

## Sistem Klasifikasi Tingkat Stres Mahasiswa Tingkat Akhir Berbasis Web Menggunakan *Support Vector Machine*

Megawati<sup>1)</sup>, Maura Widyaningsih<sup>2)</sup>, Abdul Hadi<sup>3)</sup>, Esty Aryani Safithry<sup>4)</sup>

<sup>1)2)3)</sup> Program Studi Teknik Informatika, STMIK Palangkaraya  
Jl. G Obos No. 114, Kota Palangka Raya, Kalimantan Tengah

<sup>1)</sup> mgmegawti@gmail.com

<sup>2)</sup> maurawidya@gmail.com

<sup>3)</sup> abdulhadi@stmikplk.ac.id

<sup>4)</sup> Program Studi Psikologi, Universitas Muhammadiyah  
Jl. RTA Milono KM. 1,5, Kota Palangka Raya, Kalimantan Tengah

<sup>4)</sup> estiaryanisafithry@umpr.ac.id

### Abstrak

Tekanan selama penyusunan tugas akhir, keterbatasan waktu, serta tuntutan kelulusan menjadi pemicu utama stres akademik pada mahasiswa tingkat akhir. Penelitian ini menggunakan data sebanyak 65 mahasiswa STMIK Palangkaraya yang diperoleh melalui kuesioner dengan instrumen PSS-10. Untuk mendukung deteksi dini, dikembangkan sistem klasifikasi tingkat stres berbasis web menggunakan algoritma *Support Vector Machine* (SVM). Data melalui tahapan prapemrosesan, pelabelan, dan normalisasi sebelum dimodelkan menggunakan beberapa kernel, yaitu linear, polynomial, RBF, dan sigmoid. Penyetelan *hyperparameter* dilakukan dengan GridSearchCV dan *cross-validation*. Hasil pengujian menunjukkan bahwa kernel polynomial memberikan kinerja terbaik dengan nilai macro F1-score sebesar 0,914 dan akurasi 92,31%. Kontribusi penelitian ini adalah pengembangan sistem klasifikasi stres berbasis web yang mampu mengidentifikasi tingkat stres secara akurat, praktis, dan efisien, sehingga dapat dimanfaatkan sebagai alat bantu evaluasi awal kondisi stres akademik mahasiswa.

**Kata kunci:** Mahasiswa tingkat akhir, *Machine learning*, Klasifikasi stres, SVM, Website

### Abstract

Pressure during thesis completion, time constraints, and graduation demands are major contributors to academic stress among final-year students. This study utilized data from 65 students of STMIK Palangkaraya, collected through a questionnaire based on the PSS-10 instrument. To support early detection, a web-based stress level classification system was developed using the *Support Vector Machine* (SVM) algorithm. The data underwent preprocessing, labeling, and normalization before being modeled using several kernels, including linear, polynomial, RBF, and sigmoid. Hyperparameter tuning was performed using GridSearchCV and *cross-validation*. The results showed that the polynomial kernel achieved the best performance, with a macro F1-score of 0.914 and an accuracy of 92.31%. The contribution of this study lies in the development of a web-based stress classification system that can accurately, practically, and efficiently identify stress levels, making it useful as an early evaluation tool for students' academic stress conditions.

**Keywords:** Final year students, *Machine learning*, Stress classification, SVM, Website

## 1. PENDAHULUAN

Berbagai tantangan akademik di akhir studi seperti tuntutan kelulusan tepat waktu, keterbatasan waktu, kendala penelitian, serta tekanan internal dan eksternal meningkatkan risiko stres akademik pada mahasiswa, khususnya saat penyusunan tugas akhir. Di Indonesia, prevalensi stres pada fase ini tergolong tinggi, berkisar 36,7% hingga lebih dari 70%, dengan mayoritas pada

kategori sedang hingga tinggi [1], [2]. Stres yang tidak terkelola dapat menurunkan prestasi dan konsentrasi serta meningkatkan risiko gangguan mental seperti kecemasan dan depresi [3].

Pengukuran stres umumnya masih menggunakan kuesioner manual yang bersifat deskriptif dan membutuhkan waktu dalam interpretasi [4]. Di era digital, integrasi dengan teknologi memungkinkan evaluasi *real-time*. *Machine learning*, khususnya *Support Vector Machine* (SVM), banyak digunakan untuk klasifikasi tekanan mental dengan akurasi di atas 90% [5], [6]. SVM efektif pada data berdimensi tinggi dan dataset kecil seperti *Perceived Stress Scale* (PSS-10) [7]. SVM efektif pada data berdimensi tinggi dan dataset kecil seperti PSS-10 [8].

Sebagian besar penelitian masih berfokus pada aspek teoritis atau data statis, serta belum menyediakan sistem interaktif yang dapat digunakan langsung oleh mahasiswa. Oleh karena itu, penelitian ini mengintegrasikan SVM ke dalam sistem berbasis web untuk klasifikasi stres secara *real-time* dan aplikatif. Penelitian ini menggunakan PSS-10 sebagai instrumen utama yang terdiri dari 10 pernyataan skala Likert untuk mengelompokkan stres menjadi rendah, sedang, dan tinggi [9]. Tujuannya adalah membangun sistem klasifikasi stres akademik berbasis web yang cepat, mudah digunakan, dan dilengkapi rekomendasi penanganan mandiri.

