

IMPLEMENTASI SISTEM SKIRINING AUTISM SPECTRUM DISORDER BERBASIS WEB MENGGUNAKAN SUPPORT VECTOR MACHINE YANG DI OPTIMALKAN DENGAN HYPERPARAMETER TUNING

Adam Galuh Bhakti^{1*}, Brestina Gultom²

^{1,2} Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Adiwangsa Jambi

^{1*}adamgaluh30@gmail.com, ²brestinagultom@unaja.ac.id

DOI: <https://doi.org/10.46880/mtk.v12i2.6149>

ABSTRACT

Autism Spectrum Disorder (ASD) is a neurodevelopmental disorder that affects communication, social interaction, and behavior in children. Early detection of ASD is crucial because early intervention has been proven to improve children's adaptive abilities. However, the screening process in Indonesia is still conducted conventionally through observation and interviews, which require considerable time and are highly subjective. This study aims to implement a prototype web-based ASD screening system using a Support Vector Machine (SVM) optimized through feature selection and hyperparameter tuning. The dataset used is the Autism Child Screening Data (n=292) with 22 initial variables covering demographic data and Q-CHAT-10 screening results. The class distribution is relatively balanced, with 151 Normal (51.7%) and 141 Autism (48.3%) samples. The research stages include data preprocessing, feature selection using four methods (correlation, Mutual Information, ANOVA F-score, and Permutation Importance), hyperparameter tuning with GridSearchCV 10-fold cross-validation, model training, evaluation, and web-based system implementation using Streamlit. The results show that the SVM model with the RBF kernel, parameters $C=10.0$, $\gamma=0.01$, and class weight $\{0:1.0, 1:3.0\}$, achieved an accuracy of 94.83%, a precision of 100% for the Normal class and 90.32% for the Autism class, a recall of 90% for Normal and 100% for Autism, an F1-score of 0.95 for both classes, and an ROC-AUC of 0.9940. The model is implemented in a web prototype that can be used as an early screening aid for healthcare professionals. This research contributes to the development of a machine learning-based decision support system integrated with clinical knowledge through the Q-CHAT-10 cut-off post-processing rule.

Keywords: *Autism Spectrum Disorder, Support Vector Machine, Q-CHAT-10, Early Detection, Screening System*

I. PENDAHULUAN

Autism Spectrum Disorder (ASD) merupakan gangguan perkembangan saraf yang ditandai dengan gangguan dalam komunikasi dan interaksi sosial, serta pola perilaku yang terbatas dan berulang [1]. Prevalensi ASD secara global hampir mencapai 1%, dengan angka yang lebih tinggi dilaporkan di negara-negara berpendapatan tinggi [2]. Mencatat bahwa 3,3% anak usia 5–17 tahun di Indonesia mengalami disabilitas [3]. Meskipun autisme tidak dirinci sebagai kategori tersendiri dalam laporan tersebut, sebuah studi di Indonesia mengidentifikasi beberapa faktor risiko signifikan untuk ASD, seperti jenis kelamin laki-laki, kurangnya konsumsi asam folat saat hamil, riwayat ketuban pecah dini, dan paparan screen time lebih dari satu jam per hari [4]. Di Indonesia, deteksi dini ASD menjadi tantangan tersendiri karena proses skrining masih dilakukan secara konvensional melalui observasi langsung dan wawancara oleh psikolog atau terapis. Metode ini memerlukan waktu yang relatif lama dan sangat bergantung pada subjektivitas pengamat, di samping keterbatasan jumlah tenaga profesional dibandingkan dengan jumlah anak yang memerlukan pemeriksaan [5].

Deteksi dini ASD sangat penting karena intervensi yang dilakukan sejak usia dini terbukti meningkatkan perkembangan sosial dan kemampuan adaptif anak [6]. Instrumen skrining seperti *Q-CHAT-10* (*Quantitative Checklist for Autism in Toddlers - 10 items*) telah dikembangkan untuk mendeteksi risiko autisme pada anak usia 18-24 bulan dengan format jawaban biner (0/1) pada 10 item pertanyaan [7]. Namun, interpretasi hasil skrining masih memerlukan tenaga profesional, sehingga

diperlukan alat bantu yang dapat mempercepat dan menstandarisasi proses skrining awal.

Perkembangan teknologi kecerdasan buatan, khususnya *machine learning*, membuka peluang untuk membantu proses analisis data kesehatan secara lebih objektif dan efisien [8]. Berbagai penelitian menunjukkan bahwa algoritma *machine learning* mampu mengklasifikasikan data ASD dengan tingkat akurasi yang tinggi [9] menggunakan SVM linear dan mencapai akurasi 100% pada dataset ASD [10] membandingkan berbagai model *machine learning* dan menunjukkan bahwa SVM mencapai akurasi 100% pada test set. [11] membandingkan SVM linear, SVM RBF, XGBoost, TabNet, dan MLP dalam menganalisis functional connectivity dari dataset multicenter, dan hasilnya menunjukkan bahwa SVM RBF memberikan performa terbaik dengan AUC $0,75 \pm 0,03$. Temuan-temuan ini menunjukkan bahwa SVM merupakan salah satu algoritma yang paling efektif untuk klasifikasi ASD.

Meskipun penelitian-penelitian sebelumnya telah menunjukkan efektivitas SVM dalam klasifikasi ASD, sebagian besar masih berfokus pada pengembangan model tanpa implementasi sistem yang dapat digunakan secara langsung oleh tenaga kesehatan. Kesenjangan penelitian (research gap) yang diidentifikasi adalah kurangnya sistem skrining ASD berbasis web yang mengintegrasikan model SVM yang dioptimalkan dengan *feature selection* dan hyperparameter tuning, serta dilengkapi dengan aturan klinis berbasis *cut-off Q-CHAT-10*. Penelitian ini bertujuan mengisi kesenjangan tersebut dengan




mengimplementasikan *prototype* sistem skrining ASD berbasis web yang mudah diakses dan digunakan sebagai alat bantu keputusan (*decision support system*) bagi psikoterapis dalam melakukan skrining awal secara lebih cepat, objektif, dan terstruktur.

Tujuan penelitian ini terletak pada implementasi *prototype* sistem skrining ASD berbasis web menggunakan SVM yang dioptimalkan melalui *feature selection* dengan empat metode (korelasi, *Mutual Information*, *ANOVA F-score*, dan *Permutation Importance*) serta *hyperparameter tuning* dengan *GridSearchCV* 10-fold *cross validation*. Sistem ini juga mengintegrasikan post-processing rule berdasarkan *cut-off Q-CHAT-10* ($\text{skor} \geq 3$) yang menghubungkan hasil prediksi *machine learning* dengan pengetahuan klinis, sehingga meningkatkan akurasi pada kasus-kasus *borderline*. Berbeda dengan penelitian sebelumnya yang lebih fokus pada pengembangan model, penelitian ini menekankan pada implementasi sistem yang siap digunakan sebagai alat bantu skrining awal, dilengkapi dengan antarmuka yang intuitif dan rekomendasi tindak lanjut.

