

KLASIFIKASI TINGKAT STRES BERBASIS *HEART RATE VARIABILITY* MENGGUNAKAN LOGISTIC REGRESSION PADA ESP32

Aldrey Diriyah^{1*}, Muhammad Aulia Bahtiar², Suci Fitria³, Rudi Setiawan⁴, Nova Resfita⁵

^{1,2,3,4,5}Teknik Biomedis, Institut Teknologi Sumatera

aldrey.122430054@student.itera.ac.id¹, muhammad.122430062@student.itera.ac.id²,
suci.122430128@student.itera.ac.id³, rudi.setiawan@bm.itera.ac.id⁴, nova.resfita@bm.itera.ac.id⁵

Submitted July 7, 2026; Revised August 29, 2026; Accepted August 30, 2026

Pengukuran tingkat stres yang hanya mengandalkan penilaian subjektif sering kali rentan terhadap bias persepsi, sehingga diperlukan metode objektif berbasis biomarker fisiologis seperti *Heart Rate Variability* (HRV). Penelitian ini bertujuan untuk mengembangkan sistem deteksi stres portabel menggunakan sensor PPG MAX30102 dan mikrokontroler ESP32, serta menganalisis perubahan parameter HRV sebelum dan sesudah pemberian stimulus kognitif. Metode yang digunakan adalah desain eksperimental *pre-post* pada 20 subjek, dengan tugas aritmatika mental sebagai pemicu stres. Data sinyal PPG diproses untuk mengekstraksi fitur *time-domain* (RMSSD, SDNN, dan Mean BPM) yang kemudian diklasifikasikan menggunakan algoritma Logistic Regression. Validasi label tingkat stres dilakukan menggunakan kuesioner DASS-21 dan PSS-10. Hasil penelitian menunjukkan adanya respons fisiologis yang signifikan pasca-stimulus, ditandai dengan peningkatan rata-rata Mean BPM dari 74 BPM menjadi 84 BPM, serta penurunan nilai variabilitas jantung (RMSSD dan SDNN) yang mengindikasikan aktivasi saraf simpatis. Model klasifikasi Logistic Regression berhasil membedakan kondisi stres dengan tingkat akurasi mencapai 100% pada data uji. Namun demikian, capaian sempurna pada dataset skala kecil (N=20) ini mengindikasikan perlunya pengujian lanjutan dengan ukuran sampel yang lebih besar guna meminimalkan risiko bias *overfitting*.

Kata Kunci : ESP32, *Heart Rate Variability*, Klasifikasi Stres, *Logistic Regression*, MAX30102

Abstract

Measurement of stress levels relying solely on subjective assessment is often prone to perception bias, thus necessitating an objective method based on physiological biomarkers such as Heart Rate Variability (HRV). This study aims to develop a portable stress detection system using the MAX30102 PPG sensor and ESP32 microcontroller, as well as to analyze changes in HRV parameters before and after a cognitive stimulus. The method used was a pre-post experimental design on 20 subjects, with a mental arithmetic task as the stress trigger. PPG signal data were processed to extract time-domain features (RMSSD, SDNN, and Mean BPM), which were then classified using the Logistic Regression algorithm. Stress level label validation was conducted using the DASS-21 and PSS-10 questionnaires. The results showed a significant physiological response post-stimulus, characterized by an increase in the average Mean BPM from 74 BPM to 84 BPM, and a decrease in heart rate variability values (RMSSD and SDNN), indicating sympathetic nerve activation. The Logistic Regression classification model successfully differentiated stress conditions with an accuracy rate reaching 100% on the test data. However, this perfect achievement on a small-scale dataset (N=20) indicates the need for further testing with a larger sample size in order to minimize the risk of overfitting bias.

Keywords : ESP32, *Heart Rate Variability*, *Logistic Regression*, MAX30102, *Stress Classification*

1. PENDAHULUAN

Stres psikologis merupakan salah satu faktor yang berperan penting dalam menurunkan kualitas kesehatan fisik dan

mental, terutama pada kelompok usia produktif. Paparan stres yang berlangsung secara berulang dapat memicu gangguan sistem saraf otonom, meningkatkan risiko penyakit kardiovaskular, serta menurunkan

kemampuan kognitif [1]. Selama ini, penilaian tingkat stres umumnya dilakukan menggunakan instrumen psikometrik *self-report* seperti *Depression Anxiety Stress Scale* (DASS-21) dan *Perceived Stress Scale* (PSS-10)[2]. Meskipun instrumen tersebut telah tervalidasi secara luas, metode penilaian subjektif memiliki keterbatasan karena sangat bergantung pada persepsi individu dan rentan terhadap bias pelaporan [3].