## 2. TINJAUAN PUSTAKA

### 2.1 Stres Akademik Mahasiswa

Stres akademik muncul sebagai konsekuensi dari ketidakseimbangan antara tuntutan pendidikan dengan kapasitas adaptasi yang dimiliki mahasiswa. Fenomena ini tidak hanya dipicu oleh faktor internal seperti manajemen diri, tetapi juga variabel eksternal seperti ekspektasi sosial dan beban kurikulum yang intens [10]. Dalam konteks penelitian ini, pemahaman terhadap stres akademik menjadi krusial karena sifatnya yang multidimensional mencakup aspek ketidakpastian dan kontrol diri yang kemudian akan diukur secara kuantitatif melalui instrumen psikologis untuk menentukan kategori kesehatan mental mahasiswa.

### 2.2 *Perceived Stress Scale*

Untuk mengonversi fenomena psikologis tersebut ke dalam data yang dapat diolah, digunakan *Perceived Stress Scale* (PSS). Instrumen ini mengevaluasi sejauh mana situasi mahasiswa dianggap sebagai beban yang tidak terprediksi dan sulit dikendalikan [9], [11]. Dalam operasionalisasinya, PSS menggunakan butir pertanyaan yang memerlukan konsistensi arah interpretasi. Oleh karena itu, item yang berorientasi positif (item 4, 5, 7, dan 8) harus melalui proses *reverse scoring*. Secara matematis, transformasi skor ini dirumuskan dalam Persamaan (1).

$$X'_i = 4 - X_i \quad (1)$$

Dengan 4 merupakan skor maksimum,  $X_i$  merupakan skor awal dan  $X'_i$  merupakan skor setelah *reverse scoring*. Proses ini memastikan bahwa total skor yang dihasilkan mencerminkan tingkat stres secara akurat sebelum diproses oleh algoritma pembelajaran mesin.

### 2.3 Skala Likert

Data primer mengenai persepsi stres dikumpulkan menggunakan skala Likert. Skala ini berfungsi untuk mengukur intensitas sikap atau persepsi responden melalui pilihan jawaban bertingkat [12]. Dalam penelitian ini, skala Likert menyediakan struktur data ordinal yang kemudian dikuantifikasi agar dapat diintegrasikan dengan metode analisis statistik dan komputasi. Penggunaan skala ini sangat relevan untuk menangkap nuansa subjektif dari stres akademik yang sulit diukur secara biner.

### 2.4 *Support Vector Machine*

Data yang telah dikumpulkan melalui PSS dan skala Likert merupakan data berdimensi tinggi yang memerlukan metode klasifikasi yang tangguh. SVM dipilih karena kemampuannya dalam menemukan *hyperplane optimal* yang memisahkan kategori stres (misalnya: rendah, sedang, tinggi) berdasarkan fitur-fitur yang ada [13]. Data yang telah dikumpulkan melalui PSS dan skala Likert merupakan data berdimensi tinggi

yang memerlukan metode klasifikasi yang tangguh. SVM dipilih karena kemampuannya dalam menemukan *hyperplane optimal* yang memisahkan kategori stres (misalnya: rendah, sedang, tinggi) berdasarkan fitur-fitur yang ada [14]. Beberapa fungsi kernel yang umum digunakan dapat dilihat pada Tabel 1.


Tabel 1. Berbagai fungsi kernel SVM

Fungsi Kernel	Persamaan
Linear	$K(\vec{x}_i, \vec{x}_j) = \vec{x}_i \cdot \vec{x}_j$
Radial Bias Function (RBF)	$K(\vec{x}_i, \vec{x}_j) = \left( \frac{\ \vec{x}_i - \vec{x}_j\ ^2}{2\sigma^2} \right)$
Sigmoid	$K(\vec{x}_i, \vec{x}_j) = \tanh(\alpha \vec{x}_i \cdot \vec{x}_j + \beta)$
Polynomial	$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j + 1)^p$

### 3. METODE PENELITIAN

#### 3.1 Tahapan Penelitian

Gambar 1 menunjukkan alur penelitian ini terdiri dari beberapa tahapan, yaitu pengumpulan data, praproses data (*pre-processing*), pemodelan menggunakan algoritma SVM, dan evaluasi kinerja model. Tahapan tersebut dirancang untuk menghasilkan model klasifikasi tingkat stres mahasiswa tingkat akhir yang akurat dan stabil sebagai dasar deteksi dini stres akademik.



Gambar 1 Tahapan penelitian


#### 3.2 Pengumpulan Data

Proses pengumpulan data dilakukan secara daring melalui *platform* Google Forms menggunakan instrumen PSS-10 yang telah diadaptasi ke konteks mahasiswa tingkat akhir, khususnya pada tahap penyusunan tugas akhir. Adaptasi dilakukan tanpa mengubah konstruk utama dan telah divalidasi oleh psikolog untuk memastikan keakuratan pengukuran. Daftar pertanyaan disajikan pada Tabel 2.

Tabel 2. Pertanyaan kuesioner PSS-10

No	Pertanyaan
1	Dalam sebulan terakhir, seberapa sering Anda merasa kesal karena ada masalah TA yang muncul tiba-tiba?
2	Dalam sebulan terakhir, seberapa sering Anda merasa tidak bisa mengendalikan hal-hal penting yang berhubungan dengan TA Anda?
3	Dalam sebulan terakhir, seberapa sering Anda merasa gugup atau stress saat memikirkan TA?
4	Dalam sebulan terakhir, seberapa sering Anda merasa percaya diri dapat menyelesaikan tugas-tugas TA Anda?
5	Dalam sebulan terakhir, seberapa sering Anda merasa perkembangan TA Anda berjalan sesuai rencana?
6	Dalam sebulan terakhir, seberapa sering Anda merasa tugas TA yang harus dikerjakan terlalu banyak dan sulit Anda atasi?
7	Dalam sebulan terakhir, seberapa sering Anda merasa bisa mengendalikan rasa jengkel atau frustrasi selama mengerjakan TA?
8	Dalam sebulan terakhir, seberapa sering Anda merasa berada dalam kondisi yang cukup baik atau terkontrol saat mengerjakan TA?
9	Dalam sebulan terakhir, seberapa sering Anda merasa marah karena ada hal terkait TA yang berada di luar kendali Anda?
10	Dalam sebulan terakhir, seberapa sering Anda merasa beban TA menumpuk dan membuat Anda kewalahan?

