

Pendekatan *Eyeblink Movement Analysis* Berbasis Sensitivitas untuk Pemodelan Respons Pengguna Implisit dalam ML4SE

Hasan Basri

Fakultas Sains dan Teknologi, Universitas Terbuka

Jl. Pd. Cabe Raya, Pd. Cabe Udik, Kec. Pamulang, Kota Tangerang Selatan, Banten 15437

hasan.basri@ecampus.ut.ac.id

Abstract—This study proposes a sensitivity-aware approach for analyzing eyebrow movements as an early indicator of implicit user responses within Machine Learning for Software Engineering (ML4SE). The proposed method aims to develop and evaluate a sensitivity-based detection mechanism capable of capturing subtle eyebrow micro-movements while maintaining robustness against noise. Micro-expressions are brief and involuntary facial movements, typically lasting less than half a second, making them difficult to detect due to low intensity and high susceptibility to noise. The approach utilizes facial landmark analysis to measure relative changes in eyebrow positions based on a personalized baseline. A sensitivity parameter is introduced to dynamically control the detection threshold. The processing pipeline consists of video acquisition, facial landmark extraction, baseline normalization, temporal smoothing, and rule-based classification. Experiments were conducted on 10 video sequences, each consisting of 580–619 frames, with an average of 589 frames analyzed per video after baseline initialization. Three sensitivity configurations (1.5, 2.0, and 3.0) were evaluated. Results show that increasing sensitivity improves responsiveness to subtle movements but also increases false positives, indicating higher sensitivity to noise, and shifts classifications toward higher intensity. A sensitivity value of 2.0 provides the best trade-off between sensitivity to subtle movements and robustness against noise, achieving a detection ratio of 98.30% based on frame-level analysis. These findings indicate that sensitivity functions as a decision boundary in eyebrow movement analysis. Within ML4SE, this approach provides a foundation for incorporating implicit affective signals into user modeling. Future work will extend this approach by integrating pupil movement analysis to enable multimodal detection and improve robustness and generalizability.

Keywords— Micro-Expression Detection, Facial Landmark Analysis, Sensitivity-Based Detection, ML4SE

Abstrak— Penelitian ini mengusulkan pendekatan berbasis sensitivitas (*sensitivity-aware*) untuk menganalisis pergerakan alis sebagai indikator awal respons pengguna implisit dalam *Machine Learning for Software Engineering* (ML4SE). Tujuan penelitian adalah mengembangkan dan mengevaluasi mekanisme deteksi berbasis sensitivitas yang mampu menangkap pergerakan mikro alis secara halus dengan tetap mempertahankan ketahanan terhadap *noise*. *Micro-expression* merupakan gerakan wajah yang sangat singkat dan tidak disadari, umumnya berlangsung kurang dari setengah detik, sehingga sulit dideteksi karena intensitasnya rendah dan rentan terhadap *noise*. Pendekatan yang diusulkan

memanfaatkan analisis *facial landmark* untuk mengukur perubahan relatif posisi alis berdasarkan *baseline* personal. Parameter sensitivitas digunakan untuk mengontrol ambang deteksi secara dinamis. *Pipeline* sistem meliputi akuisisi video, ekstraksi *landmark* wajah, normalisasi berbasis *baseline*, *temporal smoothing*, serta klasifikasi berbasis aturan. Eksperimen dilakukan pada 10 video independen, masing-masing terdiri dari 580–619 *frame*, dengan rata-rata 589 *frame* yang dianalisis per video setelah inisialisasi *baseline*. Tiga konfigurasi sensitivitas (1,5; 2,0; dan 3,0) dievaluasi. Hasil menunjukkan bahwa peningkatan sensitivitas meningkatkan respons terhadap pergerakan halus, namun juga meningkatkan *false positive*, yang mengindikasikan sensitivitas lebih tinggi terhadap *noise*, serta menyebabkan pergeseran klasifikasi ke intensitas yang lebih tinggi. Nilai sensitivitas 2,0 memberikan keseimbangan terbaik antara sensitivitas terhadap perubahan halus dan ketahanan terhadap *noise*, dengan rasio deteksi 98,30% berdasarkan analisis tingkat *frame*. Temuan ini menunjukkan bahwa sensitivitas berfungsi sebagai batas keputusan (*decision boundary*) dalam analisis pergerakan alis. Dalam konteks ML4SE, pendekatan ini memberikan dasar untuk integrasi sinyal afektif implisit dalam pemodelan respons pengguna. Penelitian selanjutnya akan mengintegrasikan analisis pergerakan pupil untuk membangun pendekatan multimodal yang diharapkan dapat meningkatkan *robustness* dan generalisasi sistem.