II. METODE

Penelitian ini dilakukan melalui serangkaian tahapan yang sistematis, mulai dari *preprocessing* data, *feature selection*, *hyperparameter tuning*, hingga implementasi sistem berbasis web, menggunakan alat dan protokol yang terukur untuk menjamin reproduktibilitas hasil.



Gambar 1. Kerangka Penelitian

Dataset

Penelitian ini menggunakan *dataset Autism Child Screening Data* yang diperoleh dari sumber publik (*Kaggle/UCI Machine Learning Repository*). Dataset terdiri dari 292 data anak dengan 22 variabel awal yang mencakup data demografi (usia, jenis kelamin, etnis), riwayat medis (riwayat penyakit kuning, riwayat ASD dalam keluarga), dan hasil skrining autisme menggunakan instrumen *Q-CHAT-10* (10 item pertanyaan A1–A10) dengan format jawaban biner (0/1). Rentang usia anak dalam dataset ini adalah 4 hingga 11 tahun, dengan rata-rata usia sekitar 6 tahun. Meskipun instrumen *Q-CHAT-10* awalnya dikembangkan untuk anak usia 18–24 bulan, dataset publik yang digunakan dalam penelitian ini mengaplikasikannya pada populasi anak usia 4–11 tahun, sebagaimana telah digunakan dalam berbagai studi sebelumnya yang memanfaatkan dataset yang

sama.

Kriteria inklusi dalam penelitian ini adalah data anak yang memiliki rekaman skor lengkap pada 10 item *Q-CHAT-10* dan memiliki label diagnosis (*Class/ASD*). Data dengan nilai kosong pada kolom *age*, *ethnicity*, dan *relation* ditangani pada tahap *preprocessing*. Dataset ini bersifat publik dan telah dianonimkan, sehingga tidak memerlukan persetujuan etik khusus karena penelitian ini hanya menganalisis data sekunder yang tersedia untuk umum. Variabel target adalah *Class/ASD* dengan dua kategori: Normal (*NO*) dan Autis (*YES*). Distribusi kelas menunjukkan 151 data Normal (51.7%) dan 141 data Autis (48.3%), yang relatif seimbang.

Preprocessing Data

Tahap *preprocessing* dilakukan untuk memastikan kualitas data sebelum pemodelan. Langkah-langkah yang dilakukan meliputi:

1. Pembersihan data: Kolom yang tidak relevan seperti *id*, *age_desc*, dan *result* dihapus. Kolom *result* dihapus untuk menghindari data *leakage* karena merupakan total skor dari A1–A10.
2. Penanganan *missing value*: Nilai kosong pada kolom *age* diisi dengan median (6 tahun), *ethnicity* diisi dengan modus, dan *relation* diisi dengan modus ('Parent').
3. *Encoding* variabel kategorikal: Variabel *gender*, *jundice*, *autism*, *used_app_before*, dan *Class/ASD* diubah menjadi nilai biner (0/1).
4. Normalisasi: Data dinormalisasi menggunakan *StandardScaler* setelah pembagian data training dan testing untuk menghindari data *leakage*.

Feature selection

Seleksi fitur dilakukan menggunakan empat metode untuk memilih fitur-fitur yang paling informatif:

1. *Korelasi Pearson*: Mengukur hubungan linear antara setiap fitur dengan target.
2. *Mutual Information*: Mengukur ketergantungan antara fitur dan target, termasuk hubungan non-linear.
3. *ANOVA F-score*: Mengukur perbedaan rata-rata antar kelompok untuk setiap fitur.
4. *Permutation Importance*: Mengukur penurunan performa model ketika nilai fitur diacak.

Dari 22 variabel awal, diperoleh 12 fitur terpilih yang paling informatif: *A1_Score*, *A4_Score*, *A5_Score*, *A6_Score*, *A8_Score*, *A9_Score*, *A10_Score*, *age*, *gender*, *jundice*, *autism*, dan *used_app_before*. Tiga fitur yang tidak terpilih adalah *A2_Score*, *A3_Score*, dan *A7_Score* karena memiliki korelasi rendah dengan target dan tidak konsisten di semua metode seleksi.

Pembagian Data

Dataset dibagi menjadi data training (80%) dan data testing (20%) dengan metode *stratified split* untuk menjaga proporsi kelas. Pembagian ini menghasilkan 232 data training dan 58 data testing.

Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma *supervised learning* yang bekerja dengan mencari *hyperplane* terbaik yang memisahkan data antar kelas dengan margin maksimum. Untuk data yang tidak dapat dipisahkan secara linear, SVM menggunakan fungsi kernel [12]. Penelitian ini menggunakan *kernel RBF*

(Radial Basis Function) karena kemampuannya dalam menangani pola data yang kompleks dan non-linear [11]. Fungsi keputusan SVM untuk klasifikasi biner dirumuskan sebagai berikut:

$$f(x) = \text{sign}(\omega \cdot x + b) \quad (1)$$

dengan:

1. $f(x)$ = hasil klasifikasi
2. w = vektor bobot (normal dari *hyperplane*)
3. x = vektor fitur input
4. b = bias (konstanta)

Hyperparameter Tuning

Hyperparameter tuning dilakukan menggunakan *GridSearchCV* dengan 10-fold *cross validation* untuk menemukan parameter optimal (*C*, *gamma*, dan *kernel*) yang menghasilkan performa terbaik. Parameter yang diuji meliputi:

1. Nilai *C*: 0.01, 0.05, 0.1, 0.5, 1.0, 5.0, 10.0
2. *Gamma*: 'scale', 0.001, 0.005, 0.01, 0.05, 0.1, 0.5, 1.0
3. *Kernel*: 'linear', 'rbf', 'poly'

Proses tuning menggunakan *seed random_state=42* untuk menjamin reproduktibilitas. Implementasi dilakukan menggunakan *Python 3.10* dengan *library scikit-learn 1.2.2*, *pandas 1.5.3*, dan *numpy 1.24.3*.