Penelitian ini melibatkan mahasiswa tingkat akhir di STMIK Palangkaraya dari program studi Teknik Informatika, Sistem Informasi, dan Manajemen Informatika. Dari total 200 mahasiswa, sebanyak 65 responden berpartisipasi. Mayoritas responden berada pada semester akhir, sesuai dengan kriteria penelitian, sebagaimana ditunjukkan pada Gambar 2 dan Gambar 3.



Gambar 2. Responden kuesioner

Timestamp	Nama	Program Studi	Semester	Usia	Jenis Kelamin	Dalam sebulan terakhir, seberapa sering Anda merasa kesal karena ada masalah TA yang muncul tiba-tiba?	Dalam sebulan terakhir, seberapa sering Anda merasa tidak bisa mengendalikan hal-hal penting yang berhubungan dengan TA?	Dalam sebulan terakhir, seberapa sering Anda merasa gugup atau stres saat memikirkan TA?	Dalam sebulan terakhir, seberapa sering Anda merasa percaya diri bisa menyelesaikan tugas-tugas TA?	Dalam sebulan terakhir, seberapa sering Anda merasa perkebangan TA Anda berjalan sesuai rencana?	Dalam sebulan terakhir, seberapa sering Anda merasa tugas TA yang harus dikerjakan terlalu banyak dan sulit Anda atasi?	Dalam sebulan terakhir, seberapa sering Anda merasa bisa mengendalikan rasa jengkel atau frustrasi selama mengerjakan TA?	Dalam sebulan terakhir, seberapa sering Anda merasa berada dalam kondisi/kontrol yang cukup baik saat mengerjakan TA?	Dalam sebulan terakhir, seberapa sering Anda merasa marah karena ada hal terkait TA yang berada di luar kendali Anda?	Dalam sebulan terakhir, seberapa sering Anda merasa beban TA menumpuk dan membuat Anda kewalahan?
11/15/2025 10:4	Mega	Teknik Infor	7	23	Perempuan	Cukup sering	Hampir tidak per	Kadang-kadang	Kadang-kadang	Kadang-kadang	Kadang-kadang	Cukup sering	Hampir tidak per	Hampir tidak per	
11/15/2025 14:0	Ryan A	Teknik Infor	7	23	Laki-laki	Cukup sering	Kadang-kadang	Kadang-kadang	Sangat sering	Sangat sering	Cukup sering	Kadang-kadang	Kadang-kadang	Cukup sering	
11/18/2025 10:1	Melinda	Teknik Infor	7	20	Perempuan	Tidak pernah	Tidak pernah	Cukup sering	Kadang-kadang	Cukup sering	Kadang-kadang	Tidak pernah	Tidak pernah	Cukup sering	
11/18/2025 10:1	Fernan	Teknik Infor	7	21	Laki-laki	Cukup sering	Kadang-kadang	Hampir tidak per	Sangat sering	Cukup sering	Sangat sering	Hampir tidak per	Hampir tidak per	Sangat sering	
11/18/2025 10:1	Angella	Teknik Infor	7	21	Perempuan	Kadang-kadang	Kadang-kadang	Sangat sering	Kadang-kadang	Kadang-kadang	Cukup sering	Kadang-kadang	Kadang-kadang	Cukup sering	
11/18/2025 10:2	Andraw	Teknik Infor	7	20	Laki-laki	Sangat sering	Cukup sering	Cukup sering	Sangat sering	Kadang-kadang	Cukup sering	Cukup sering	Kadang-kadang	Sangat sering	
11/18/2025 10:2	Siaka T	Teknik Infor	7	21	Perempuan	Cukup sering	Kadang-kadang	Sangat sering	Cukup sering	Kadang-kadang	Kadang-kadang	Kadang-kadang	Kadang-kadang	Cukup sering	
11/18/2025 10:2	CERLA	Teknik Infor	7	21	Perempuan	Cukup sering	Cukup sering	Kadang-kadang	Kadang-kadang	Kadang-kadang	Kadang-kadang	Kadang-kadang	Kadang-kadang	Cukup sering	
11/18/2025 10:2	Esiska	Teknik Infor	7	22	Perempuan	Cukup sering	Kadang-kadang	Cukup sering	Kadang-kadang	Kadang-kadang	Cukup sering	Kadang-kadang	Kadang-kadang	Cukup sering	
11/18/2025 10:3	NORAIL	Teknik Infor	7	23	Perempuan	Kadang-kadang	Cukup sering	Cukup sering	Cukup sering	Kadang-kadang	Hampir tidak per	Kadang-kadang	Kadang-kadang	Hampir tidak per	
11/18/2025 10:3	Rifad A	Teknik Infor	7	22	Laki-laki	Cukup sering	Hampir tidak per	Hampir tidak per	Sangat sering	Kadang-kadang	Kadang-kadang	Hampir tidak per	Kadang-kadang	Hampir tidak per	
11/18/2025 11:0	Glenn Pt	Teknik Infor	7	21	Laki-laki	Sangat sering	Sangat sering	Sangat sering	Hampir tidak per	Hampir tidak per	Sangat sering	Hampir tidak per	Hampir tidak per	Sangat sering	

Gambar 3. Data hasil kuesioner

### 3.3 Pre-processing

Data yang terkumpul selanjutnya melalui tahap *pre-processing*. *Data cleaning* dilakukan dengan menyaring responden semester 5 ke atas sehingga diperoleh 63 data valid. Kolom yang tidak relevan dihapus dan item pertanyaan diubah menjadi PSS1 hingga PSS10 sebagai fitur utama. Nilai respons dikonversi ke numerik (0–4), dari “tidak pernah” hingga “sangat sering”. Selanjutnya dilakukan *reverse scoring* pada PSS4, PSS5, PSS7, dan PSS8 sesuai pedoman PSS-10, dengan perbandingan hasil ditunjukkan pada Gambar 4.