Kata kunci— Micro-Expression Detection, Facial Landmark Analysis, Sensitivity-Based Detection, ML4SE

I. PENDAHULUAN

Perkembangan *Machine Learning for Software Engineering* (ML4SE) telah membuka peluang baru dalam meningkatkan kualitas dan efektivitas proses pengembangan perangkat lunak, namun masih terdapat masalah dalam memodelkan respons pengguna yang bersifat implisit dan tidak dapat diamati secara langsung. ML4SE memanfaatkan teknik *machine learning* untuk mendukung berbagai aktivitas dalam siklus hidup perangkat lunak, seperti analisis kebutuhan, pengujian, prediksi kualitas, hingga pemahaman perilaku pengguna [1],[2],[3]. Pendekatan ini menjadi penting karena banyak permasalahan dalam rekayasa perangkat lunak tidak dapat dimodelkan secara deterministik dan membutuhkan pembelajaran dari data serta pola perilaku pengguna, termasuk bagaimana menangkap sinyal halus seperti *micro-expression* yang rentan terhadap *noise*.

Pada konteks interaksi manusia dan komputer (*Human-Computer Interaction/HCI*), pemahaman terhadap respons pengguna merupakan aspek krusial dalam pengembangan sistem yang adaptif dan berorientasi pengguna. Respons tersebut tidak hanya tercermin dari interaksi eksplisit, tetapi juga dari sinyal implisit seperti ekspresi wajah [4],[5],[6],[7],[8], ekspresi wajah juga dapat digunakan untuk memahami karakteristik pengguna secara implisit [9]. Salah satu bentuk ekspresi yang relevan adalah *micro-expression*, yaitu perubahan ekspresi wajah yang sangat singkat dan memiliki intensitas rendah, yang dapat mencerminkan kondisi afektif pengguna secara spontan [10],[11],[12],[13].


Penelitian sebelumnya yang telah dilakukan oleh penulis dalam domain ML4SE berfokus pada pemanfaatan *machine learning* untuk mendukung analisis perilaku pengguna dan pengambilan keputusan dalam sistem perangkat lunak. Studi-studi tersebut menunjukkan bahwa integrasi data perilaku pengguna ke dalam proses rekayasa perangkat lunak dapat meningkatkan kualitas sistem, khususnya dalam aspek adaptivitas dan pengalaman pengguna [14],[15],[16]. Namun, sebagian besar pendekatan masih bergantung pada data eksplisit dan belum memanfaatkan sinyal afektif berbasis ekspresi wajah secara optimal.

Deteksi *micro-expression* menjadi tantangan tersendiri karena durasinya yang sangat singkat (umumnya kurang dari 200 ms) serta amplitudo gerak yang kecil [17], [18]. Selain itu, faktor eksternal seperti pergerakan kepala, variasi pencahayaan, dan ketidakstabilan *landmark* wajah dapat menyebabkan *noise* yang signifikan. Pendekatan berbasis *facial landmark*, seperti *MediaPipe Face Landmarker*, memungkinkan ekstraksi fitur wajah secara *real-time* tanpa memerlukan pelatihan model yang kompleks [19], [20]. Namun, sebagian besar penelitian masih berfokus pada ekspresi makro dan belum secara spesifik mengakomodasi kebutuhan sensitivitas tinggi untuk mendeteksi *micro-expression*.

Pada konteks tersebut, penelitian ini memperkenalkan pendekatan berbasis sensitivitas (*sensitivity-aware*) sebagai mekanisme adaptif yang berfungsi untuk mengatur ambang deteksi secara dinamis, sehingga mampu meningkatkan kemampuan sistem dalam menangkap perubahan mikro sekaligus mengendalikan pengaruh *noise*. Berbeda dengan pendekatan sebelumnya yang umumnya menggunakan model kompleks atau *threshold* statis, pendekatan ini memanfaatkan kontrol sensitivitas eksplisit yang berperan sebagai *decision boundary* dalam membedakan antara sinyal *micro-expression* dan *noise*.