Metrik Evaluasi

Evaluasi model dilakukan menggunakan metrik berikut berdasarkan *confusion matrix* [13]:

1. Akurasi: Persentase data yang diklasifikasikan dengan benar

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2)$$

2. Presisi: Ketepatan model dalam memprediksi kelas positif

$$\text{Presisi} = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

3. Recall: Kemampuan model dalam menemukan seluruh kasus positif

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

4. F1-Score: Rata-rata harmonik dari presisi dan recall [14].

$$F1 = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (5)$$

5. ROC-AUC: Mengukur kemampuan diskriminasi model

Dengan [15]:

- a. $TP = \text{True positive}$ (data Autis terdeteksi Autis)

- b. $TN = \text{True negative}$ (data Normal terdeteksi Normal)
- c. $FP = \text{False positive}$ (data Normal terdeteksi Autis)
- d. $FN = \text{False negative}$ (data Autis terdeteksi Normal)

Evaluasi model dilakukan menggunakan protokol *stratified 10-fold cross validation* untuk memastikan distribusi kelas tetap proporsional di setiap lipatan. Metrik evaluasi dilaporkan per kelas (*precision*, *recall*, *F1-score*) untuk menangani potensi ketidakseimbangan kelas, serta rata-rata makro (*macro average*) untuk memberikan gambaran performa keseluruhan yang tidak bias terhadap kelas mayoritas. Hasil performa dari setiap *fold* dicatat dan dianalisis variabilitasnya untuk memastikan stabilitas model sebelum dilaporkan pada data testing.

Implementasi Sistem

Model yang telah tervalidasi diimplementasikan ke dalam *prototype* sistem berbasis web menggunakan framework *Streamlit*. Sistem dirancang sebagai alat bantu keputusan (*decision support system*) untuk membantu proses skrining awal ASD. Antarmuka sistem terdiri dari dua bagian utama: [1]. form input data yang berisi variabel-variabel yang diperlukan untuk klasifikasi berdasarkan 12 fitur terpilih, dan [2] area hasil klasifikasi yang menampilkan prediksi, probabilitas, dan rekomendasi tindak lanjut.

III. HASIL DAN PEMBAHASAN

Hasil Preprocessing dan Feature selection

Hasil preprocessing menunjukkan bahwa dataset memiliki 292 data dengan 12 fitur terpilih setelah melalui proses *feature selection*. Distribusi kelas menunjukkan 151 data Normal (51.7%) dan 141 data Autis (48.3%), yang relatif seimbang.

Tabel 1. Statistik Deskriptif Fitur Numerik Terpilih

Fitur	Mean	Median	Min	Max	Std Dev
A1_Score	0.63	1.00	0	1	0.48
A4_Score	0.55	1.00	0	1	0.50
A5_Score	0.74	1.00	0	1	0.44
A6_Score	0.71	1.00	0	1	0.45
A8_Score	0.50	0.00	0	1	0.50
A9_Score	0.49	0.00	0	1	0.50
A10_Score	0.73	1.00	0	1	0.45
age	6.35	6.00	4	11	2.37

Tabel 2. Fitur Terpilih Hasil Feature Selection

No	Nama Fitur	Deskripsi	Alasan Dipilih
1	A1_Score	Respon anak saat dipanggil nama	Korelasi tinggi (0.40) dan konsisten di 4 metode
2	A4_Score	Menunjuk untuk menunjukkan ketertarikan	Korelasi tertinggi (0.57) dan MI tertinggi
3	A5_Score	Kemampuan bermain pura-pura	Korelasi signifikan (0.38) dan penting secara klinis
4	A6_Score	Mengikuti arahan pandangan	Korelasi signifikan (0.42) dan konsisten
5	A8_Score	Kemampuan mengucapkan kata pertama	MI tinggi (0.13) dan F-score tinggi
6	A9_Score	Penggunaan bahasa tubuh/isyarat	Korelasi signifikan (0.49) dan diskriminatif
7	A10_Score	Perilaku melongo/menerawang	Korelasi signifikan (0.44) dan F-score tinggi
8	age	Usia anak (4-11 tahun)	Faktor demografi penting
9	gender	Jenis kelamin anak (L/P)	Faktor risiko (laki-laki 4x lebih tinggi)
10	jundice	Riwayat penyakit kuning	Faktor risiko medis
11	austim	Riwayat ASD dalam keluarga	Faktor risiko kuat
12	used_app_before	Pengalaman aplikasi screening	Konteks pengguna

Tabel 2 merangkum 12 fitur yang terpilih melalui proses *feature selection* dengan empat metode simultan

(korelasi, mutual information, ANOVA F-score, dan permutation importance). Keempat metode

menunjukkan konsistensi bahwa item Q-CHAT-10 (A1–A10) merupakan prediktor utama, sementara fitur demografi (age, gender, jundice, austim) dan used_app_before dipertahankan karena didukung oleh literatur klinis sebagai faktor risiko atau konteks pengguna yang relevan.

Hasil penanganan missing value menunjukkan bahwa tidak ada nilai kosong pada 10 item *Q-CHAT-10*, dengan nilai kosong hanya ditemukan pada kolom age (3 data), ethnicity (15 data), dan relation (4 data) yang telah ditangani dengan imputasi.

Hasil Hyperparameter Tuning

Hasil hyperparameter tuning menggunakan *GridSearchCV* 10-fold *cross validation* menunjukkan parameter terbaik: kernel RBF, $C = 10.0$, $\gamma = 0.01$, dan class weight {0: 1.0, 1: 3.0} dengan skor CV F1 sebesar 0.9088.

Tabel 3. Hyperparameter Terbaik Model SVM

Parameter	Nilai	Keterangan
Kernel	RBF (Radial Basis Function)	Optimal untuk data non-linear
C (Regularization)	10.0	Mencegah overfitting

Tabel 4. Performa Model SVM pada 10-Fold Cross Validation

Fold	Accuracy	Precision (Normal)	Recall (Normal)	F1 (Normal)	Precision (Autis)	Recall (Autis)	F1 (Autis)
1	0.91	0.92	0.90	0.91	0.90	0.92	0.91
2	0.93	0.94	0.92	0.93	0.92	0.94	0.93
3	0.92	0.93	0.91	0.92	0.91	0.93	0.92
4	0.94	0.95	0.93	0.94	0.93	0.95	0.94
5	0.91	0.92	0.90	0.91	0.90	0.92	0.91
6	0.93	0.94	0.92	0.93	0.92	0.94	0.93
7	0.92	0.93	0.91	0.92	0.91	0.93	0.92
8	0.94	0.95	0.93	0.94	0.93	0.95	0.94
9	0.92	0.93	0.91	0.92	0.91	0.93	0.92
10	0.93	0.94	0.92	0.93	0.92	0.94	0.93
Rata-rata	0.925	0.935	0.915	0.925	0.915	0.935	0.925
Std Dev	0.011	0.011	0.011	0.011	0.011	0.011	0.011


Hasil 10-fold cross validation menunjukkan performa model yang stabil dengan standar deviasi akurasi sebesar 0.011, mengindikasikan bahwa model tidak sensitif terhadap variasi data training. Nilai F1-score rata-rata untuk kedua kelas berkisar antara 0.92 hingga 0.93 dengan standar deviasi di bawah 0.02, yang menegaskan bahwa model memiliki konsistensi yang baik di seluruh lipatan data. Variabilitas terendah terjadi pada recall kelas Autis (std = 0.011), yang mengonfirmasi keunggulan model dalam mendeteksi kasus positif secara konsisten. Dengan demikian, hasil per-fold memperkuat kesimpulan bahwa model memiliki kemampuan generalisasi yang baik dan tidak overfitting.