TABEL 2A: PSS1-PSS10 SEBELUM Reverse Scoring (5 baris teratas)									
pss1	pss2	pss3	pss4	pss5	pss6	pss7	pss8	pss9	pss10
3	1	2	2	2	2	2	3	1	1
3	2	2	4	4	3	2	2	2	3
0	0	3	2	3	2	0	0	3	2
3	2	1	4	3	4	1	1	4	4
2	2	4	2	2	3	2	2	2	3

TABEL 2B: PSS1-PSS10 SUDAH Reverse Scoring (5 baris teratas)									
pss1	pss2	pss3	pss4	pss5	pss6	pss7	pss8	pss9	pss10
3	1	2	2	2	2	2	1	1	1
3	2	2	0	0	3	2	2	2	3
0	0	3	2	1	2	4	4	3	2
3	2	1	0	1	4	3	3	4	4
2	2	4	2	2	3	2	2	2	3

Gambar 4. Reverse scoring

Setelah proses *reverse scoring*, total skor stres dihitung dengan menjumlahkan PSS1–PSS10 sehingga diperoleh rentang nilai 0–40. Skor tersebut dikategorikan menjadi tiga tingkat, yaitu rendah (0 – 13), sedang (14 – 26), dan tinggi (27 – 40). Label kategori kemudian dikonversi ke bentuk numerik (0 = rendah, 1 = sedang, 2 = tinggi) untuk mendukung analisis statistik dan pemodelan *machine learning*. Hasil pelabelan dan distribusi data ditunjukkan pada Gambar 5, yang memperlihatkan adanya ketidakseimbangan kelas sebagai dasar pertimbangan dalam pemilihan metode dan evaluasi model.



Gambar 5. Distribusi kelas tingkat stres

### 3.4 Model Training

Pada tahap pemodelan, dataset hasil *preprocessing* dimuat dari file Excel yang berisi 10 fitur PSS (PSS1–PSS10) dan satu label kelas. Sebelum digunakan, dilakukan validasi untuk memastikan seluruh nilai berada pada rentang 0–4 serta tidak terdapat nilai kosong, sehingga data layak digunakan untuk pelatihan model. Dataset kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan teknik *stratified sampling* dengan *random\_state* 42, sehingga distribusi kelas tetap seimbang.

Model dibangun menggunakan *pipeline* yang mengintegrasikan *StandardScaler* dan SVM. Normalisasi dilakukan untuk menstandarisasi fitur, sekaligus mencegah *data leakage* karena proses scaling hanya dihitung dari data latih pada setiap iterasi validasi. SVM menggunakan *class\_weight = balanced* untuk mengatasi ketidakseimbangan kelas dan *probability = True* untuk mendukung estimasi probabilitas.

Model SVM dikembangkan menggunakan tiga jenis kernel, yaitu RBF, linear, polynomial dan sigmoid. Kernel RBF digunakan untuk menangkap pola non-linear yang kompleks, kernel linear sebagai pembanding sederhana, dan kernel polynomial untuk merepresentasikan hubungan non-linear yang dapat dikontrol melalui parameter derajat (*degree*). Optimasi *hyperparameter* dilakukan menggunakan *GridSearchCV* dengan skema *Repeated Stratified K-Fold Cross-Validation* (5 lipatan dan 3 pengulangan, *random\_state* = 42). Rincian parameter pengujian disajikan pada Tabel 3.

Tabel 3. Hyperparameter pengujian

Kernel	C	Gamma	Degree	Coef0
RBF	$10^{-2} - 10^3$	$10^{-4} - 10^1$	-	-
Linear	$10^{-3} - 10^3$	-	-	-
Polynomial	$10^{-2} - 10^2$	scale, auto	2 – 4	0.0, 0.5, 1.0
Sigmoid	$10^{-3} - 10^3$	scale, auto, $10^{-4} - 10^1$	-	0.0, 0.5, 1.0

Evaluasi model menggunakan *F1-score macro* selama proses validasi silang, karena mampu memberikan penilaian yang seimbang pada setiap kelas. Selain menentukan model terbaik, dilakukan analisis tambahan terhadap hasil *GridSearchCV* untuk membandingkan performa antar kernel dan menampilkan beberapa konfigurasi terbaik pada masing-masing kernel. Model terbaik kemudian diuji untuk mengukur kemampuan generalisasi, dengan confusion matrix, classification report, dan akurasi. Model akhir disimpan dalam format *.pkl* menggunakan *joblib* untuk keperluan implementasi lebih lanjut.

## 4. PEMBAHASAN

Optimasi model dilakukan menggunakan *GridSearchCV* dengan pendekatan *Repeated Stratified K-Fold* untuk memperoleh kombinasi hyperparameter terbaik pada setiap kernel SVM. Hasil optimasi tersebut menghasilkan konfigurasi parameter optimal yang berbeda untuk masing-masing kernel. Rincian hyperparameter terbaik disajikan pada Tabel 4.