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi pendekatan *sensitivity-aware* dalam menganalisis pergerakan alis menggunakan *facial landmark* dengan *baseline personal*, sehingga memungkinkan representasi perubahan yang lebih adaptif terhadap karakteristik individu. Secara khusus, permasalahan yang diangkat dalam penelitian ini adalah bagaimana merancang mekanisme deteksi yang sensitif terhadap *micro-expression* namun tetap *robust* terhadap *noise*, serta bagaimana menentukan konfigurasi sensitivitas yang optimal dalam membedakan antara sinyal dan *noise*. Selain itu, penelitian ini mengevaluasi pengaruh variasi parameter sensitivitas terhadap

perilaku deteksi dan mengidentifikasi konfigurasi sensitivitas yang optimal dalam menyeimbangkan kemampuan deteksi terhadap perubahan halus dan *robustness* sistem, khususnya dalam mendukung pemodelan respon pengguna implisit dalam konteks ML4SE.



Gambar. 1 Diagram alur sistem analisis pergerakan alis berbasis sensitivitas

II. METODE PENELITIAN

Penelitian ini mengembangkan pendekatan untuk menganalisis pergerakan alis sebagai indikator pergerakan mikro wajah dalam konteks ML4SE. Pendekatan ini berfungsi sebagai mekanisme ekstraksi data implisit dari pengguna untuk mendukung analisis perilaku dalam sistem perangkat lunak. Secara umum, sistem yang diusulkan terdiri dari beberapa tahapan utama, yaitu: (1) akuisisi video, (2) deteksi *landmark* wajah, (3) perhitungan jarak alis, (4) normalisasi berbasis *baseline*, (5) *temporal smoothing*, (6) pengelompokan berbasis sensitivitas, dan (7) visualisasi. Gambar 1 Mengilustrasikan alur sistem secara keseluruhan

A. Akuisisi Data

Data yang digunakan berupa video wajah pengguna dengan *frame rate* sekitar 30 FPS. Video diproses secara *frame-by-frame* untuk menangkap perubahan pergerakan wajah dalam

interval waktu yang sangat singkat. Pergerakan mikro wajah umumnya terjadi dalam durasi sangat singkat (kurang dari 200 ms), sehingga pada video 30 FPS perubahan tersebut hanya muncul dalam beberapa *frame*.

B. Deteksi Landmark Wajah

Deteksi *landmark* wajah dilakukan menggunakan *MediaPipe Face Landmarker*, yang menghasilkan titik-titik koordinat wajah secara *real-time*. Pendekatan ini dipilih karena tidak memerlukan proses *training* model tambahan dan mampu bekerja secara efisien dalam aplikasi *real-time*. *Landmark* yang digunakan difokuskan pada area:

- 1) alis kiri dan kanan
- 2) bagian atas mata.

Pemilihan area ini didasarkan pada *Facial Action Coding System* (FACS), di mana gerakan alis berkaitan dengan *Action Unit* seperti AU1, AU2, dan AU4 [21], [22].

C. Perhitungan Jarak Alis

Untuk setiap *frame*, sistem menghitung jarak antara titik alis dan titik bagian atas mata menggunakan jarak *Euclidean*:

$$d = \sqrt{(x_{eyebrow} - x_{eye})^2 + (y_{eyebrow} - y_{eye})^2}$$

Nilai jarak dihitung untuk beberapa titik alis, kemudian dirata-ratakan untuk memperoleh representasi posisi alis kiri dan kanan [23]–[25].

D. Normalisasi Berbasis Baseline

Untuk mengatasi variasi antar individu, sistem menggunakan *baseline personal* yang dihitung dari sejumlah *frame* awal (*default* 30 *frame*) yang diasumsikan sebagai kondisi netral. Perubahan posisi alis dihitung relatif terhadap *baseline*:

$$\Delta_L = \frac{d_L(t) - \bar{d}_L}{\bar{d}_L}, \Delta_R = \frac{d_R(t) - \bar{d}_R}{\bar{d}_R}$$

Pendekatan ini memungkinkan sistem untuk lebih adaptif terhadap perbedaan bentuk wajah pengguna [26], [27].

E. Temporal Smoothing

Untuk mengurangi *noise* akibat fluktuasi *facial landmark*, digunakan teknik *temporal smoothing* berbasis *moving average*. Pada setiap *frame* ke-*t*, nilai perubahan posisi alis dihitung sebagai rata-rata dari *w frame* terakhir [28] dengan *w* adalah ukuran *window* yang digunakan dalam proses *smoothing*.

$$\Delta(t) = \frac{1}{w} \sum_{i=t-w+1}^t \Delta(i)$$

Penelitian ini digunakan nilai $w = 5$ *frame*, sehingga setiap nilai pada *frame* saat ini merupakan rata-rata dari lima *frame* berturut-turut. Pemilihan nilai *w* didasarkan pada karakteristik *micro-expression* yang berlangsung sangat singkat. Nilai *window* yang kecil memungkinkan sistem tetap responsif terhadap perubahan cepat, sedangkan nilai *window* yang terlalu besar dapat menghaluskan sinyal secara berlebihan dan menyebabkan hilangnya informasi perubahan mikro. Secara umum, semakin besar nilai *window*, semakin kuat efek

smoothing yang dihasilkan, namun dengan konsekuensi meningkatnya *delay* dan berkurangnya sensitivitas terhadap perubahan cepat.

