



Implementation of Decision Tree and Support Vector Machine (SVM) Algorithm for Stunting Risk Prediction

Implementasi Algoritma Decision Tree dan Support Vector Machine (SVM) untuk Prediksi Risiko *Stunting* pada Keluarga

**Amanda Iksanul Putri^{1*}, Yulia Syarif²,
Puguh Jayadi³, Fadlan Arrazak⁴, Febi Nur Salisah⁵**

^{1,2,4,5}Department of Information System, Faculty of Science and Technology
State Islamic University of Sultan Syarif Kasim Riau, Indonesia

³Program Studi Teknik Informatika, Fakultas Teknik, Universitas PGRI Madiun, Indonesia

E-Mail: ¹12150320068@students.uin-suska.ac.id, ²12150321439@students.uin-suska.ac.id,
³puguh.jayadi@unipma.ac.id, ⁴12150312250@students.uin-suska.ac.id, ⁵febinursalisah@uin-suska.ac.id

Received Aug 30th 2023; Revised Oct 04th 2023; Accepted Nov 05th 2023
Corresponding Author: Amanda Iksanul Putri

Abstract

Stunting is a condition of chronic malnutrition caused by inadequate food intake resulting from improper dietary habits. Stunting can lead to physical stunting in children, as well as hinder the growth and development of other organs such as the kidneys, heart, and brain. The increasing cases of stunting in children require early prevention efforts. This study utilized 18 attributes and 5021 data records from 10 districts in Dumai City, with one of them selected as the class. To establish which technique is best for processing the data, we used decision tree and support vector machine (SVM) algorithms. The prediction results using the Decision Tree algorithm in this study achieved an accuracy score of 96.15%, a recall value of 92.06% for "Not stunting" and 97.34% for "Yes" a precision value of 90.99% for "Not stunting" and 97.68% for "Yes". On the other hand, using the SVM algorithm yielded an accuracy score of 62.48%, a recall value of 99.12% for "Not stunting" and 51.80% for "Yes" and a precision value of 37.49% for "Not stunting" and 99.51% for "Yes stunting." Based on the research using the data, the accuracy of the decision tree algorithm is significantly better compared to the SVM algorithm.

Keyword: Decision Tree, Prediction, Stunting, Support Vector Machine (SVM)

Abstrak

Kondisi kekurangan gizi kronis yang disebabkan oleh asupan makanan yang tidak mencukupi sebagai akibat dari kebiasaan makan yang tidak tepat sesuai dengan gizi yang diperlukan disebut juga dengan *stunting*. *Stunting* dapat membuat fisik anak menjadi lebih pendek, selain itu dapat menghambat pertumbuhan dan perkembangan organ lain seperti ginjal, jantung, dan otak pada anak. Meningkatnya kasus *stunting* pada anak memerlukan upaya pencegahan secara dini. Pada penelitian ini menggunakan 18 atribut dan 5021 record data dari 10 kelurahan Kota Dumai dimana salah satu diantaranya dijadikan sebagai kelas. Pada penelitian ini menerapkan Algoritma *Decision Tree* dan *Support Vector Machine* (SVM) untuk mengetahui algoritma mana yang tepat memproses data tersebut. Hasil prediksi dengan menggunakan *Decision Tree* pada penelitian ini mendapatkan nilai akurasi sebesar 96.15%, nilai recall Tidak sebesar 92.06% serta Ya sebesar 97.34% dan nilai presisi Tidak sebesar 90.99% serta Ya sebesar 97.68%. Sedangkan dengan menggunakan Algoritma SVM mendapatkan nilai akurasi sebesar 62.48%, nilai *recall* Tidak sebesar 99.12% serta Ya sebesar 51.80% dan nilai presisi Tidak sebesar 37.49% serta Ya sebesar 99.51%. Berdasarkan penelitian menggunakan data tersebut dapat disimpulkan bahwa akurasi algoritma *Decision Tree* jauh lebih baik dibandingkan dengan algoritma SVM.