Tabel 4. Hyperparameter terbaik setiap kernel SVM

Kernel	C	Gamma	Degree	Coef0	F1-macro CV
Polynomial	0,316	scale	3	1,0	0,8990
Linear	316,23	-	-	-	0,8706
RBF	1000,0	0,000811	-	-	0,8706
Sigmoid	316,23	0,01	-	0,0	0,8706

Berdasarkan konfigurasi hyperparameter terbaik tersebut, selanjutnya dilakukan evaluasi kinerja model menggunakan *cross-validation* untuk menilai performa dan stabilitas masing-masing kernel. Ringkasan hasil evaluasi disajikan pada Tabel 5.

Tabel 5. Ringkasan kinerja model SVM (Cross-Validation)

Kernel	Jumlah Model	F1-macro Terbaik	F1-macro Rata-rata	Std. Deviasi
Polynomial	162	0,8990	0,6566	0,1882
Linear	13	0,8706	0,7374	0,2364
RBF	144	0,8706	0,4472	0,2659
Sigmoid	312	0,8706	0,4231	0,2292

Berdasarkan Tabel 5, *polynomial* menunjukkan performa terbaik dengan F1-macro tertinggi sebesar 0,8990 serta tingkat stabilitas yang relatif baik dengan standar deviasi 0,1882. Hal ini mengindikasikan bahwa pola hubungan antar item PSS dan tingkat stres bersifat non-linear dengan kompleksitas moderat.

Kernel *linear* memiliki nilai rata-rata F1-macro tertinggi, yaitu 0,7374, namun disertai variasi performa yang cukup besar antar lipatan. Kondisi ini menunjukkan bahwa meskipun sebagian pola dalam data bersifat linear, struktur keseluruhan data tidak sepenuhnya dapat direpresentasikan secara linear. Sementara itu, kernel *RBF* dan *sigmoid* mencapai nilai F1-macro maksimum yang sama, yaitu 0,8706, namun memiliki rata-rata performa yang lebih rendah serta deviasi yang relatif tinggi. Hal ini menunjukkan bahwa kedua kernel tersebut cenderung sensitif terhadap kombinasi hyperparameter dan berpotensi mengalami *overfitting* pada data tertentu. Secara keseluruhan, kernel *polynomial* dipilih sebagai model terbaik karena mampu memberikan keseimbangan antara akurasi dan stabilitas dalam proses klasifikasi tingkat stres.


#### 4.1 Evaluasi Model

Setelah melalui proses *cross-validation*, SVM dengan kernel *polynomial* dipilih sebagai model terbaik dan selanjutnya diuji menggunakan data uji yang sepenuhnya terpisah dari pelatihan maupun optimasi hyperparameter. Tahap ini bertujuan untuk mengukur kemampuan generalisasi model terhadap data baru.

Tabel 6. Evaluasi data uji

Kelas	Precision	Recall	F1-score	Support
0	1.0000	1.0000	1.0000	2
1	1.0000	0.8889	0.9412	9
2	0.6667	1.0000	0.8000	2
Macro Avg	0.8889	0.9630	0.9137	13
Weighted Avg	0.9487	0.9231	0.9285	13

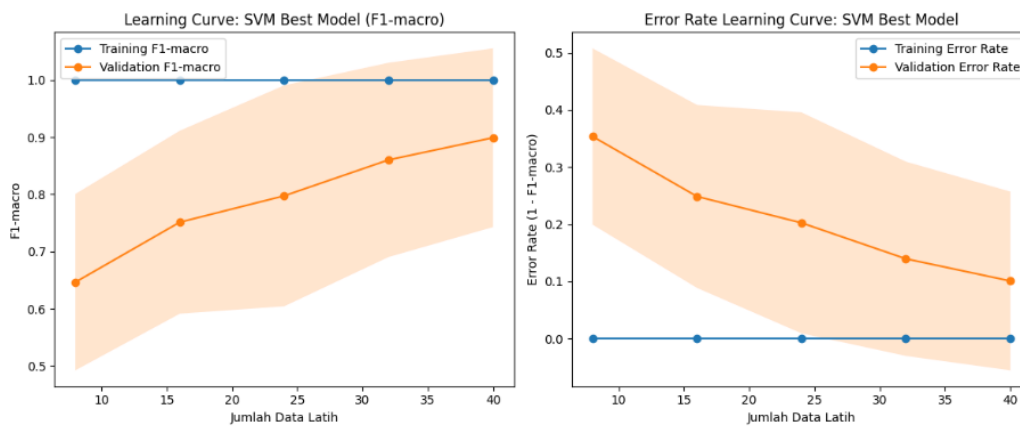
Nilai F1-macro sebesar 0,9137 pada data uji menunjukkan bahwa model memiliki performa yang stabil dan tidak bergantung pada dominasi kelas tertentu. Akurasi keseluruhan model pada data uji mencapai 92,31%, yang menunjukkan tingkat ketepatan prediksi yang tinggi. Distribusi kesalahan klasifikasi secara rinci ditunjukkan pada Gambar 6, yang memperlihatkan bahwa hanya satu sampel dari kelas 1 yang salah diklasifikasikan, sementara seluruh sampel pada kelas 0 dan kelas 2 berhasil diklasifikasikan dengan benar.