F. Klasifikasi Berbasis Sensitivitas

Komponen utama penelitian ini adalah parameter *sensitivity*, yang mengatur ambang deteksi perubahan alis. Ambang deteksi didefinisikan sebagai:

$$\theta = \frac{0.06}{sensitivity}$$

Semakin tinggi nilai *sensitivity threshold* semakin kecil, sistem semakin peka terhadap perubahan kecil. Klasifikasi dilakukan berdasarkan nilai perubahan relatif kiri (Δ_L) dan kanan (Δ_R):

- 1) Penurunan alis (AU4)
 $\Delta_L < -\theta$ dan $\Delta_R < -\theta$
- 2) Kenaikan alis (AU1+AU2)
 $\Delta_L > \theta$ dan $\Delta_R > \theta$

Perbedaan signifikan kiri-kanan sama dengan *asymmetric micro-expression*, selain itu netral [29], [30]. Pendekatan ini bersifat *rule-based*, yang sesuai dengan kebutuhan sistem ringan dalam konteks ML4SE, di mana interpretabilitas dan efisiensi menjadi faktor penting.

III. HASIL PENELITIAN

Eksperimen dilakukan menggunakan 10 video wajah pengguna, di mana setiap video memiliki panjang antara 580 hingga 619 *frame* dengan *frame rate* sekitar 30 FPS. Pada setiap video, sebanyak 30 *frame* awal digunakan sebagai *baseline*, sehingga jumlah *frame* yang dianalisis pada masing-masing video berkisar antara 550 hingga 589 *frame*, dengan rata-rata sekitar 589 *frame* per video.

Pengujian dilakukan dengan tiga konfigurasi parameter sensitivitas, yaitu 1,5; 2,0; dan 3,0, untuk mengamati pengaruhnya terhadap distribusi deteksi *micro-expression*. Nilai 1,5 dipilih untuk merepresentasikan konfigurasi konservatif dengan ambang deteksi yang relatif ketat, nilai 2,0 digunakan sebagai konfigurasi moderat untuk memperoleh keseimbangan antara kemampuan deteksi dan ketahanan terhadap *noise*, sedangkan nilai 3,0 digunakan untuk merepresentasikan konfigurasi agresif dengan ambang deteksi yang lebih rendah. Dengan demikian, ketiga nilai tersebut digunakan untuk mengevaluasi *trade-off* antara sensitivitas sistem dalam menangkap perubahan kecil dan risiko meningkatnya *false positive*. Hasil deteksi diekstraksi dalam bentuk file CSV yang berisi informasi per *frame*, termasuk kode AU, label ekspresi, serta perubahan relatif posisi alis kiri dan kanan.


A. Distribusi Deteksi Berdasarkan Sensitivitas

Seluruh hasil distribusi deteksi untuk masing-masing konfigurasi sensitivitas ditunjukkan sebagai berikut:

- 1) Pada sensitivitas 1,5, label *AU_asym_micro* tampak dominan sekitar 60%, *AU4_strong* berada pada proporsi yang cukup tinggi, *AU1+AU2_high* berada pada tingkat sedang, dan *Neutral* masih muncul secara signifikan.
- 2) Pada sensitivitas 2,0, *AU_asym_micro* tetap menjadi label dominan, sementara *AU4_strong* dan

AU1+AU2_high mengalami peningkatan. Pada konfigurasi ini, jumlah *frame* berlabel *Neutral* menurun secara signifikan.

- 3) Pada sensitivitas 3,0, *AU_asym_micro* tetap berada pada proporsi yang tinggi, sedangkan *AU4_strong* meningkat secara tajam dan *AU1+AU2_high* juga mengalami peningkatan. Pada konfigurasi ini, *frame* berlabel *Neutral* hampir tidak muncul.