Untuk mengatasi keterbatasan tersebut, pendekatan objektif berbasis biomarker fisiologis seperti *Heart Rate Variability* (HRV) mulai banyak digunakan. HRV merepresentasikan variasi interval antar denyut jantung pada interval RR dan mencerminkan keseimbangan aktivitas sistem saraf otonom [4]. Penurunan nilai HRV pada parameter domain waktu, khususnya *Root Mean Square of Successive Differences* (RMSSD) dan *Standard Deviation of NN intervals* (SDNN), telah dikaitkan dengan peningkatan aktivitas saraf simpatis akibat stres [4], [5]. Sejumlah studi menegaskan bahwa pemberian stimulus kognitif, seperti tugas aritmatika mental, mampu menginduksi stres akut yang terlihat jelas dari perubahan signifikan pada rentang HRV[6].


Sebagian besar evaluasi HRV pada penelitian terdahulu masih mengandalkan perangkat elektrokardiogram (EKG) klinis yang relatif mahal dan kurang fleksibel untuk pemantauan harian. Perkembangan *Internet of Things* (IoT) dan mikrokontroler membuka peluang pemanfaatan sensor *photoplethysmography* (PPG) berbiaya rendah seperti MAX30102 [7]. Penggunaan sensor optik yang diintegrasikan dengan mikrokontroler ESP32 memberikan solusi akuisisi data kardiovaskular yang nirkabel dan portabel [8]. Walaupun rentan terhadap artefak sinyal pergerakan, tantangan pada sensor PPG dapat diatasi melalui pendekatan pengolahan sinyal digital yang tepat [9].

Implementasi kecerdasan buatan dalam skala kecil yang disebut *Tiny Machine Learning* atau TinyML memungkinkan inferensi data fisiologis dilakukan langsung pada perangkat *edge* [10]. Algoritma klasifikasi seperti Logistic Regression terbukti relevan untuk diaplikasikan pada mikrokontroler karena kebutuhan memori yang kecil, waktu komputasi yang efisien, serta stabilitas yang sangat baik pada dataset berukuran kecil hingga menengah [11]. Pendekatan model regresi ini juga mampu memberikan interpretabilitas yang kuat terkait hubungan antara perubahan fitur fisiologis dengan kondisi klinis pasien [12].

Berdasarkan tinjauan literatur tersebut, belum banyak penelitian yang memadukan ekstraksi HRV dari sensor PPG *low-cost* dengan pemrosesan *machine learning* yang divalidasi langsung oleh dua kuesioner psikologis standar sekaligus. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem pendeteksi stres portabel menggunakan MAX30102 dan ESP32, menganalisis perubahan fitur HRV sebelum dan sesudah pemberian stimulus kognitif, serta mengklasifikasikan tingkat stres menggunakan Logistic Regression dengan validasi dari DASS-21 dan PSS-10. Manfaat dari penelitian ini adalah dihasilkannya alternatif *prototype* alat pemantauan kesehatan mental yang objektif, portabel, dan terjangkau, sehingga dapat mendukung upaya deteksi dini dan mitigasi stres pada masyarakat secara luas.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan rancangan *pre-post experimental design* untuk mengevaluasi perubahan parameter HRV sebelum dan sesudah subjek diberikan stimulus kognitif. Diagram alir penelitian yang menggambarkan tahapan pengambilan data hingga analisis klasifikasi ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir Penelitian

Ruang lingkup atau objek penelitian melibatkan 20 subjek partisipan sukarela yang terdiri dari 7 laki-laki dan 13 perempuan dengan rentang usia 20–22 tahun, di mana seluruh subjek dipastikan berada dalam kondisi kesehatan fisik yang baik saat pengambilan data. Karakteristik subjek penelitian disajikan pada Tabel 1.