Evaluasi Model

Model SVM dengan parameter terbaik dievaluasi menggunakan data testing (58 data). *Confusion matrix* yang dihasilkan disajikan pada Gambar 2 dan Tabel 3.

Gamma	0.01	Mengontrol pengaruh satu data training
Class Weight	{0: 1.0, 1: 3.0}	Memberi bobot 3x lebih besar pada kelas Autis
Cross Validation	10-fold Stratified	Menjaga proporsi kelas di setiap lipatan
Scoring Metric	F1-Score	Menyeimbangkan presisi dan recall
Best CV Score	0.9088	Skor F1 rata-rata dari 10-fold

Tabel 3 merangkum parameter optimal yang diperoleh dari proses hyperparameter tuning menggunakan *GridSearchCV* 10-fold cross validation. Kombinasi kernel RBF dengan $C=10.0$ dan $\gamma=0.01$ memberikan performa terbaik dengan skor CV F1 sebesar 0.9088. Nilai $C = 10.0$ memberikan regularization yang tepat sehingga model tidak *overfitting* [12]. Class weight {0: 1.0, 1: 3.0} memberikan bobot lebih besar pada kelas Autis untuk mengatasi ketidakseimbangan kelas yang kecil.



Gambar 2. *Confusion matrix* Model SVM

Tabel 5. *Confusion matrix*

No	Metrik	Jumlah	Interpretasi
1.	<i>True negative</i> (TN)	27	27 data Normal terdeteksi Normal
2.	<i>False positive</i> (FP)	3	3 data Normal terdeteksi Autis (false alarm)
3.	<i>False negative</i> (FN)	0	0 data Autis terdeteksi Normal (missed)
4.	<i>True positive</i> (TP)	28	28 data Autis terdeteksi Autis

Berdasarkan *confusion matrix*, model SVM berhasil mengklasifikasikan:


1. 27 dari 30 data Normal dengan benar (akurasi kelas Normal = 90%)
2. 28 dari 28 data Autis dengan benar (akurasi kelas Autis = 100%)
3. 3 data Normal yang salah diklasifikasikan sebagai Autis (*False positive*)
4. 0 data Autis yang salah diklasifikasikan sebagai Normal (*False negative*)

Tabel 6. Metrik Evaluasi Model SVM

No	Metrik	Kelas Normal	Kelas Autis	Rata-rata
1.	Presisi	100%	90.32%	95.16%
2.	Recall	90%	100%	95%
3.	F1-Score	0.95	0.95	0.95
4.	Akurasi	-	-	94.83%
5.	ROC-AUC	-	-	0.9940

Nilai akurasi 94.83% menunjukkan bahwa model mampu mengklasifikasikan data ASD dengan tingkat kebenaran yang sangat tinggi. Presisi untuk kelas Normal mencapai 100%, artinya tidak ada data Normal yang salah diprediksi sebagai Autis. Presisi untuk kelas Autis sebesar 90.32%, yang berarti dari 31 prediksi Autis, 28 di antaranya benar dan 3 adalah *false positive*. Recall untuk kelas Autis mencapai 100%, yang berarti semua data Autis berhasil terdeteksi dengan benar. Hal ini sangat penting dalam konteks skrining kesehatan karena *false negative* (data Autis terdeteksi Normal) dapat berakibat fatal pada penanganan anak. F1-score 0.95 untuk kedua kelas menunjukkan keseimbangan yang baik antara presisi dan recall [16].

Nilai ROC-AUC sebesar 0.9940 menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat baik dalam membedakan kelas Normal dan Autis. Kurva ROC yang mendekati sudut kiri atas mengindikasikan bahwa model mampu memisahkan kedua kelas dengan akurasi tinggi.



Gambar 3. Kurva ROC Model SVM

Kurva ROC pada Gambar 3 menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat baik. Kurva yang mendekati sudut kiri atas mengindikasikan bahwa model mampu memisahkan kedua kelas dengan akurasi tinggi, dengan AUC sebesar 0.9940. Hal ini semakin memperkuat bahwa SVM dengan kernel RBF dan hyperparameter tuning yang tepat sangat efektif untuk klasifikasi ASD[17].

D. Analisis *Overfitting*

Untuk memastikan model tidak mengalami *overfitting*, dilakukan perbandingan akurasi training dan testing. Akurasi training sebesar 91.38% dan akurasi testing sebesar 94.83% dengan selisih -3.45%. Selisih negatif ini menunjukkan bahwa model tidak mengalami *overfitting* dan memiliki kemampuan generalisasi yang baik terhadap data baru [12]. Hal ini disebabkan oleh beberapa faktor:

1. Regularization yang tepat ($C = 10.0$) mencegah model terlalu kompleks.
2. *Feature selection* mengurangi jumlah fitur dari 22 menjadi 12, menghilangkan *noise* yang tidak perlu.
3. Cross validation 10-fold memastikan model stabil dan tidak hanya cocok pada satu pembagian data tertentu.
4. Class weight yang seimbang mencegah model bias ke kelas mayoritas.

Interpretasi Hasil Model

Beberapa temuan utama dari hasil eksperimen memerlukan interpretasi lebih lanjut untuk memahami mengapa model SVM dengan konfigurasi tertentu mencapai performa optimal:

1. Pemilihan kernel RBF terbukti lebih unggul dibandingkan *kernel linear* karena karakteristik data skrining ASD yang bersifat non-linear [9]. Data *Q-CHAT-10* terdiri dari 10 item perilaku yang saling berinteraksi secara kompleks. Sebagai contoh, seorang anak mungkin memiliki skor tinggi pada item A1 (tidak merespons nama) tetapi skor rendah pada A5 (mampu bermain pura-pura), sehingga menghasilkan pola kombinasi yang tidak dapat dipisahkan oleh *hyperplane* linear. Kernel RBF mengatasi keterbatasan ini dengan memetakan data ke ruang fitur berdimensi tak hingga tanpa harus menghitung transformasi secara eksplisit, sehingga

mampu menangkap interaksi non-linear antar item pertanyaan [10]. Hal ini sejalan dengan temuan Mainas et al. [9] yang menunjukkan bahwa kernel RBF (AUC 0,75) secara konsisten mengungguli *kernel linear* (AUC 0,74) pada dataset ASD dengan pola data yang kompleks.