Kata Kunci: Decision Tree, Prediksi, *Stunting*, Support Vector Machine (SVM)

1. INTRODUCTION

Kondisi kekurangan gizi kronis yang disebabkan oleh asupan makanan yang tidak mencukupi sebagai akibat dari kebiasaan makan yang tidak tepat sesuai dengan gizi yang diperlukan disebut juga dengan

stunting. *Stunting* bisa dimulai saat anak masih dalam kandungan dan tidak terlihat hingga berusia dua tahun [1]. *Stunting* dapat membuat fisik anak menjadi lebih pendek, selain itu dapat menghambat pertumbuhan dan perkembangan organ lain seperti ginjal, jantung, dan otak pada anak. Akibatnya, anak yang *stunting* akan mengalami gangguan perkembangan neurosensori dan motorik, IQ rendah, dan gangguan kinerja psikomotorik [2]. Dampak berbahaya langsung dan jangka panjang dapat diakibatkan oleh *stunting*. *Stunting* dapat memperlambat pertumbuhan tubuh, metabolisme, dan perkembangan otak dalam jangka pendek. Di sisi lain, dampak negatif jangka panjang antara lain penurunan kinerja kognitif dan pembelajaran, penurunan daya tahan fisik yang meningkatkan risiko penyakit, dan penyakit kronis seperti diabetes, obesitas, penyakit kardiovaskular, kanker, stroke, dan gangguan geriatri. Mungkin juga ada peningkatan risiko penyakit. *Stunting* juga dapat mengakibatkan pekerjaan berkualitas rendah, yang menurunkan hasil ekonomi [3].

Stunting dipengaruhi oleh penyebab bawaan dan eksternal. *Stunting* pada anak disebabkan oleh variabel internal yang berhubungan langsung dengan tumbuh kembangnya, seperti pola asuh orang tua, ASI eksklusif, makanan pendamping ASI, imunisasi lengkap, asupan protein dan mineral yang cukup, kelainan virus, dan genetik. Di sisi lain, karakteristik sosial ekonomi keluarga yang meliputi tingkat pendidikan ibu, posisi pekerjaan ibu, dan pendapatan rumah tangga berpengaruh secara eksternal [4]. Untuk menurunkan bahaya *stunting*, pemerintah Indonesia telah menerapkan sejumlah kebijakan. Intervensi nutrisi adalah salah satunya, dengan penekanan pada dua jenis terapi: intervensi nutrisi sensitif dan intervensi nutrisi yang ditargetkan. Sementara perawatan nutrisi yang ditargetkan berfokus pada asupan makanan, intervensi nutrisi yang sensitif mencoba mengatasi faktor tidak langsung yang berkontribusi terhadap *stunting*, seperti ketahanan pangan, akses ke layanan kesehatan, kebersihan lingkungan, dan gaya pengasuhan. Infeksi dan penyakit merupakan salah satu penyebab langsung *stunting* yang menjadi sasaran [5].

Anak yang tergolong *stunting* yaitu mereka yang status gizinya ditentukan oleh panjang atau tinggi badannya berdasarkan pedoman WHO-MGRS (*Multicenter Growth Reference Study*) untuk anak seusianya. Menurut data WHO tentang kejadian *stunting* anak, Indonesia memiliki tingkat *stunting* tertinggi ketiga di Kawasan Asia Tenggara (SEAR) [6]. Menurut WHO, masalah kesehatan masyarakat dapat dikatakan kronis jika prevalensi *stunting* lebih tinggi dari 20% [7]. Menurut situs web Kementerian Kesehatan Republik Indonesia, prevalensi *stunting* di Indonesia adalah 21,6%, yang tidak memenuhi standar yang ditetapkan oleh WHO (kemkes.go.id). Namun, *stunting* sendiri dapat dideteksi sejak dini (*early warning*) dengan memantau pola makan anak [8]. *Early Warning* pada *stunting* sangat sulit dilakukan dikarenakan beberapa hal penyebabnya yaitu sebagian besar ibu yang membesarkan anak-anak yang mengalami *stunting* hanya memiliki sedikit atau bahkan tidak memiliki pendidikan dan tidak memiliki pengetahuan informal tentang *stunting* [9]. Rendahnya keterlibatan masyarakat dalam pemeriksaan kesehatan di puskesmas seperti Posyandu [10], Sulit bagi masyarakat untuk mengambil tindakan ketika terkena *stunting* terjadi karena terbatasnya sumber daya untuk menyelenggarakan pelatihan rutin dan teratur, terbatasnya tenaga kesehatan, yang mengakibatkan perawatan kesehatan yang tidak memadai, dan terbatasnya tenaga profesional [11], tidak memiliki alat ukur panjang badan yang standar, alat tidak terpasang dengan baik, cara pengukuran yang tidak benar, seperti posisi anak, pembacaan hasil dan koreksi hasil pengukuran [12]. Semua pihak, termasuk iptek, harus menjawab kompleksitas tantangan yang berkaitan dengan *stunting* dan bertanggung jawab [13].