Gambar. 2 Timeline pergerakan alis berdasarkan konfigurasi sensitivitas

Hasil eksperimen pada Gambar. 2 menunjukkan bahwa parameter sensitivitas memiliki pengaruh yang signifikan terhadap performa deteksi. Semakin tinggi nilai sensitivitas, semakin kecil ambang deteksi yang digunakan, sehingga sistem menjadi lebih peka terhadap perubahan kecil pada posisi alis. Namun, peningkatan sensitivitas juga menyebabkan peningkatan jumlah deteksi yang tidak selalu merepresentasikan ekspresi nyata. Hal ini terlihat dari:

- 1) Penurunan jumlah *frame* dengan label *Neutral*
- 2) Peningkatan signifikan pada label *AU4_strong*
- 3) Dominasi label *AU_asym_micro*

Temuan ini sejalan dengan karakteristik *micro-expression* yang memiliki amplitudo rendah dan rentan terhadap *noise*, sehingga deteksi berbasis *threshold* sangat sensitif terhadap perubahan kecil pada *landmark* wajah.

B. Dominasi Asymmetric Micro-Expression

Salah satu temuan utama dalam penelitian ini adalah dominasi label *asymmetric micro-expression* pada semua konfigurasi sensitivitas. Hal ini menunjukkan bahwa sistem sangat sensitif terhadap perbedaan pergerakan antara alis kiri dan kanan. Interpretasi dari fenomena ini adalah berhasil menangkap *micro-movement* yang tidak simetris, yang merupakan karakteristik penting dalam *micro-expression*. Namun, sebagian deteksi kemungkinan dipengaruhi oleh faktor eksternal seperti pergerakan kepala, ketidakstabilan *landmark* dan *noise visual*.

Hasil eksperimen juga menunjukkan adanya pergeseran distribusi dari kategori *micro-expression* ke *strong expression* seiring peningkatan sensitivitas. Secara khusus label *AU4_micro* cenderung menurun dan label *AU4_strong* meningkat signifikan. Hal ini menunjukkan bahwa parameter

sensitivitas tidak hanya mempengaruhi jumlah deteksi, tetapi juga mempengaruhi interpretasi intensitas ekspresi. Dengan kata lain Sensitivity berperan sebagai penguat sinyal (*signal amplifier*), yang dapat mengubah persepsi sistem terhadap tingkat intensitas ekspresi.

IV. PEMBAHASAN

A. Temporal Pergerakan Alis

Berdasarkan data perubahan relatif (*percentage change*), ditemukan bahwa pergerakan alis sering tidak simetris, perubahan berkisar antara $\pm 1\%$ hingga $\pm 8\%$ dan banyak perubahan terjadi dalam interval *frame* yang sangat pendek. Hal ini konsisten dengan karakteristik *micro-expression* yang bersifat cepat (*short duration*), halus (*low intensity*) dan spontan (*involuntary*).

Berdasarkan hasil eksperimen dan visualisasi grafik, terlihat bahwa parameter sensitivitas memiliki pengaruh langsung terhadap perilaku sistem dalam mendeteksi *micro-expression*. Secara konseptual, sensitivitas berfungsi sebagai pengatur ambang (*threshold*) yang menentukan apakah suatu perubahan posisi alis dikategorikan sebagai sinyal (ekspresi) atau *noise*. Dalam teori *signal detection*, perubahan *threshold* akan mempengaruhi kemampuan sistem dalam membedakan antara sinyal dan *noise*.

Hal ini menunjukkan bahwa semakin tinggi nilai sensitivitas, semakin kecil ambang deteksi yang digunakan. Hal ini menyebabkan sistem menjadi lebih responsif terhadap perubahan kecil, namun juga meningkatkan kemungkinan mendeteksi *noise* sebagai ekspresi. Fenomena ini sejalan dengan prinsip bahwa sensitivitas berbanding terbalik dengan *threshold*, di mana penurunan *threshold* akan meningkatkan peluang deteksi tetapi juga meningkatkan *false alarm*.


B. Perbandingan Kinerja Antar Sensitivitas

Dari 589 *frame* yang dianalisis, diperoleh karakteristik sebagai berikut:

- 1) Sensitivitas 1,5 menunjukkan perilaku yang relatif konservatif, dengan jumlah *frame* netral masih cukup tinggi (25 *frame*). Hal ini mengindikasikan bahwa sebagian perubahan kecil pada alis belum melewati ambang deteksi, sehingga berpotensi menurunkan kemampuan sistem dalam menangkap *micro-expression* (low recall).
- 2) Sensitivitas 3,0 menghasilkan tingkat deteksi tertinggi (98.98%), namun diikuti dengan peningkatan signifikan pada kategori *strong/high* (42.78%). Hal ini menunjukkan bahwa sistem menjadi terlalu agresif, di mana perubahan kecil cenderung diklasifikasikan sebagai ekspresi dengan intensitas tinggi. Kondisi ini berpotensi meningkatkan *false positive*, terutama akibat *noise* seperti pergerakan kepala atau ketidakstabilan *landmark*.
- 3) Sensitivitas 2,0 menunjukkan keseimbangan terbaik, dengan *detection rate* tinggi (98.30%), penurunan signifikan *frame* netral (10 *frame*), serta distribusi klasifikasi yang lebih stabil dibandingkan *sensitivity* 3,0.

