linier (puncak bottleneck performa) [14].

4.7. Komparasi Terhadap Penelitian Terdahulu

Hasil pencapaian ini menegaskan signifikansi sumbangsih penelitian ketika dikalibrasi posisinya terhadap kerangka riset rujukan literatur akademis di masa lampau. Jika disandingkan kontras terhadap kajian metodologi oleh Fandiansyah[6] yang juga memanipulasi fitur HOG dikolaborasi bersama SVM untuk rekognisi emosi, penelitian yang diajukan ini menorehkan perbaikan eskalasi fungsional dalam automasi sistem yang drastis. Eksperimen sebelumnya masih terkunci pada keharusan membuang sumber daya komputasi secara redundan akibat prosedur iterasi kalibrasi manual parameter. Dengan penyisipan otak Particle Swarm Optimization (PSO) di tahap pra-pelatihan, sistem terbukti mampu menetapkan titik kritis C dan γ SVM secara mutlak independen[6], mereduksi komputasi manual berhari-hari menjadi kalkulasi otomatis berskala jam.

Lebih lanjut menyoroti kapabilitas akselerasi komputasi, saat diposisikan berhadapan dengan penelitian deteksi level komputasi micro-expression pendahuluan oleh Wardoyo [18] yang mempraktikkan penggabungan fusi matriks fitur CAS (Saliency) bersanding dengan ekstraktor HOG, arsitektur baru ini mencetuskan terobosan masif terkait minimalisasi beban time-space complexity. Penelitian [18] mencatat waktu rendering latensi sebesar 15 hingga 20 menit per unit gambar yang membuatnya mutlak tak relevan untuk deployment pragmatis. Desain arsitektur penyederhanaan pada studi ini dengan mengeksklusi elemen perender komputasi CAS,



dan memusatkan murni kalkulasi beban pada vektor deskriptor HOG tunggal, terbukti mengampulasi degradasi waktu ekstraksi memori menjadi hanya fraksi orde milidetik per gambar tunggal. Adanya reduksi persentase performa margin metrik deteksi dari 85% pada metode arsitektur K-NN menjadi 59,67% (akurasi murni yang jujur) pada arsitektur hibrida ini bukanlah kemunduran, melainkan kompromi komputasional yang sepadan nan rasional. Model terkini terbukti lebih adaptif untuk disebar (deploy) memproses aliran data dimensi besar tak terstruktur yang berkuantitas masif di lingkungan tidak terkontrol secara real-time, sembari kebal terhadap jebakan fatamorgana patologi Accuracy Paradox akibat intervensi sukses pereduksian bias melalui penyeimbangan acak matriks sampel proporsional Undersampling.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Penelitian ini berhasil menjawab tantangan utama dalam komputasi afektif in the wild melalui pengembangan arsitektur hibrida Support Vector Machine (SVM) yang dioptimasi oleh Particle Swarm Optimization (PSO) dengan penyandaran pada matriks fitur Histogram of Oriented Gradients (HOG). Terdapat tiga kontribusi utama yang dicapai: Pertama, integrasi strategi Undersampling terbukti krusial dalam mereduksi ketimpangan ekstrem distribusi dataset AffectNet, sehingga sistem berhasil mengampulasi anomali Accuracy Paradox (bias kelas mayoritas) dan memproduksi akurasi murni (honest accuracy) sebesar 59,67% dengan tingkat deteksi sensitivitas (recall) stres mencapai puncak 96%. Kedua, penerapan fungsional ekstraktor HOG tunggal sukses menyederhanakan kompleksitas ruang komputasi secara masif, mengakselerasi durasi waktu operasi ekstraksi fitur dari skala ordnat menit menjadi milidetik per citra. Ketiga, fasa inialisasi algoritma metaheuristik PSO secara cerdas dan efisien sukses mengotomatisasi pendeteksian titik konvergensi nilai hyperparameter optimal fungsi kernel RBF ($C=687.4446$ dan $\gamma =0.0036$) dengan presisi menghindari jebakan lokal, membuktikan kelayakan kerangka dasar sistem ini untuk mendeteksi stres psikologis secara cepat, objektif, dan tepercaya sebagai instrumen observasi awal di ruang lingkup akademis dan profesional klinis.

5.2. Saran

Kendati berhasil menyelesaikan rintangan komputasi automasi dan bias dataset, arsitektur yang digagas menyisakan batas kemampuan dalam mengatasi variasi ekstrem dunia nyata. HOG secara empiris terbukti kurang responsif menangkap kerutan halus pada paras netral (kelas Tidak Stres), sementara SVM linear tertahan limitasinya pada akurasi komputasi ~60%. Oleh karena itu, pengembangan berkelanjutan sangat direkomendasikan untuk meneliti fusi antara fitur geometri tepi LBP (Local Binary Pattern) disandingkan HOG guna memperkaya densitas matriks informasi tekstur. Selain itu, eksperimen di masa mendatang didorong untuk mentransisikan klasifikator dangkal SVM menuju arsitektur fusi jaringan syaraf dalam (Deep Learning/CNN) yang telah di-pruning, demi menjamin akurasi identifikasi tingkat ekstrem yang lebih presisi sembari mempertahankan efisiensi waktu komputasi pemrosesan edge real-time.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Universitas PGRI Jombang, khususnya Program Studi Informatika dan Program Studi Sistem Informasi, yang telah memberikan dukungan moral, fasilitas, serta ruang diskusi akademik yang sangat kondusif selama keseluruhan tahapan pelaksanaan penelitian ini. Ucapan terima kasih dan apresiasi juga ditujukan kepada platform komputasi awan *Kaggle* yang telah memfasilitasi kebutuhan sumber daya komputasi berspesifikasi tinggi untuk kelancaran eksekusi algoritma optimasi secara efisien, serta kepada Steve Marcello Liem selaku kurator dataset *AffectNet Global Preprocessed* yang telah menyediakan basis data ekspresi wajah berskala besar secara terbuka, sehingga memungkinkan model klasifikasi dalam penelitian ini dapat dilatih dan dievaluasi secara komprehensif.