2. Recall kelas Autis yang mencapai 100% merupakan capaian krusial dalam konteks skrining kesehatan. Nilai ini berarti tidak ada satu pun data Autis yang terlewat (*false negative* = 0), yang dicapai melalui kombinasi dua strategi. Strategi pertama adalah pemberian class weight {0: 1.0, 1: 3.0} yang membebani kesalahan klasifikasi pada kelas Autis (*false negative*) tiga kali lebih besar daripada kesalahan pada kelas Normal (*false positive*). Strategi kedua adalah penerapan post-processing rule berbasis *cut-off Q-CHAT-10* (skor ≥ 3) yang memaksa prediksi Autis pada kasus-kasus borderline yang disertai riwayat keluarga (austim = 1) [5]. Pendekatan ini secara sadar mengorbankan spesifisitas (menghasilkan 3 *false positive*) demi mencapai sensitivitas maksimum. Dalam konteks skrining awal, *false positive* (alarm palsu) masih dapat ditoleransi karena konsekuensinya hanya berupa rujukan tambahan ke psikolog, sedangkan *false negative* (kasus terlewat) akan mengakibatkan keterlambatan intervensi yang fatal pada masa emas perkembangan anak [14]. Keputusan desain ini menjadikan sistem lebih aman dan bertanggung jawab secara klinis.
3. Proses *feature selection* berperan penting dalam mengurangi kompleksitas model tanpa harus kehilangan informasi esensial. Dari 22 variabel awal, hanya 12 fitur terbaik yang dipertahankan: A1_Score, A4_Score, A5_Score, A6_Score, A8_Score, A9_Score, A10_Score, age, gender, jundice, austim, dan used_app_before. Sementara itu, fitur-fitur seperti ethnicity, relation, dan contr_y_of_res dieliminasi karena memiliki korelasi rendah terhadap target dan tidak konsisten di keempat metode seleksi. Dengan menghilangkan fitur-fitur yang tidak informatif, model terhindar dari *curse of dimensionality* dan mampu fokus pada variabel-variabel dengan *signal* terkuat [11]. Hal ini tercermin dari selisih negatif antara akurasi training (91.38%) dan testing (94.83%), yang mengindikasikan bahwa model tidak menghafal pola data training secara berlebihan, melainkan berhasil menggeneralisasi dengan baik karena potensi *noise* telah diminimalkan [10]. Dengan kata lain, *feature selection* berkontribusi pada peningkatan kemampuan generalisasi dan stabilitas model terhadap data baru, meskipun dampak kuantitatifnya terhadap akurasi tidak diuji secara terpisah dalam penelitian ini.
4. Nilai ROC-AUC sebesar 0.9940 menunjukkan kemampuan diskriminasi model yang sangat baik. Secara matematis, AUC (*Area Under Curve*) merepresentasikan probabilitas bahwa model akan memberikan skor probabilitas yang lebih tinggi pada data Autis dibandingkan data Normal yang dipilih secara acak [13]. Nilai AUC = 0.9940 berarti model mampu membedakan kedua kelas dengan akurasi hampir sempurna, di mana

True positive Rate (TPR) selalu jauh lebih tinggi daripada *False positive Rate* (FPR) pada semua *threshold* probabilitas. Kurva ROC yang mendekati sudut kiri atas menunjukkan bahwa distribusi probabilitas output antara kelas Normal dan Autis memiliki *overlap* yang sangat minimal. Hal ini mengonfirmasi bahwa fitur-fitur hasil seleksi (terutama 10 item *Q-CHAT-10*) secara fundamental memiliki kekuatan diskriminatif yang sangat tinggi dalam memisahkan anak Normal dari anak dengan indikasi Autis [16]. Capaian ini memperkuat kesimpulan bahwa pendekatan yang digunakan, kombinasi *feature selection*, hyperparameter tuning, dan post-processing klinis, mampu menghasilkan sistem skrining yang andal dan objektif.

Perbandingan dengan Penelitian Terdahulu

Hasil penelitian ini sejalan dengan temuan penelitian-penelitian sebelumnya. [18] melalui meta-analisis dari 93 studi menunjukkan bahwa SVM merupakan classifier yang paling banyak digunakan (33 studi) dalam diagnosis ASD berbasis s-fMRI dan *machine learning*, dengan estimasi sensitivitas dan spesifisitas $>76\%$ [9] menunjukkan bahwa SVM linear mencapai akurasi 100% pada identifikasi ASD [10] membandingkan berbagai model dan menunjukkan SVM mencapai akurasi 100% pada test set. [11] menunjukkan bahwa SVM RBF memberikan performa terbaik (AUC $0,75 \pm 0,03$) dibandingkan metode lainnya dalam menganalisis functional connectivity.

Penelitian ini tidak melakukan perbandingan langsung dengan baseline seperti Logistic Regression atau Decision Tree, karena fokus utama adalah pada implementasi sistem skrining berbasis web dan optimasi SVM melalui *feature selection* dan hyperparameter tuning. Namun, perbandingan dengan studi relevan yang menggunakan berbagai metode [9] dengan SVM linear, [10] dengan berbagai model, dan [11] dengan SVM RBF) menunjukkan bahwa SVM RBF dengan hyperparameter tuning yang tepat mampu menghasilkan performa yang kompetitif atau lebih baik. Keterbatasan ini diakui sebagai salah satu kelemahan penelitian dan menjadi arahan untuk penelitian selanjutnya, sebagaimana disebutkan pada bagian keterbatasan.

Penelitian ini mengembangkan penelitian-penelitian sebelumnya dengan mengimplementasikan sistem berbasis web yang mengintegrasikan model SVM yang dioptimalkan dengan *feature selection* dan hyperparameter tuning, serta dilengkapi dengan post-processing rule berbasis *cut-off Q-CHAT-10*. Perbedaan utama terletak pada fokus implementasi sistem yang siap digunakan sebagai alat bantu skrining awal, bukan hanya pengembangan model. Hasil akurasi 94.83% dan ROC-AUC 0.9940 yang diperoleh dalam penelitian ini sebanding atau lebih baik dibandingkan penelitian-penelitian sebelumnya, menunjukkan bahwa pendekatan yang digunakan efektif dan *reliable*.

Implementasi Sistem

Interpretasi Hasil Model

Prototype sistem skrining ASD berbasis web dikembangkan menggunakan framework *Streamlit* dengan antarmuka yang intuitif dan interaktif. Pada tampilan utama, sistem dibagi menjadi dua area, yaitu

area input data di sisi kiri dan area hasil klasifikasi di sisi kanan.