Gambar 6. Confusion matrix SVM (*pure PSS*)

Pada Gambar 7 yang menampilkan *Learning Curve* dan *Error Rate Learning Curve* dari model SVM terbaik, terlihat bahwa peningkatan jumlah data latih memberikan dampak yang signifikan terhadap stabilitas dan kemampuan generalisasi model. Nilai F1-score macro pada data pelatihan berada pada kisaran yang sangat tinggi (mendekati 1) sejak jumlah data yang relatif kecil, yang mengindikasikan bahwa model memiliki kapasitas yang kuat dalam mempelajari pola pada data latih. Namun, yang lebih penting adalah tren pada data validasi yang menunjukkan peningkatan bertahap seiring bertambahnya data.

Kesenjangan awal antara kurva pelatihan dan validasi mengindikasikan adanya kecenderungan *overfitting ringan* pada jumlah data kecil. Akan tetapi, seiring bertambahnya data latih, gap tersebut semakin menyempit, yang menunjukkan bahwa model mulai mencapai kondisi yang lebih seimbang (*bias-variance trade-off* yang optimal). Hal ini diperkuat oleh kurva error rate, di mana error pada data validasi menurun secara konsisten, sementara error pelatihan tetap mendekati nol. Pola ini menunjukkan bahwa model tidak hanya menghafal data latih, tetapi benar-benar belajar pola yang dapat digeneralisasikan. Dengan demikian, dapat disimpulkan bahwa performa model masih berpotensi meningkat apabila jumlah data ditambah, karena kurva validasi belum sepenuhnya konvergen.



Gambar 7. Learning curve & error rate learning curve

#### 4.2 Perbandingan Metode *Machine Learning*

Untuk mengevaluasi keunggulan model, dilakukan perbandingan dengan beberapa algoritma lain. Ringkasan hasil perbandingan disajikan pada Tabel 7.

Tabel 7. Perbandingan kinerja model

Model	F1-macro CV	F1-macro Test	Akurasi Test	Catatan
SVM Polynomial	0,8990	0,9137	92,31%	Stabil, generalisasi baik
KNN	0,6411	0,8713	92,31%	Lemah di kelas minoritas
Decision Tree	0,7030	0,7556	76,92%	Cenderung overfitting
Random Forest	0,5921	1,0000	100,00%	Overfitting (gap CV–test besar)
Naive Bayes	0,5579	0,7078	76,92%	Asumsi tidak terpenuhi

Berdasarkan Tabel 7, model SVM dengan kernel *polynomial* menunjukkan performa paling seimbang antara nilai *cross-validation* dan data uji. Meskipun *Random Forest* menghasilkan akurasi sempurna pada data uji, nilai F1-macro *cross-validation* yang rendah menunjukkan adanya *overfitting*. Sementara itu, KNN memiliki performa cukup baik namun kurang stabil pada kelas minoritas. *Decision Tree* dan *Naive Bayes* menunjukkan performa yang lebih rendah, sehingga kurang optimal untuk kasus ini. Secara keseluruhan, SVM dengan kernel *polynomial* dipilih sebagai model terbaik karena mampu memberikan keseimbangan antara akurasi, stabilitas, dan kemampuan generalisasi dalam klasifikasi tingkat stres.

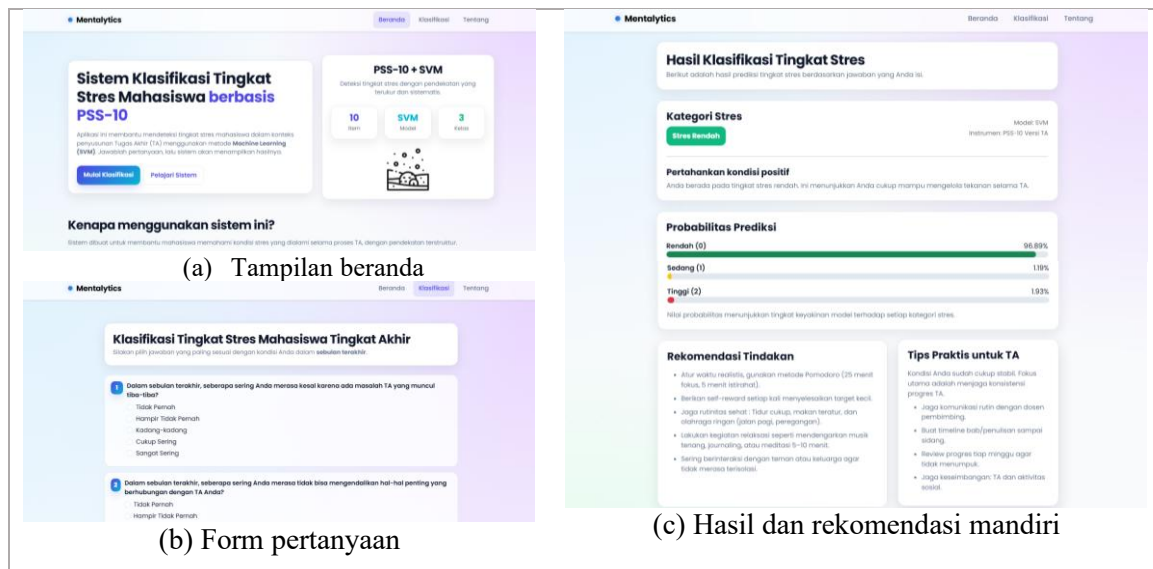
#### 4.3 Sistem Klasifikasi

Sebagai implementasi hasil penelitian, model klasifikasi yang telah dilatih diintegrasikan ke dalam sistem berbasis web untuk menunjukkan penerapan praktis serta memfasilitasi interaksi pengguna.