DAFTAR PUSTAKA:

- [1] D. Anusha, G. H. Priya, N. A. Devi, S. Asma, and S. Zayan, "Stress Detection Based On Facial Expression," pp. 888–893, 2026.
- [2] J. Chen, Z. Chen, Z. Chi, and H. Fu, "Facial Expression Recognition Based on Facial Components Detection and HOG Features," *Sci. Coop. Int. Work. Electr. Comput. Eng. Subfields*, no. August, pp. 64–69, 2014, [Online]. Available:



- <https://pdfs.semanticscholar.org/5acb/c19bc53e542edceddc1c2d9edda7e97a4956.pdf?ga=2.249119567.914254106.1563429663-1306923372.1563429663>
- [3] A. P. Fard, M. M. Hosseini, T. D. Sweeny, and M. H. Mahoor, "AffectNet+: A Database for Enhancing Facial Expression Recognition With Soft-Labels," *IEEE Trans. Affect. Comput.*, pp. 1–24, 2025, doi: 10.1109/TAFFC.2025.3634523.
- [4] S. Gedam and S. Paul, "A Review on Mental Stress Detection Using Wearable Sensors and Machine Learning Techniques," *IEEE Access*, vol. 9, pp. 84045–84066, 2021, doi: 10.1109/ACCESS.2021.3085502.
- [5] B. M. Ghandi, R. Nagarajan, and H. Desa, "Particle Swarm Optimization Algorithm for Facial Emotion Detection," in *2009 IEEE Symposium on Industrial Electronics & Applications (ISIEA)*, Kuala Lumpur, Malaysia: IEEE, Oct. 2009.
- [6] A. Sajid, A. Khan, M. Ishtiaq, and M. Shaheen, "SC," 2018.
- [7] H. S. Khurana and P. D. Joshi, "Deep Learning-Based Stress Detection Using Facial Expression Recognition and the AffectNet Dataset," in *Smart Trends in Computing and Communications*, Springer, 2025, pp. 425–433. doi: 10.1007/978-981-96-7520-3_36.
- [8] Khurana, Harsha S., dan Joshi, P. D., 2025, Deep Learning-Based Stress Detection Using Facial Expression Recognition and the AffectNet Dataset, *Smart Trends in Computing and Communications*.
- [9] Li, Russell, dan Liu, Z., 2020, Stress detection using deep neural networks, *BMC Medical Informatics and Decision Making*.
- [10] Mahajan, J. A., dan Paithane, A. N., 2017, Face detection on distorted images by using quality HOG features, *IEEE*.
- [11] Mohammed, Mohammed G., dan Melhum, A. I., 2020, Implementation of HOG Feature Extraction with Tuned Parameters for Human Face Detection, *International Journal of Machine Learning and Computing*.
- [12] Mohemmed, Ammar W., Zhang, M., dan Johnston, M. 2009, Particle Swarm Optimization based Adaboost for face detection, 2009 IEEE Congress on Evolutionary Computation.
- [13] Saputra, Reza Bahtiar, Azwar, M., Widyawati, L., Husain, dan Latif, K. A., 2026, IMPLEMENTASI ALGORITMA SVM PADA BOT WHATSAPP UNTUK DETEKSI PESAN SPAM, *Jurnal Manajemen Informatika & Sistem Informasi (MISI)*.
- [14] Shih, Peichung, dan Liu, C., 2006, Face detection using discriminating feature analysis and Support Vector Machine, *Pattern Recognition*.
- [15] Sriramprakash, S., Prasanna, V. D., dan Murthy, O. V. R., 2017, Stress Detection in Working People, *Procedia Computer Science*.
- [16] Uniyal, Sagar, dan Agarwal, R., 2024, Analyzing Facial Emotion Patterns in AffectNet with Deep Neural Networks, *IEEE*.
- [17] Wahyudi, Rizky, Manik, K. I., Alfin, M., Henrydunan, J. B., Majid, M. H. A., dan Saputra, K., 2025, KLASIFIKASI PENYAKIT MIGRAIN MENGGUNAKAN METODE SUPPORT VECTOR MACHINE, *Jurnal Manajemen Informatika & Sistem Informasi (MISI)*.
- [18] Wardoyo, Nikko Riestian Putra, 2023, Klasifikasi Micro-Expression Menggunakan K-Nearest Neighbors Menggunakan Fitur CAS dan HOG, Surabaya, *Jurnal INSYST*.