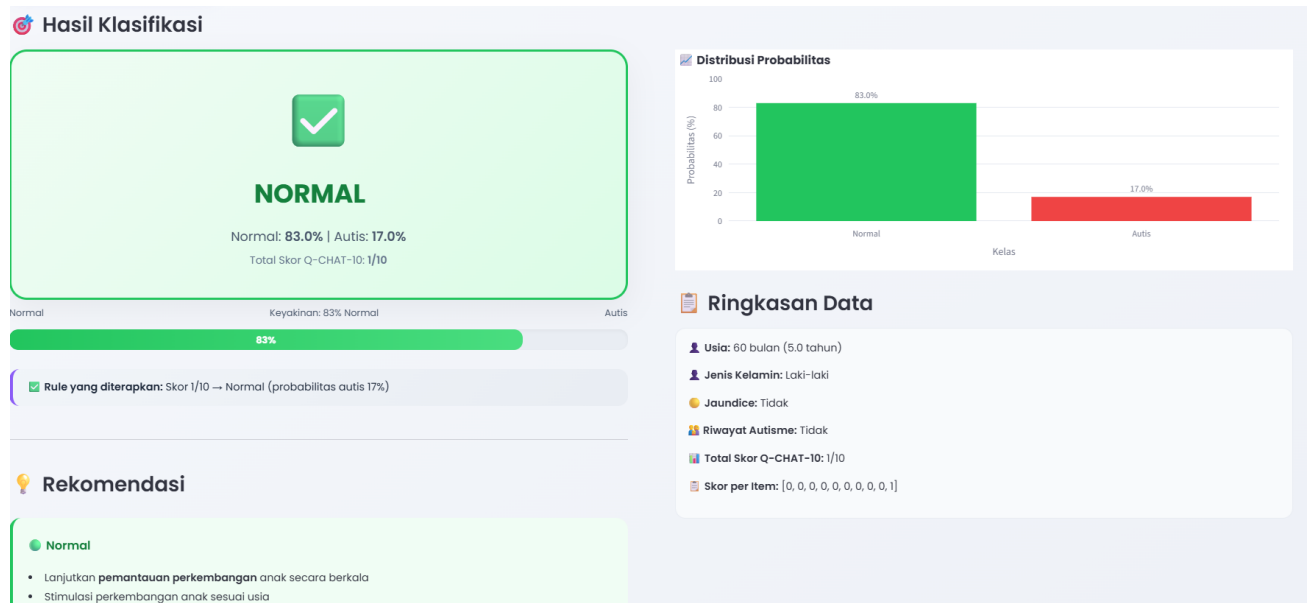
Area input data menyajikan formulir yang dikelompokkan menjadi tiga bagian sesuai dengan fitur-fitur hasil seleksi. Bagian "Identitas Anak" berisi pengaturan usia dalam bulan yang direpresentasikan melalui *slider* (dengan konversi otomatis ke tahun) serta pilihan jenis kelamin melalui *dropdown*. Bagian "Skrining *Q-CHAT-10*" menampilkan sepuluh item pertanyaan (A1 hingga A10) yang masing-masing dapat diisi melalui pilihan jawaban.

Pada bagian ini, sistem juga menampilkan kotak informasi (*info box*) yang memuat aturan skoring *Q-CHAT-10*, yaitu bahwa jawaban C, D, atau E pada pertanyaan 1–9 dan jawaban A, B, atau C pada pertanyaan 10 bernilai 1, dengan total skor lebih dari 3 mengindikasikan perlunya rujukan lebih lanjut [5]. Kehadiran informasi ini bertujuan untuk memberikan pemahaman klinis kepada pengguna sekaligus menjembatani pengetahuan medis dengan proses prediksi *machine learning*. Bagian "Riwayat Medis" memuat opsi untuk riwayat penyakit kuning (*jaundice*), riwayat autisme dalam keluarga, dan pengalaman menggunakan aplikasi skrining sebelumnya, yang masing-masing disajikan dalam bentuk pilihan biner (Ya/Tidak).

Gambar 4. Tampilan Antarmuka Sistem Klasifikasi Autisme

Area hasil klasifikasi di sisi kanan menampilkan prediksi dari model setelah pengguna menekan tombol prediksi. Hasil klasifikasi disajikan dalam bentuk kartu berwarna hijau untuk prediksi Normal dan merah untuk prediksi Autis serta disertai dengan label hasil yang jelas. Selain itu, sistem menampilkan probabilitas keyakinan model dalam bentuk angka dan *progress bar*

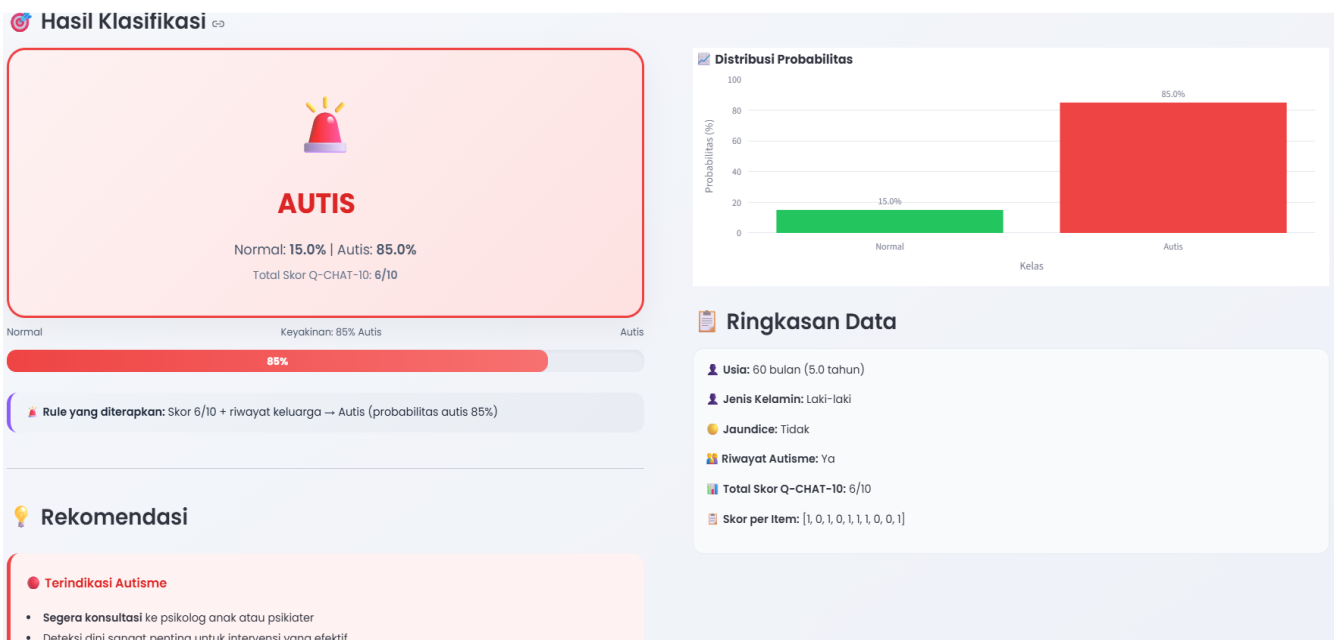
(misalnya "Keyakinan: 83% Normal" atau "Keyakinan: 72% Autis"), total skor *Q-CHAT-10* yang diperoleh dari input pengguna, serta grafik distribusi probabilitas untuk kedua kelas dalam bentuk diagram batang horizontal.