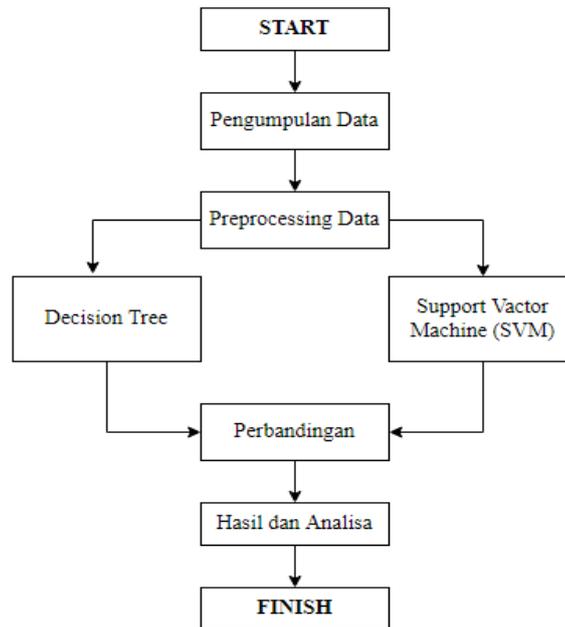
Dalam penelitian ini, *Decision Tree* dan *Support Vector Machine* (SVM) adalah dua teknik yang digunakan di bidang *Machine Learning* (ML), algoritma klasifikasi termasuk *Decision Tree* dan SVM. Sebagai subbidang kecerdasan buatan, pembelajaran ML memungkinkan sistem untuk belajar secara otomatis tanpa pemrograman yang membosankan [14]. Hasil klasifikasi dari *Decision Tree* atau SVM bisa digunakan sebagai *early warning stunting*, pengolahan data yang banyak menggunakan ML disebut juga data mining. Data mining adalah proses menganalisis sebuah kasus untuk mengetahui algoritma mana yang bekerja paling baik. Kumpulan data besar dapat ditambang menggunakan teknik penambangan data untuk mengungkap pola dan informasi [15]. Selain itu, algoritma *Decision Tree* dan SVM telah digunakan dalam penelitian berbagai penyakit seperti kanker payudara [16], *Acute Lymphoblastic Leukimia* (ALL) [17] dan virus covid-19 varian omicron [18].

Oleh karena itu, penelitian ini menggunakan uji-t untuk memprediksi *stunting* keluarga dan bertujuan untuk menentukan algoritma mana yang lebih baik diantara keduanya. Kami dapat menentukan algoritma mana yang berkinerja lebih baik berkat aplikasi Rapidminer.

2. MATERIALS AND METHOD

Gambar 1 menampilkan proses yang digunakan dalam investigasi ini. Metode penelitian ini berlangsung dari berbagai tahap proses, tahap pertama yaitu mengumpulkan dan melakukan proses *preprocessing* data yang ditujukan untuk penelitian. Kami membagi data menjadi dua, masing-masing 70:30 untuk set pelatihan dan tes. Tahap selanjutnya adalah membuat dan menjalankan model algoritma SVM dan *Decision Tree* setelah membagi data menjadi data latih dan data uji dengan perbandingan 70:30. Langkah selanjutnya adalah mengeksplorasi performa model menggunakan data uji. Data uji kemudian digunakan untuk memprediksi hasil, dan hasil prediksi tersebut dibandingkan dengan nilai parameter yang sebenarnya

dari data uji. Dengan membandingkan prediksi dan nilai parameter sebenarnya, kita dapat mengukur tingkat kesalahan dalam proses prediksi model pada data pengujian.



Gambar 1. Research Methodology

2.1 Akusisi Data

Data stunting besumber dari Dinas Pengendalian Penduduk dan Keluarga Brenecana Kota Dumai Provinsi Riau. Pada penelitian ini menggunakan 18 atribut dan 5021 record data dari 10 kelurahan Kota Dumai, yaitu Kelurahan Bagan Besar, Kelurahan Bagan Keladi, Kelurahan Basilan Baru, Kelurahan Guntung, Kelurahan Jaya Mukti, Kelurahan Kayu Kapur, Kelurahan Purnama, Kelurahan STDI, dan Kelurahan Teluk Binjai. Atribut yang dipertimbangkan dalam penyelidikan ini tercantum dalam Tabel 1.