Sistem ini dikembangkan menggunakan teknologi *frontend* HTML, CSS, dan JavaScript, serta *backend* Python dengan *framework* Flask, yang terhubung dengan model *machine learning* hasil pelatihan. Seluruh tampilan sistem mulai dari halaman beranda, *form* pengisian PSS-10, hingga halaman hasil klasifikasi ditampilkan dalam satu visualisasi terpadu pada Gambar 11. Antarmuka hasil klasifikasi menyajikan label prediksi tingkat stres, nilai *confidence score*, serta rekomendasi penanganan mandiri.

Penyajian informasi yang ringkas dan informatif dirancang agar pengguna dapat memahami kondisi psikologisnya secara cepat dan intuitif. *Confidence score* memberikan konteks terkait tingkat keyakinan model terhadap hasil prediksi, sehingga meningkatkan transparansi sistem. Rekomendasi yang diberikan bersifat preventif dan edukatif, bukan sebagai pengganti diagnosis profesional, melainkan sebagai instrumen deteksi dini untuk meningkatkan kesadaran kesehatan mental.

Selain itu, dilakukan evaluasi usability secara sederhana melalui aspek kemudahan penggunaan (*ease of use*), kejelasan informasi (*clarity*), dan tampilan antarmuka (*user interface*). Hasil evaluasi menunjukkan bahwa sistem mudah digunakan oleh pengguna umum, dengan alur interaksi yang jelas mulai dari pengisian kuesioner hingga memperoleh hasil. Tampilan yang minimalis dan responsif juga mendukung pengalaman pengguna yang lebih baik. Secara keseluruhan, sistem ini berfungsi sebagai media demonstrasi dan validasi fungsional model *machine learning*, sekaligus menunjukkan potensi penerapannya sebagai alat bantu awal dalam pengukuran tingkat stres mahasiswa.



Gambar 11. Tampilan antarmuka sistem klasifikasi

## 5. KESIMPULAN

Berdasarkan rangkaian penelitian yang telah dilaksanakan, dapat disimpulkan bahwa pengembangan sistem klasifikasi tingkat stres bagi mahasiswa tingkat akhir berbasis web dengan algoritma SVM telah berhasil diimplementasikan dengan performa yang sangat baik. Penggunaan instrumen PSS-10 terbukti mampu menghasilkan data yang valid dan terstruktur untuk mengategorikan tingkat stres ke dalam kelas rendah, sedang, dan tinggi. Secara teknis, SVM dengan kernel polynomial menjadi model terbaik dengan akurasi 92,31% dan F1-score macro 0,914, menunjukkan kemampuan generalisasi yang baik serta ketahanan terhadap ketidakseimbangan data. Dari sisi implementasi, sistem berbasis web memudahkan mahasiswa melakukan deteksi stres secara mandiri, cepat, dan efisien. Sistem ini berpotensi sebagai alat deteksi dini untuk mendukung pencegahan dan pengelolaan stres akademik. Namun, penelitian ini masih terbatas pada jumlah dan variasi data. Penelitian selanjutnya disarankan memperluas dataset, mencoba metode lain atau ensemble, serta menambahkan fitur seperti rekomendasi penanganan stres dan integrasi dengan layanan konseling.