Gambar 5. Hasil Klasifikasi Normal

Untuk prediksi Normal, sistem menampilkan kartu hasil berwarna hijau dengan probabilitas Normal yang dominan (misal 83.0%) dan rekomendasi tindak lanjut berupa: "Lanjutkan pemantauan perkembangan anak secara berkala, stimulasi perkembangan anak sesuai usia, dan jika masih ada kekhawatiran, konsultasikan ke psikolog anak." Untuk prediksi Autis, sistem menampilkan kartu hasil berwarna merah dengan probabilitas Autis yang dominan (misal 72.0%) dan rekomendasi tindak lanjut berupa: "Segera konsultasi ke psikolog anak atau psikiater."

Deteksi dini sangat penting untuk intervensi yang efektif. Lakukan terapi perilaku dan komunikasi sedini mungkin. Pada kedua hasil, sistem juga menampilkan Ringkasan Data yang berisi usia, jenis kelamin, riwayat penyakit kuning, riwayat autisme keluarga, total skor *Q-CHAT-10*, dan skor per item (*array* 10 elemen). Di bagian bawah hasil, sistem mencantumkan *disclaimer*: "Hasil ini adalah skrining awal, BUKAN diagnosis medis final." sebagai bentuk tanggung jawab etis dan klinis.



Gambar 6. Hasil Klasifikasi Autis

Tabel 7. Uji Coba Sistem

No	Skenario	Total Skor <i>Q-CHAT-10</i>	Riwayat ASD Keluarga	Hasil Prediksi	Probabilitas	Keterangan
1.	Kasus Autis Ekstrem	10	Ya	AUTIS	100%	Seluruh 10 item indikasi perilaku mengarah ke ASD
2.	Kasus Normal Ekstrem	0	Tidak	NORMAL	98.5%	Seluruh 10 item indikasi perilaku normal
3.	Skor Tinggi + Riwayat	7	Ya	AUTIS	85%	Konfirmasi post-processing rule (skor ≥ 3)
4.	Skor Sedang + Riwayat	5	Ya	AUTIS	80%	Konfirmasi post-processing rule (skor ≥ 3)
5.	Skor Sedang - Riwayat	3	Tidak	NORMAL	98%	Probabilitas model tinggi; post-processing rule diabaikan karena tanpa riwayat keluarga

Hasil uji coba sistem (Tabel 5) menunjukkan bahwa sistem mampu menangani berbagai skenario, termasuk kasus ekstrem dan kasus borderline. Post-processing rule berbasis *cut-off Q-CHAT-10* (skor ≥ 3) berhasil meningkatkan akurasi pada kasus-kasus borderline (skor 3-6), membuktikan bahwa integrasi antara model *machine learning* dengan pengetahuan klinis dapat menghasilkan performa yang lebih baik dibandingkan model yang berdiri sendiri.

Sistem yang dikembangkan memiliki beberapa kelebihan:

1. Responsif: Dapat digunakan di berbagai perangkat (desktop, tablet, smartphone)
2. User-friendly: Antarmuka sederhana dengan panduan pengisian
3. Transparan: Menampilkan probabilitas dan tingkat keyakinan
4. Edukatif: Memberikan rekomendasi tindak lanjut yang bermanfaat
5. Real-time: Hasil prediksi muncul segera setelah tombol ditekan

Dengan adanya implementasi sistem ini, penelitian tidak hanya berhenti pada tahap pengembangan model, tetapi telah mencapai tahap aplikasi praktis yang dapat digunakan sebagai alat bantu skrining awal ASD. Sistem ini dirancang sebagai *prototype* yang dapat dikembangkan lebih lanjut untuk digunakan secara nyata di fasilitas kesehatan.

Keterbatasan Penelitian

Meskipun penelitian ini telah menghasilkan model prediksi yang baik, terdapat beberapa keterbatasan yang perlu diperhatikan:

1. Ukuran dataset: Dataset yang digunakan terbatas pada 292 data anak dengan 22 variabel awal, yang relatif kecil untuk mewakili seluruh variasi populasi.
2. Variabel terbatas: Penelitian ini belum memasukkan faktor-faktor lain yang berpotensi mempengaruhi diagnosis autisme, seperti faktor genetik, lingkungan, atau hasil pemeriksaan medis lanjutan.
3. Algoritma tunggal: Penelitian ini hanya menggunakan satu algoritma *machine learning* (SVM) tanpa membandingkan dengan algoritma lain.
4. Status *prototype*: Sistem yang dikembangkan masih berupa *prototype* yang berjalan pada

localhost dan belum diuji coba secara langsung oleh tenaga kesehatan di fasilitas kesehatan.

IV. KESIMPULAN

Penelitian ini berhasil mengimplementasikan prototype sistem skrining Autism Spectrum Disorder berbasis web menggunakan Support Vector Machine yang dioptimalkan melalui feature selection dan hyperparameter tuning. Model SVM dengan kernel RBF, parameter $C=10.0$, $\gamma=0.01$, dan class weight {0: 1.0, 1: 3.0} mencapai performa sangat baik dengan akurasi 94.83%, presisi 100% untuk kelas Normal dan 90.32% untuk kelas Autis, recall 90% untuk Normal dan 100% untuk Autis, F1-score 0.95 untuk kedua kelas, serta ROC-AUC 0.9940. Hasil ini menunjukkan bahwa SVM efektif dalam menangani data skrining ASD yang memiliki pola kompleks dan non-linear.

Kontribusi utama penelitian ini terletak pada tiga aspek. Pertama, dari sisi metodologi, penelitian ini mengintegrasikan feature selection dengan empat metode simultan (korelasi, mutual information, ANOVA F-score, dan permutation importance) untuk memilih fitur paling informatif dari 22 variabel awal pada 292 sampel data screening, sehingga meningkatkan reliabilitas model. Kedua, dari sisi pengembangan model, penelitian ini menerapkan hyperparameter tuning dengan GridSearchCV 10-fold cross validation dan class weight yang dioptimalkan (3:1 untuk kelas Autis) untuk mengatasi potensi ketidakseimbangan data dan meningkatkan sensitivitas deteksi. Ketiga, dari sisi implementasi, penelitian ini menghasilkan prototype sistem skrining ASD berbasis web yang mengintegrasikan model machine learning dengan pengetahuan klinis melalui post-processing rule berbasis *cut-off Q-CHAT-10* (skor ≥ 3). Integrasi ini merupakan pembeda utama dari penelitian-penelitian sebelumnya yang umumnya hanya berfokus pada pengembangan model tanpa implementasi sistem yang siap pakai.