Tabel 1. Subjek Penelitian

No	Jenis kelamin	Jumlah	Rentang usia (tahun)
1	Laki-laki	7	20-21
2	Perempuan	13	20-21
-		20	20-21

Bahan dan alat utama yang digunakan dalam penelitian ini terdiri dari perangkat keras berupa sensor PPG MAX30102 untuk mendeteksi sinyal kardiovaskular, mikrokontroler ESP32 sebagai pusat kendali dan komunikasi nirkabel, kabel *jumper*, serta komputer. Untuk perangkat lunak, penelitian ini menggunakan Arduino IDE, Google Sheets untuk basis data, Google Colab untuk analisis *machine learning*, serta instrumen kuesioner cetak

DASS-21 dan PSS-10. Rincian alat dan bahan disajikan pada Tabel 2. Seluruh rangkaian pengambilan data dan eksperimen dilaksanakan di fasilitas laboratorium Program Studi Teknik Biomedis, Institut Teknologi Sumatera.

Tabel 2. Alat dan Bahan

Perangkat keras	Perangkat lunak
Sensor PPG MAX30102	Arduino IDE
Mikrokontroler ESP32	Google Sheets
Kabel <i>jumper</i> dan USB type C	Google Colab
Laptop	Kuesioner DAS-21 dan PSS

Teknik pengumpulan data diawali dengan meminta subjek mengisi kuesioner DASS-21 dan PSS-10 untuk memperoleh gambaran awal atau label tingkat stres subjektif. Setelah itu, perekaman sinyal fisiologis HRV *baseline* dilakukan selama 60 detik dalam kondisi istirahat. Subjek kemudian diberikan stimulus kognitif berupa tugas hitung cepat seperti tes koran yang dirancang untuk memicu beban mental dan respons stres. Segera setelah stimulus tersebut selesai dikerjakan, perekaman HRV *post-stimulus* kembali dilakukan selama 60 detik. Seluruh data interval RR yang diakuisisi oleh sensor diproses oleh ESP32 dan dikirimkan secara otomatis menuju Google Sheets melalui *HTTP GET request*. Mekanisme pengiriman data dari sensor hingga penyimpanan ditunjukkan pada Gambar 2.



Gambar 2. Mekanisme Pengiriman Data


Teknik analisis penelitian diawali dengan tahapan *pre-processing* data untuk menyeleksi artefak sinyal dan membuang nilai interval RR yang dianggap tidak fisiologis, yakni rentang nilai di bawah 300

ms atau di atas 2000 ms, sekaligus mengeliminasi nilai *outlier* [13]. Sinyal yang telah dibersihkan kemudian diproses untuk mengekstraksi fitur dominan pada *time-domain* [14]. Daftar fitur HRV yang digunakan ditampilkan pada Tabel 3.

Tabel 3. Fitur HRV yang Diekstraksi

Fitur	Deskripsi
RMSSD	Akar rata-rata kuadrat perbedaan RR berurutan [12]
SDNN	Simpangan baku seluruh RR interval [7]
Mean RR	Rata-rata RR (ms) [13]
Median RR	Median RR [13]
pNN50	Proporsi selisih RR > 50 ms [11]
Mean BPM	BPM rata-rata selama 1 menit [10]
STD BPM	Variabilitas BPM [9]
<i>N Beats</i>	Jumlah <i>beat</i> valid [9]

Fitur-fitur tersebut dinormalisasi menggunakan fungsi “*StandardScaler*” dan dipisahkan menjadi data *training set* serta *testing set* dengan rasio 80:20. Pada tahap akhir, algoritma *Logistic Regression* diterapkan untuk mengklasifikasikan kondisi tingkat stres partisipan. Alur pemodelan regresi logistik ini ditunjukkan pada Gambar 3. Kinerja akhir dari model klasifikasi kemudian dievaluasi menggunakan *confusion matrix* dengan mengukur capaian metrik akurasi, presisi, *recall*, dan *F1-score*.



Gambar 3. Proses Pemodelan Logistic Regression

3. HASIL DAN PEMBAHASAN

Pengukuran tingkat stres partisipan dilakukan menggunakan dua pendekatan, yaitu validasi psikologis melalui kuesioner serta pengukuran parameter fisiologis *Heart Rate Variability* (HRV). Hasil pengisian kuesioner DASS-21 dan PSS-10 pada 20 subjek menunjukkan distribusi kelas yang seimbang. Sebanyak 10 subjek (50%) terklasifikasi dalam kategori tidak stres (DASS-21) dan stres rendah (PSS-10), sedangkan 10 subjek lainnya (50%) berada pada kategori stres dan stres tinggi. Konsistensi antara kedua instrumen ini memberikan landasan label (*ground truth*) yang valid untuk pemodelan klasifikasi [9]. Distribusi tingkat stres ditunjukkan pada Tabel 4.