Tabel 1. Atribut Data Stunting

No	Atribut	Keterangan	Jumlah Data	Value (X)	Value (V)	Value (-)	Missing Value
1	Baduta	Bawah Dua Tahun (0-23 bulan)	5021	4270	750	0	1
2	Balita	Bawah Lima Tahun (24-59 bulan)	5021	3471	1549	0	1
3	PUS	Pasangan Usia Subur	5021	100	4921	0	0
4	PUS Hamil	Pasangan Usia Subur Hamil	5021	4785	236	0	0
5	Anak 7- 15 Tahun	Ada Anak 7-15 Tahun Tidak Sekolah	5021	142	221	4657	1
6	Sumber Penghasil an	Tidak ada anggota keluarga yang mampu menutupi kebutuhan pokok mereka setiap bulan	5021	4954	67	0	0
7	Jenis Lantai Tanah	Jenis Lantai Rumah Tanah, Semen, atau Keramik	5021	4977	44	0	0
8	Jenis Makanan	Tidak semua orang makan "aneka makanan" lebih dari dua kali sehari di rumah tangga	5021	4993	28	0	0
9	Keluarga Pra Sejahtera	Keluarga Yang Tidak Mampu Memenuhi Kebutuhan Dasar nya, Seperti Kebutuhan Pendidikan, Agama, Sandang, Pangan, dan Kesehatan.	5021	4714	307	0	0
10	Sumber Air Minum	keluarga tanpa akses ke sumber air minum dasar yang layak	5021	4915	106	0	0
11	Jenis Jamban	Keluarga Yang Tidak Mempunyai Kamar Mandi Yang Layak	5021	4662	359	0	0
12	Jenis	Keluarga Tidak Mempunyai	5021	4067	954	0	0

No	Atribut	Keterangan	Jumlah Data	Value (X)	Value (V)	Value (-)	Missing Value
13	Rumah Pendidikan an Ibu	Rumah Layak Huni Pendidikan Terakhir Ibu Dibawah SLTP	5021	3766	1246	0	0
14	Terlalu Muda	Umur Istri Kurang Dari 20 Tahun	5021	4816	130	74	1
15	Terlalu Tua (>35 Tahun)	Umur Istri Lebih Dari 35 Tahun	5021	2047	2490	119	2
16	Terlalu Dekat (< 2 Tahun)	Umur Anak Jaraknya Hanya 2 Tahun	5021	3205	252	1558	6
17	Terlalu Banyak (3 Anak)	Memiliki Anak Yang Terlalu Banyak	5021	2956	1964	86	2
18	Class	Kategori keluarga berpotensi resiko stunting	5021				

2.2 Stunting

Dengan menentukan skor indeks-z tinggi badan vs umur (TB/U), stunting dapat diidentifikasi. Hal ini menunjukkan bahwa tinggi badan (TB) individu tidak sesuai dengan usianya [19]. Jika *Z-score* kurang dari -2 SD atau kurang dari -3 SD, anak dianggap stunting [20]. Adapun rumus Z score adalah ditunjukkan pada persamaan 1 [19]:

$$Z \text{ Score} = \frac{x \text{ hitung} - MBR}{SBR} \quad (1)$$

Keterangan:

- x = Parameter yang di ukur
- MBR = Median buku rujukan
- SBR = Simpangan baku rujukan

2.3 Data Mining

Data Mining adalah sekelompok prosedur yang digunakan untuk mengumpulkan informasi dan pola dari kumpulan data [21]. Salah satu cabang ilmu komputer yang disebut data mining menggunakan sejumlah prosedur komputasi, metode statistik, pengelompokan, klasifikasi, dan pengenalan pola dalam kumpulan data [22]. Ada berbagai tahapan untuk proses *data mining* [23]:

1. *Data Preprocessing*
Preprocessing merupakan langkah yang dilakukan sebelum memulai analisis data yang sebenarnya. Pada tahap ini, dilakukan proses untuk membersihkan dan memproses data, mengintegrasikan serta mengurangi data, melakukan transmisi, dan melakukan normalisasi data[24].
2. *Selection Feature*
Prosedur ini digunakan untuk memadatkan dataset stunting dan memilih fitur yang penting untuk diagnosis stunting.
3. *Data Scrambling*
Pengacakan data pada dataset dapat berdampak pada performa. Hal ini disebabkan oleh model klasifikasi yang dilatih pada data tersebut selama proses pelatihan. Pengacakan data akan diterapkan setelah tahap preprocessing dan reduksi data.
4. *Data Classification*
Salah satu pekerjaan terpenting dalam data mining dan pembelajaran mesin adalah klasifikasi, yang termasuk dalam kategori pembelajaran terawasi [21]. Klasifikasi adalah proses mengidentifikasi model atau fungsi yang mendefinisikan atau membedakan suatu konsep atau kelas data dengan tujuan untuk dapat menyimpulkan kelas objek yang labelnya tidak diketahui. Untuk mencapai hal ini, sebuah model dibuat melalui proses kategorisasi yang dapat membagi data menjadi beberapa kelas sesuai dengan aturan atau fungsi yang telah ditentukan sebelumnya [25].
5. *Performance Evaluation*
Nilai akurasi dari prosedur yang diterapkan diperiksa selama tahap evaluasi kinerja dengan melakukan perbandingan kesalahan (*error*) masing-masing algoritma dengan menggunakan data yang sama dan membagi data dengan perbandingan 70:30. Menggunakan persamaan 2.