C. Analisis Trade-off Sensitivitas

Gambar 3 memperlihatkan adanya hubungan *trade-off* antara jumlah *frame* netral dan jumlah deteksi ekspresi kuat. Seiring meningkatnya sensitivitas jumlah *frame neutral* menurun drastis dan jumlah *strong/high* meningkat signifikan.



Gambar. 3 Trade-off antara Ambang Sensitivitas dan Detection Rate

Dalam perspektif *signal detection theory*, kondisi ini mencerminkan perubahan *decision criterion*, di mana sistem menjadi lebih permisif dalam menganggap suatu sinyal sebagai ekspresi. Akibatnya, sistem cenderung meningkatkan *hit rate*, tetapi juga berisiko meningkatkan *false alarm*. Dengan kata lain *sensitivity* yang tinggi tidak hanya meningkatkan deteksi, tetapi juga menggeser batas keputusan sistem terhadap apa yang dianggap sebagai ekspresi.

Dalam konteks ML4SE, parameter sensitivitas dapat dipandang sebagai *hyperparameter* pada tahap akuisisi data perilaku pengguna. Berbeda dengan pendekatan konvensional yang menggunakan data eksplisit seperti log interaksi, sistem ini memanfaatkan sinyal implisit berupa *micro-expression*. Namun, kualitas data yang dihasilkan sangat bergantung pada nilai sensitivitas:

- 1) Sensitivitas rendah, maka data kurang informatif
- 2) Sensitivitas tinggi, maka data terlalu noisy
- 3) Sensitivitas optimal, maka data representatif dan stabil

Sensitivitas berperan penting dalam menentukan kualitas fitur yang akan digunakan pada tahap analisis lanjutan dalam *pipeline* ML4SE. Berdasarkan seluruh analisis kuantitatif dan visualisasi, nilai *sensitivity* = 2.0 dipilih sebagai konfigurasi optimal dalam penelitian ini. Pemilihan ini didasarkan pada beberapa pertimbangan mampu menangkap *micro-expression* dengan baik (*detection rate* tinggi), mengurangi jumlah *frame* netral secara signifikan dan tidak menyebabkan *over-detection* seperti pada *sensitivity* 3.0.

V. KESIMPULAN

Penelitian ini mengusulkan pendekatan *sensitivity-aware* untuk menganalisis *micro-expression* berbasis pergerakan alis menggunakan *facial landmark* dalam konteks ML4SE. Pendekatan ini memanfaatkan perubahan relatif posisi alis terhadap *baseline personal*, *temporal smoothing*, serta klasifikasi berbasis sensitivitas untuk mengontrol ambang deteksi. Hasil eksperimen menunjukkan bahwa parameter sensitivitas berpengaruh langsung terhadap jumlah deteksi dan distribusi intensitas ekspresi. Semakin tinggi nilai sensitivitas,

sistem menjadi lebih responsif terhadap perubahan kecil, tetapi juga semakin berisiko mengklasifikasikan *noise* sebagai ekspresi. Dari tiga konfigurasi yang diuji, sensitivitas 1,5 menunjukkan perilaku konservatif dengan jumlah *frame* netral yang lebih tinggi, sedangkan sensitivitas 3,0 menghasilkan *detection rate* tertinggi tetapi cenderung meningkatkan klasifikasi *strong/high* yang berpotensi menunjukkan *over-detection*. Sensitivitas 2,0 memberikan keseimbangan terbaik dengan *detection rate* sebesar 98,30%, jumlah *frame* netral yang rendah, dan distribusi klasifikasi yang lebih stabil. Dengan demikian, sensitivitas 2,0 dipilih sebagai konfigurasi optimal dalam penelitian ini. Temuan ini menunjukkan bahwa sensitivitas berperan sebagai *decision boundary* dalam deteksi *micro-expression* dan dapat menjadi *hyperparameter* penting pada tahap akuisisi data perilaku pengguna implisit dalam *pipeline* ML4SE.