---

## DAFTAR PUSTAKA

- [1] E. Sitepu, J. Tampubolon, S. Manulang, and S. N. Amalia, "Analisis faktor-faktor yang berhubungan dengan kejadian stres pada mahasiswa tingkat akhir S1 Matematika di Universitas Negeri Medan," *Statistika*, vol. 24, no. 1, pp. 93–101, 2024, doi: 10.29313/Statistika.V24i1.3257.
- [2] I. A. Nurcholis, W. Safitri, and F. Alfiani, "Academic stress scale on final year English students when writing thesis during pandemic COVID-19 at Universitas Muhammadiyah Bengkulu," *J. Eduscience*, vol. 10, no. 1, pp. 75–86, Apr. 2023, doi: 10.36987/Jes.V10i1.3940.
- [3] W. R. Silviani, H. Hastuti, and W. N. Fida, "Hubungan komunikasi interpersonal dosen pembimbing mahasiswa terhadap tekanan psikologis dalam menyusun skripsi," *J. Ilm. Komun. Jikom Stikom Ima*, vol. 15, no. 01, p. 40, Mar. 2023, doi: 10.38041/Jikom1.V15i01.243.
- [4] E. M. Ladapase and A. Sona, "Gambaran stres akademik pada mahasiswa Universitas Nusa Nipa Indonesia di Maumere," *Empower. J. Mhs. Psikol. Univ. Buana Perjuangan Karawang*, vol. 2, no. 2, pp. 42–47, Jan. 2023, doi: 10.36805/Empowerment.V2i2.664.
- [5] M. Widyaningsih, R. Rosmiati, and P. I. Prakoso, "Predicting anxiety of STMIK Palangkaraya students using K-means clustering and Gaussian naïve Bayes," *J. Tek. Inform. Jutif*, vol. 7, no. 1, pp. 169–184, Feb. 2026, doi: 10.52436/1.Jutif.2026.7.1.5259.
- [6] P. Jayadurga and P. Aruna, "Analyzing the impact of sleep trait in the detection and prediction of stress through machine learning," *Ymer Digit.*, Vol. 21, No. 07, Pp. 382–400, Jul. 2022, Doi: 10.37896/Ymer21.07/30.
- [7] R. V. Anand, A. Q. Md, S. Urooj, S. Mohan, M. A. Alawad, and A. C., "Enhancing diagnostic decision-making: Ensemble learning techniques for reliable stress level classification," *Diagnostics*, vol. 13, no. 22, p. 3455, Nov. 2023, doi: 10.3390/Diagnostics13223455.
- [8] N. A. M. Samsudin, S. M. Shaharudin, N. A. F. Sulaiman, M. F. M. Fuad, M. F. Zulfikri, and N. H. Zainuddin, "Modeling student's academic performance during COVID-19 based on classification in support vector machine," *Turk. J. Comput. Math. Educ. Turcomat*, vol. 12, no. 5, pp. 1798–1804, Apr. 2021, doi: 10.17762/Turcomat.V12i5.2190.
- [9] A. Asram, S. Riskiyani, and R. M. Thaha, "Validity and reliability of the Indonesian version of the perceived stress scale (PSS) and self-reporting questionnaire (SRQ) questionnaire: study of stress levels and mental health conditions in master students of the faculty of public health," *Int. J. Chem. Biochem. Sci.*, vol. 25, no. 19, Jul. 2024, doi: 10.62877/84-Ijcbbs-24-25-19-84.
- [10] P. O. Garriott and S. Nisle, "Stress, coping, and perceived academic goal progress in first-generation college students: the role of institutional supports.," *J. Divers. High. Educ.*, vol. 11, no. 4, pp. 436–450, Dec. 2018, doi: 10.1037/Dhe0000068.
- [11] S. Cohen, T. Kamarck, and R. Mermelstein, "A global measure of perceived stress," *J. Health Soc. Behav.*, Vol. 24, No. 4, Pp. 385–396, 1983, Doi: 10.2307/2136404.
- [12] A. H. Suasapha, "Skala likert untuk penelitian pariwisata; beberapa catatan untuk menyusunnnya dengan baik," *J. Kepariwisataaan*, vol. 19, no. 1, pp. 26–37, Mar. 2020, doi: 10.52352/Jpar.V19i1.407.
- [13] N. M. T. O. Adriana, I. M. A. D. Suarjaya, and D. P. Githa, "Analisis sentimen publik terhadap aksi demonstrasi di Indonesia menggunakan support vector machine dan random forest," *Decode J. Pendidik. Teknol. Inf.*, vol. 3, no. 2, pp. 257–267, Jun. 2023, doi: 10.51454/Decode.V3i2.187.
- [14] H. D. Kartika, G. E. Hayatulah, and A. Khumaidi, "Comparison of kernel support vector machine in predicting judges' decisions at the Bekasi district court," *J. Ilm. Merpati Menara Penelit. Akad. Teknol. Inf.*, vol. 10, no. 3, p. 145, Dec. 2022, doi: 10.24843/Jim.2022.V10.I03.P03.
- [15] I. S. Al-Mejibli, J. K. Alwan, and D. H. Abd, "The effect of gamma value on support vector machine performance with different kernels," *Int. J. Electr. Comput. Eng. Ijece*, vol. 10, no. 5, p. 5497, Oct. 2020, doi: 10.11591/Ijece.V10i5.Pp5497-5506.

### **Biodata Penulis**

**Megawati**, penulis merupakan mahasiswa aktif Program Studi Teknik Informatika di STMIK Palangkaraya. Saat ini sedang menempuh semester akhir dan mendalami bidang Sistem Cerdas dengan minat penelitian pada machine learning dan pengolahan data.

**Dr. Maura Widyaningsih, S.Kom., M.Cs.**, penulis merupakan Dosen STMIK Palangkaraya Prodi Teknik Informatika. S1 (2000) lulusan Universitas Dian Nuswantoro, Semarang, Indonesia. S2 (2014) dan S3 (2024) dari Prodi Ilmu Komputer, Fakultas MIPA, Universitas Gadjah Mada, Yogyakarta, Indonesia. Bidang keilmuan adalah di *Artificial Intelligence* dan *Image Processing*. Fokus pengembangan Kehutanan, Agriculture, Pangan dan Psikologi.

**Ir. Abdul Hadi, S.T., M.Kom**, penulis merupakan Dosen STMIK Palangkaraya pada Program Studi Teknik Informatika. Pendidikan Sarjana (S1) ditempuh pada Program Studi Teknik Informatika, Universitas Ahmad Dahlan (UAD), Yogyakarta, Indonesia, dan lulus pada tahun 2011. Pendidikan Magister (S2) diselesaikan pada Program Magister Teknik Informatika, Universitas Ahmad Dahlan (UAD), Yogyakarta, Indonesia, pada tahun 2021. Gelar Profesi Insinyur (Ir.) diperoleh pada tahun 2024. Bidang keilmuan yang ditekuni meliputi Network Computing, Cloud Computing, Network Security, dan Digital Forensics, dengan fokus pada pengembangan infrastruktur jaringan, keamanan sistem, serta forensik digital.

**Dr. Esty Aryani Safithry, M.Psi., Psikolog**, penulis merupakan Dosen pada Fakultas Psikologi Universitas Muhammadiyah Palangkaraya. Penulis menyelesaikan pendidikan Sarjana (S1) di Fakultas Psikologi Universitas Muhammadiyah Malang, kemudian melanjutkan studi Magister dan Program Profesi Psikologi (S2 Profesi Psikolog) di Universitas Muhammadiyah Malang. Saat ini, penulis telah menyelesaikan pendidikan Doktor (S3) pada Program Studi Psikologi Pendidikan di Universitas Negeri Malang. Bidang keilmuan yang menjadi fokus pengembangan akademik dan penelitian meliputi Psikologi Klinis dan Psikologi Pendidikan, dengan minat khusus pada intervensi berbasis kognitif-perilaku, penguatan ketahanan individu dan keluarga, serta pengembangan pendekatan psikologi yang terintegrasi dengan nilai-nilai kearifan lokal. Selain aktif dalam kegiatan pengajaran, penulis juga terlibat dalam penelitian, pengabdian kepada masyarakat, serta praktik profesional sebagai psikolog.

---