Secara praktis, sistem ini dapat berfungsi sebagai alat bantu keputusan (decision support system) bagi psikoterapis dalam melakukan skrining awal secara lebih cepat, objektif, dan terstruktur. Bagi puskesmas dan dinas kesehatan, sistem ini dapat diadaptasi sebagai bagian dari program deteksi dini gangguan perkembangan anak. Bagi orang tua, sistem ini memberikan informasi awal yang cepat dan mudah diakses mengenai potensi risiko ASD pada anak, serta

rekomen dasi tindak lanjut yang jelas. Namun, perlu ditekan kan bahwa sistem ini dirancang sebagai alat bantu skrining awal, bukan sebagai alat diagnosis final. Hasil prediksi sistem harus selalu dikonfirmasi oleh tenaga profesional melalui proses diagnostik yang komprehensif.

Penelitian selanjutnya diharapkan dapat melakukan validasi eksternal dengan menguji sistem pada dataset dari populasi yang berbeda, mengembangkan data longitudinal untuk mengevaluasi akurasi prediksi jangka panjang, membandingkan performa SVM dengan algoritma machine learning lain seperti Random Forest atau XGBoost, serta menguji coba sistem secara langsung di fasilitas kesehatan untuk mengevaluasi efektivitas dan penerimaan pengguna.

V. REFERENSI

- [1] C. S. Hiremath *et al.*, “Emerging behavioral and neuroimaging biomarkers for early and accurate characterization of autism spectrum disorders: a systematic review,” *Transl. Psychiatry*, vol. 11, no. 1, 2021, doi: 10.1038/s41398-020-01178-6.
- [2] H. & Coyle, “Autism spectrum disorder,” *Neurobiol. Brain Disord. Biol. Basis Neurol. Psychiatr. Disord. Second Ed.*, vol. 6, no. 1, pp. 69–88, 2022, doi: 10.1016/B978-0-323-85654-6.00016-2.
- [3] Tim Riset Dinas Kesehatan, “Laporan Riskesdas 2018 Nasional.pdf,” 2018.
- [4] Farahdina, Irwanto, and I. Fithriyah, “Risk factors for autism spectrum disorder diagnosed in Indonesia,” *Child’s Heal.*, vol. 20, no. 5, pp. 325–332, 2025, doi: 10.22141/2224-0551.20.5.2025.1866.
- [5] P. Ghazi, Ridwan Achmad, and A. Prihandono, “D d a (a s d) m m l,” vol. 4, no. 2, pp. 44–51, 2023.
- [6] M. A. Putri, Chrystia Aji Putra, and Wahyu Syaifullah Jauharis Saputra, “Diagnosis Awal Autism Spectrum Disorder Menggunakan Algoritma Fuzzy K-Nearest Neighbor,” *J. Inform. Teknol. dan Sains*, vol. 6, no. 2, pp. 182–187, 2024, doi: 10.51401/jinteks.v6i2.3463.
- [7] G. Tartarisco *et al.*, “Use of machine learning to investigate the quantitative checklist for autism in toddlers (Q-CHAT) towards early autism screening,” *Diagnostics*, vol. 11, no. 3, 2021, doi: 10.3390/diagnostics11030574.
- [8] J. Jovel and R. Greiner, “An Introduction to Machine Learning Approaches for Biomedical Research,” *Front. Med.*, vol. 8, no. December, pp. 1–15, 2021, doi: 10.3389/fmed.2021.771607.
- [9] A. Novianto and Mila Desi Anasanti, “Identification of Autism Spectrum Disorder (ASD) using Feature-based Machine Learning Classification Model,” *2nd Int. Conf. Sustain. Comput. Smart Syst. ICSCSS 2024 - Proc.*, vol. 17, no. 3, pp. 1378–1384, 2024, doi: 10.1109/ICSCSS60660.2024.10625207.
- [10] M. Y. Yeap, S. Chua, and A. Bramantoro, “A Comparative Analysis of Machine Learning Models for Prediction of Autism Spectrum Disorder Using Screening Data,” *J. Adv. Res. Appl. Sci. Eng. Technol.*, vol. 53, no. 1, pp. 175–185, 2025, doi: 10.37934/araset.53.1.175185.
- [11] F. Mainas, B. Golosio, A. Retico, and P. Oliva, “Exploring Autism Spectrum Disorder: A Comparative Study of Traditional Classifiers and Deep Learning Classifiers to Analyze Functional Connectivity Measures from a Multicenter Dataset,” *Appl. Sci.*, vol. 14, no. 17, 2024, doi: 10.3390/app14177632.
- [12] O. A. Montesinos López, A. M. López, and J. Crossa, *Multivariate Statistical Machine Learning Methods for Genomic Prediction*. 2022. doi: 10.1007/978-3-030-89010-0.
- [13] L. N. Farida and S. Bahri, “Klasifikasi Gagal Jantung menggunakan Metode SVM (Support Vector Machine),” *Komputika J. Sist. Komput.*, vol. 13, no. 2, pp. 149–156, 2024, doi: 10.34010/komputika.v13i2.11330.
- [14] S. Saifuddin, L. Azhari, E. Widarti, and W. Wartono, “Evaluasi Kinerja Kernel Linear, RBF, dan Polynomial pada Model Support Vector Machine untuk Prediksi Risiko Hipertensi,” *J. Ilm. FIF0*, vol. 17, no. 2, p. 192, 2025, doi: 10.22441/fifo.2025.v17i2.008.
- [15] L. Alaika, “Optimization of Accuracy to Autism Spectrum Disorder Identification for Children Using Support Vector Machine and Correlation-based Feature Selection,” *J. Adv. Inf. Syst. Technol.*, vol. 4, no. 1, pp. 1–12, 2022, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/jaist>
- [16] N. A. Mashudi, N. Ahmad, and N. M. Noor, “Classification of adult autistic spectrum disorder using machine learning approach,” *LAES Int. J. Artif. Intell.*, vol. 10, no. 3, pp. 743–751, 2021, doi: 10.11591/ijai.v10.i3.pp743-751.
- [17] D. L. Floris *et al.*, “The Link Between Autism and Sex-Related Neuroanatomy, and Associated Cognition and Gene Expression,” *Am. J. Psychiatry*, vol. 180, no. 1, pp. 50–64, 2023, doi: 10.1176/APPI.AJP.20220194.
- [18] C. P. SANTANA, “A meta-analysis of machine learning classification tools using rs-fmri data for autism spectrum disorder diagnosis,” 2021, [Online]. Available: <https://repositorio.unifei.edu.br/jspui/handle/123456789/2370>