REFERENSI

- [1] Z. Kotti, R. Galanopoulou, and D. Spinellis, "Machine learning for software engineering: A tertiary study," *ACM Comput. Surv.*, vol. 55, no. 12, pp. 1–39, Dec. 2023, doi: 10.1145/3572905.
- [2] H. Gao, W. Hussain, R. J. Durán Barroso, J. Arshad, and Y. Yin, "Guest Editorial: Machine learning applied to quality and security in software systems," *IET Softw.*, vol. 17, no. 4, pp. 345–347, Aug. 2023, doi: 10.1049/sfw2.12141.
- [3] J. Alostad, "Integrating human-computer interaction and software engineering for enhanced usability using support vector machines," *Int. J. Interact. Mob. Technol.*, vol. 19, no. 16, pp. 41–59, Aug. 2025, doi: 10.3991/ijim.v19i16.53159.
- [4] D. Gaspar-Figueiredo, M. Fernández-Diego, S. Abrahão, and E. Insfran, "A comparative study on reward models for user interface adaptation with reinforcement learning," *Empir. Softw. Eng.*, vol. 30, no. 4, p. 109, Jul. 2025, doi: 10.1007/s10664-025-10659-5.
- [5] M. Antona, G. Margetis, S. Ntoa, and H. Degen, "Special issue on AI in HCI," *Int. J. Human-Computer Interact.*, vol. 39, no. 9, pp. 1723–1726, May 2023, doi: 10.1080/10447318.2023.2177421.
- [6] J. Song, "A review of the application of natural language processing in Human-Computer interaction," *Appl. Comput. Eng.*, vol. 106, no. 1, pp. 111–117, Nov. 2024, doi: 10.54254/2755-2721/106/20241328.
- [7] R. S. Maragatham, Y. A. B. El-Ebiary, S. V. K. Sridharan, V. S. Rao, and S. R. Godla, "Enhancing HCI through real-time gesture recognition with federated CNNs: Improving performance and responsiveness," *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 4, 2024, doi: 10.14569/IJACSA.2024.0150489.
- [8] Poornima M, Paramesha R, and Rohith M N, "Enhancing accessibility and assistance through eye gaze tracking: The I alert approach," *Int. J. Sci. Res. Arch.*, vol. 13, no. 2, pp. 3735–3741, Dec. 2024, doi: 10.30574/ijrsra.2024.13.2.2625.
- [9] G. A. Muhyi, Y. Wihardi, and E. Piantari, "Age estimation untuk intelligent advertising pada poster digital menggunakan convolutional neural network," *J. Apl. dan Teor. Ilmu Komput.*, vol. 7, no. 1, pp. 1–5, Mar. 2024, doi: 10.17509/jatikom.v7i1.27878.
- [10] A. Ahmad et al., "A comprehensive bibliometric survey of micro-expression recognition system based on deep learning," *Heliyon*, vol. 10, no. 5, p. e27392, Mar. 2024, doi: 10.1016/j.heliyon.2024.e27392.
- [11] N. Saffaryazdi et al., "Using facial micro-expressions in combination with EEG and physiological signals for emotion recognition," *Front. Psychol.*, vol. 13, Jun. 2022, doi: 10.3389/fpsyg.2022.864047.
- [12] S. Vajjayanthi and J. Arunnehr, "Deep neural network-based emotion recognition using facial landmark features and particle swarm optimization," *Automatika*, vol. 65, no. 3, pp. 1088–1099, Jul. 2024, doi: 10.1080/00051144.2024.2343964.
- [13] A.-L. Cimeanu, D. Popescu, and D. Iordache, "New trends in emotion recognition using image analysis by neural networks, a systematic review," *Sensors*, vol. 23, no. 16, p. 7092, Aug. 2023, doi: 10.3390/s23167092.
- [14] H. Basri, M. B. S. Junianto, and I. Kusyad, "Enhancing usability testing through sentiment analysis: A comparative study using SVM, naive