Tabel 4. Distribusi Tingkat Stres Kuesioner

Kategori Stress	DASS-21 (Jumlah Subjek)	PSS-10 (Jumlah Subjek)
Tidak stres / Stres rendah	10	10
Stres / Stres tinggi	10	10
Total	20	20


Evaluasi parameter fisiologis difokuskan pada perubahan nilai RMSSD, SDNN, dan *Mean BPM* sebelum dan sesudah perlakuan stimulus kognitif. Ketiga parameter ini dipilih karena merepresentasikan respons langsung sistem saraf otonom terhadap kondisi relaksasi dan stres [8]. Nilai *Mean BPM* yang merupakan representasi langsung dari aktivitas kardiovaskular menunjukkan tren peningkatan yang signifikan pada sebagian besar subjek [7]. Perubahan *Mean BPM* dapat dilihat pada Tabel 5 dan divisualisasikan pada Gambar 4.

Tabel 5. Nilai Mean BPM Sebelum dan Sesudah Perlakuan

Subjek	Mean BPM <i>Pre</i>	Mean BPM <i>Post</i>
1	76.96	97.02
2	73.49	97.82
3	71.54	101.46
4	78.60	84.65
5	61.37	70.13
6	90.39	95.07
7	74.45	71.17
8	72.00	83.44
9	78.77	86.65
10	73.89	82.33
11	77.45	68.89
12	77.07	83.27
13	69.35	86.73
14	76.59	91.72
15	73.58	80.06
16	69.59	65.26
17	69.25	71.74
18	72.54	85.09
19	72.29	80.37
20	74.97	74.84


Tabel 6. Nilai RMSSD Sebelum dan Sesudah Perlakuan

Subjek	RMSSD <i>Pre</i>	RMSSD <i>Post</i>
1	0.4548	0.0788
2	0.0582	0.0586
3	0.0346	0.0509
4	0.0164	0.0318
5	0.1072	0.0243
6	0.0125	0.0191
7	0.0470	0.0335
8	0.0416	0.0403
9	0.0764	0.0697
10	0.0520	0.0315
11	0.0529	0.0706
12	0.2001	0.0414
13	0.0908	0.6010
14	0.0842	0.0372
15	0.0673	0.0452
16	0.0874	0.0849
17	0.1918	0.0670
18	0.0909	0.0437
19	0.1052	0.0466
20	0.1009	0.0982



Gambar 4. Grafik Perubahan Mean BPM Subjek

Peningkatan *Mean* BPM *pre*-stimulus menunjukkan bahwa tugas aritmatika mental terbukti efektif dalam memberikan beban kognitif yang memicu stres akut. Selain itu, variabilitas HRV yang direpresentasikan oleh parameter RMSSD juga menunjukkan respons fisiologis yang relevan. Sebagian besar subjek mengalami penurunan nilai RMSSD setelah diberikan stimulus, seperti yang ditunjukkan pada Tabel 6 dan Gambar 5.




Gambar 5. Grafik Perubahan RMSSD Subjek

Penurunan nilai RMSSD dan SDNN mengonfirmasi terjadinya dominasi aktivitas sistem saraf simpatis saat partisipan mengalami tekanan mental, sekaligus melemahnya fungsi kontrol parasimpatis. Temuan ini sejalan dengan studi penelitian sebelumnya yang menyatakan bahwa beban mental akut berkorelasi kuat dengan tertekannya variabilitas detak jantung [15], [16]. Meskipun terdapat variasi respons pada beberapa subjek misalnya pada Subjek 13, tren umum yang diperoleh membuktikan keandalan sensor MAX30102 pada

mikrokontroler ESP32 untuk mendeteksi respons stres fisiologis.

Tahap akhir analisis yakni evaluasi model klasifikasi Logistic Regression yang diterapkan pada fitur HRV *time-domain* (RMSSD, SDNN, dan *Mean BPM*). Hasil pengujian menunjukkan bahwa model mampu mencapai kinerja sempurna, dengan nilai akurasi, presisi, *recall*, dan *F1-score* masing-masing sebesar 100% pada data uji. Distribusi prediksi yang tepat sasaran ini divisualisasikan melalui *confusion matrix* pada Gambar 6.



Gambar 6. Confusion Matrix Model Logistic Regression

Capaian ini menunjukkan pemisahan kelas yang sangat baik, yang didukung oleh kemampuan algoritma *Logistic Regression* dalam menangani dataset berskala kecil secara efisien tanpa komputasi yang berat. Hal ini menjadikannya sangat ideal untuk diimplementasikan sebagai sistem pendukung komputasi *edge* (*TinyML*) pada perangkat portabel dengan sumber daya terbatas seperti ESP32 [17].