- bayes, decision trees and random forest,” *J. Teknol. Sist. Inf. dan Apl.*, vol. 7, no. 4, pp. 1603–1610, Oct. 2024, doi: 10.32493/jtsi.v7i4.45117.
- [15] H. Basri, “Optimizing sentiment analysis for usability testing: enhancing svm accuracy through kernel selection and tuning methods,” *multitek Indonesia.*, vol. 18, no. 2, pp. 105–113, Jan. 2025, doi: 10.24269/mtkind.v18i2.10615.
- [16] H. Basri, W. N. Purwanti, and I. Alparisi, “Evaluating SMOTE performance for imbalanced multi-label sentiment classification in MLSE usability testing of mobile app reviews,” *J. Tek. Inform.*, vol. 7, no. 2, pp. 937–947, 2026, [Online]. Available: <https://jutif.if.unsoed.ac.id/index.php/jurnal/article/view/5351>
- [17] X. Shen, Q. Wu, and X. Fu, “Effects of the duration of expressions on the recognition of microexpressions,” *J. Zhejiang Univ. Sci. B*, vol. 13, no. 3, pp. 221–230, Mar. 2012, doi: 10.1631/jzus.B1100063.
- [18] X. Zeng, Q. Wu, S. Zhang, Z. Liu, Q. Zhou, and M. Zhang, “A false trail to follow: Differential effects of the facial feedback signals from the upper and lower face on the recognition of micro-expressions,” *Front. Psychol.*, vol. 9, Oct. 2018, doi: 10.3389/fpsyg.2018.02015.
- [19] A. F. Abate, P. Barra, C. Bisogni, M. Nappi, and S. Ricciardi, “Near real-time three axis head pose estimation without training,” *IEEE Access*, vol. 7, pp. 64256–64265, 2019, doi: 10.1109/ACCESS.2019.2917451.
- [20] G. Sanil, K. Prakash, S. Prabhu, V. C. Nayak, and S. Sengupta, “2D-3D facial image analysis for identification of facial features using machine learning algorithms with hyper-parameter optimization for forensics applications,” *IEEE Access*, vol. 11, pp. 82521–82538, 2023, doi: 10.1109/ACCESS.2023.3298443.
- [21] C. Correia-Caeiro, A. Burrows, D. A. Wilson, A. Abdelrahman, and T. Miyabe-Nishiwaki, “CalliFACS: The common marmoset facial action coding system,” *PLoS One*, vol. 17, no. 5, p. e0266442, May 2022, doi: 10.1371/journal.pone.0266442.
- [22] S. Yang, H. Huang, Y. S. Huang, and X. Jin, “Facial action units detection using temporal context and feature reassignment,” *Comput. Animat. Virtual Worlds*, vol. 35, no. 3, May 2024, doi: 10.1002/cav.2246.
- [23] Y. Yaddaden, “Efficient dynamic emotion recognition from facial expressions using statistical spatio-temporal geometric features,” *Big Data Cogn. Comput.*, vol. 9, no. 8, p. 213, Aug. 2025, doi: 10.3390/bdcc9080213.
- [24] N. Samadiani, G. Huang, Y. Hu, and X. Li, “Happy emotion recognition from unconstrained videos using 3D hybrid deep features,” *IEEE Access*, vol. 9, pp. 35524–35538, 2021, doi: 10.1109/ACCESS.2021.3061744.
- [25] P. Chenniappan, S. Rajan, N. Madian, D. Deepa, K. S. Ali, and T. Perarasi, “Geometric based feature extraction techniques for facial expression recognition using SVM,” in *2021 Smart Technologies, Communication and Robotics (STCR)*, Oct. 2021, pp. 1–6. doi: 10.1109/STCR51658.2021.9588963.
- [26] J. N. Schneider, T. R. Brick, and I. Dziobek, “Distance to the neutral face predicts arousal ratings of dynamic facial expressions in individuals with and without autism spectrum disorder,” *Front. Psychol.*, vol. 11, Nov. 2020, doi: 10.3389/fpsyg.2020.577494.
- [27] A. A. Macedo, L. Persona, and F. Meloni, “Recognition of emotions through facial geometry with normalized landmarks,” in *Proceedings of the 30th Brazilian Symposium on Multimedia and the Web (WebMedia 2024)*, Oct. 2024, pp. 257–266. doi: 10.5753/webmedia.2024.243252.
- [28] D. Canedo and A. J. R. Neves, “Facial expression recognition using computer vision: A systematic review,” *Appl. Sci.*, vol. 9, no. 21, p. 4678, Nov. 2019, doi: 10.3390/app9214678.
- [29] M. Khademi and L.-P. Morency, “Relative facial action unit detection,” in *IEEE Winter Conference on Applications of Computer Vision*, Mar. 2014, pp. 1090–1095. doi: 10.1109/WACV.2014.6835983.
- [30] Y. Wu, M. Arevalillo-Herráez, and P. Arnau-González, “Improved Action Unit Detection Based on a Hybrid Model,” *IEEE Access*, vol. 11, pp. 77585–77595, 2023, doi: 10.1109/ACCESS.2023.3297266.