Akan tetapi, interpretasi terhadap tingkat akurasi absolut 100% ini harus dilakukan secara kritis. Pada ukuran sampel eksperimental yang terbatas ($N=20$), tingginya performa model membawa risiko *overfitting* yang sangat besar [18]. Model berpotensi menghafal pola data spesifik dari *testing set* dan kemungkinan mengalami

penurunan akurasi apabila dihadapkan pada variasi data HRV dari populasi baru. Oleh karena itu, pengujian ekstensif dengan penambahan skala partisipan sangat diperlukan untuk memvalidasi generalisasi model sebelum diimplementasikan pada skenario pemantauan klinis *real-time* [19].

4. SIMPULAN

Penelitian ini telah berhasil mengembangkan sistem purwarupa deteksi stres portabel menggunakan sensor PPG MAX30102 dan mikrokontroler ESP32 yang terintegrasi dengan algoritma *machine learning Logistic Regression*. Berdasarkan hasil pengujian eksperimental *pre-post* pada 20 subjek, pemberian stimulus kognitif berupa tugas aritmatika mental terbukti efektif memicu respons stres akut. Respons fisiologis ini ditandai dengan peningkatan rata-rata *Mean BPM* dari 74 BPM menjadi 84 BPM, serta penurunan nilai variabilitas jantung (RMSSD dan SDNN) yang secara klinis mengindikasikan dominasi aktivitas saraf simpatik akibat peningkatan beban mental.

Temuan objektif tersebut juga tervalidasi secara konsisten oleh penilaian subjektif melalui kuesioner DASS-21 dan PSS-10. Pada tahap pemodelan, klasifikasi tingkat stres menggunakan *Logistic Regression* mampu membedakan kondisi relaksasi dan stres dengan tingkat akurasi mencapai 100% pada data uji. Meskipun capaian ini menunjukkan potensi pemrosesan kecerdasan buatan skala kecil (*TinyML*) yang sangat baik pada perangkat *edge*, pengujian ekstensif dengan ukuran sampel yang jauh lebih besar tetap mutlak diperlukan guna memvalidasi kemampuan generalisasi model dan meminimalkan risiko *overfitting*. Secara keseluruhan, integrasi antara sensor optik berbiaya rendah, analisis fitur HRV *time-domain*, dan algoritma regresi linear terbukti mampu menjawab rumusan masalah dengan menghadirkan alternatif alat pemantauan

tingkat stres yang objektif, portabel, non-invasif, dan terjangkau.

DAFTAR PUSTAKA

- [1] J. C. Benítez and D. Restrepo, "Longitudinal Effects of Stress in an Academic Context on Psychological Well-being, Physiological Markers, Health Behaviors, and Academic Performance in University Students," *BMC Psychol.*, vol. 13, no. 1, Dec. 2025, doi: 10.1186/s40359-025-03041-z.
- [2] D. Manzar, M. Salahuddin, and J. S. Alotaibi, "Depression, Anxiety, and Stress Scale-21 (DASS-21): Further Psychometric Exploration Using Robust Item Response Theory and Classical Theory Measures Among University Students," *PLoS One*, vol. 20, no. 7, Jul. 2025, doi: 10.1371/journal.pone.0325238.
- [3] M. Gellisch and M. Bablok, "Neurobiological Stress Markers in Educational Research: A Systematic Review of Physiological Insights in Health Science Education," *Trends Neurosci. Educ.*, vol. 37, Dec. 2024, doi: 10.1016/j.tine.2024.100242.
- [4] Kane, Martin, and C. Rees, "Continuous Heart Rate Variability Monitoring, Stress and Recovery in Doctors: a Systematic Review and Meta-analysis," *Occup. Med. (Chic. Ill.)*, vol. 75, no. 9, pp. 630–639, Dec. 2025, doi: 10.1093/occmed/kqaf101.
- [5] M. Elgendi, K. Markov, and H. Liu, "Wearable Devices for Anxiety Assessment: a Systematic Review," *Communications Medicine*, vol. 6, no. 1, Dec. 2026, doi: 10.1038/s43856-025-01234-6.
- [6] A. S. Shah, V. Vaccarino, and K. Moazzami, "Autonomic Reactivity to Mental Stress is Associated with Cardiovascular Mortality," *European Heart Journal Open*, vol. 4, no. 6, Nov. 2024, doi: 10.1093/ehjopen/oeae086.
- [7] J. E. Miranda-Vega, R. Ayala-Figueroa, Y. Villarreal-González, and P. Escarcega-Zepeda, "Comparative Assessment of PPG-Derived HRV Using MAX30102 Sensor and Analog Circuitry with ADS1115 ADC," *Sensors*, vol. 26, no. 8, Apr. 2026, doi: 10.3390/s26082487.
- [8] Y. Segono, E. Hutagalung, H. G. Simbolon, and A. Ridwan, "IoT-Based Stress Monitoring Using CNN for HRV-GSR Analysis," *Sinkron*, vol. 10, no. 1, pp. 621–637, Jan. 2026, doi: 10.33395/sinkron.v10i1.15671.
- [9] Y. Watanabe, N. Yamane, A. Sathyanarayana, and V. Mishra, "Beyond Motion Artifacts: Optimizing PPG Preprocessing for Accurate Pulse Rate Variability Estimation," in *UbiComp Companion 2025 - Companion of the 2025 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, Association for Computing Machinery, Inc, Dec. 2025, pp. 1176–1182. doi: 10.1145/3714394.3756241.
- [10] P. Ganesan, Y. R. Thota, H. Shehata, and T. Nikoubin, "TinyML Based Stress Detection Utilizing PPG Signals: A Lightweight Approach for Smart Wearable Devices," in *Proceedings of the ACM Great Lakes Symposium on VLSI*, Association for Computing Machinery, Jun. 2025, pp. 941–946. doi: 10.1145/3716368.3735274.
- [11] A. Chatterjee, M. Riegler, and P. Halvorsen, "Stress Management with HRV Following AI, Semantic Ontology, Genetic Algorithm and Tree Explainer," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-87510-w.

- [12] R. A. Prakoso, E. R. Widasari, and I. Nurfarida, "Sistem Deteksi Stres menggunakan Metode Support Vector Machine dengan Fitur RMSSD dan PNN50," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 13, no. 3, pp. 2355–7699, Jun. 2026.
- [13] M. Karlsson, R. Hörnsten, A. Rydberg, and U. Wiklund, "Automatic Filtering of Outliers in RR Intervals Before Analysis of Heart Rate Variability in Holter Recordings: a Comparison with Carefully Edited Data," 2012. [Online]. Available: <http://www.biomedical-engineering-online.com/content/11/1/2>
- [14] E. Antikainen, H. Njoum, W. Maetzler, and P. O'Donnell, "Assessing Fatigue and Sleep in Chronic Diseases using Physiological Signals from Wearables: A Pilot Study," *Front. Physiol.*, vol. 13, Nov. 2022, doi: 10.3389/fphys.2022.968185.
- [15] Castaldo, Melillo, and Bracale, "Acute Mental Stress Assessment via Short Term HRV Analysis in Healthy Adults: A Systematic Review with Meta-analysis," *Biomed. Signal Process. Control*, vol. 18, pp. 370–377, Nov. 2015, doi: 10.1016/j.bspc.2015.02.012.
- [16] R. Capotorto, V. Ronca, G. Di Flumeri, and F. Babiloni, "Beyond The Lab: a Review on Neurophysiological Mental States Assessment in Real-world Settings," *Progress in Biomedical Engineering*, vol. 8, no. 3, Sep. 2026, doi: 10.1088/2516-1091/ae7863.
- [17] R. Lavelle-Hill, G. Smith, and K. Murayama, "Bridging Traditional-Statistics and Machine-Learning Approaches in Psychology: Navigating Small Samples, Measurement Error, Nonindependent Observations, and Missing Data," *Adv. Methods Pract. Psychol. Sci.*, vol. 8, no. 3, Jul. 2025, doi: 10.1177/25152459251345696.
- [18] R. Singh, V. Ranjan, A. Ganguly, and S. Halder, "Stress Classification Using Heart Rate Variability and Machine Learning Models," *Procedia Comput. Sci.*, vol. 258, no. 3, pp. 4248–4256, 2025, doi: 10.1016/j.procs.2025.04.674.
- [19] M. Bahameish, T. Stockman, and J. Requena Carrión, "Strategies for Reliable Stress Recognition: A Machine Learning Approach Using Heart Rate Variability Features," *Sensors*, vol. 24, no. 10, May 2024, doi: 10.3390/s24103210.