$$Akurasi = \frac{tp+tn}{tp+tn+fp+fn} \quad (2)$$

2.4 Machine Learning

Studi tentang pembuatan algoritma komputer yang dapat memproses data untuk menghasilkan tindakan cerdas, atau mengubah data menjadi informasi, dikenal sebagai pembelajaran mesin [21]. Kumpulan data yang besar dan rumit dapat diproses dengan cepat oleh *machine learning*. Selain itu, *machine learning* juga dapat mengidentifikasi pola dan tren yang tidak dapat dilihat oleh manusia dan meningkatkan produktivitas tanpa harus didorong oleh kesuksesan [26].

2.5 Decision Tree

Dengan menggunakan seperangkat aturan keputusan dan struktur pohon keputusan, kumpulan data yang sangat besar dapat dibagi menjadi kumpulan catatan yang lebih kecil. Tiga algoritma ID3, CART, dan C4.5 dapat digabungkan untuk membuat pohon keputusan. Algoritma ID3, yang dibuat oleh Quinlan, diperluas oleh algoritma C4.5 [15]. ID3 adalah metode yang digunakan untuk data kategorikal, sementara C4.5 digunakan untuk data kategorikal maupun numerik. Sementara C4.5 menggunakan rasio perolehan sebagai kriteria pemilihan atributnya, teknik ID3 menggunakan perolehan informasi sebagai kriterianya [27].

Berikut ini adalah tahapan-tahapan dalam algoritma *Decision Tree* [28]:

1. Persiapkan *dataset* pelatihan.
2. Tentukan akar dari pohon keputusan.
3. Pilih karakteristik yang akan bertindak sebagai akar pohon keputusan dengan menghitung nilai gain. Gain dihitung berdasarkan nilai Gain tertinggi dari atribut-atribut yang tersedia. Persamaan berikut dapat digunakan untuk menghitung nilai Gain.

$$Gain(S, A) = Entropy(S) - \sum_{i=1}^N \frac{|s_i|}{|S|} \times Entropy(S_i) \quad (3)$$

4. Prosedur untuk setiap cabang yang terbentuk, ulangi langkah kedua. Di sisi lain, untuk menghitung nilai entropi, gunakan persamaan yang sesuai. Persamaan yang dapat digunakan adalah Persamaan dua berikut ini:

$$Entropy(S) = \sum_{i=1}^N -p_i \times \log 2p_i \quad (4)$$

5. Proses pembentukan pohon keputusan berakhir ketika semua cabang dari node N memiliki kelas yang sama.

2.6 Support Vector Machine (SVM)

Pendekatan *Structural Risk Minimization* (SRM) berfungsi sebagai dasar untuk teknik pembelajaran mesin yang dikenal sebagai *Support Vector Machine* (SVM). Menemukan *hyperplane* terbaik untuk membagi dua kelas di ruang input adalah tujuan dari SVM. Bidang-hiper yang terletak di tengah-tengah antara dua set objek dari dua kelas adalah bidang-hiper yang ideal. Menghitung margin *hyperplane* dan menentukan titik maksimumnya akan mengungkapkan *hyperplane* mana yang paling baik membagi dua kelas. Margin adalah pemisahan antara pola terdekat setiap kelas dan *hyperplane*. *Support vector* adalah pola yang paling dekat dengan *hyperplane* [29].

$$f(x_d) = \sum_{i=1}^{n_s} \alpha_i y_i x_i x_d + b \quad (5)$$

Dimana:

- | | |
|------------|--------------------------------------|
| n_s | = Banyaknya support vector |
| α_i | = besaran bobot dari tiap titik data |
| y_i | = Kelas data |
| x^i | = Variabel Support Vector |
| x^d | = Data yang akan diklasifikasikan |
| b | = Nilai error |

2.7 Rapid Miner

Perusahaan dengan nama yang sama menciptakan platform perangkat lunak yang berfokus pada sains data yang dikenal sebagai RapidMiner [30]. Perangkat lunak ini mengandung semua algoritma dasar yang diperlukan untuk tugas *data mining*, seperti *predictive mining*, *descriptive mining* and *pre-processing* data agar data menjadi cocok untuk mining. Perangkat lunak ini juga sangat cocok untuk menggambarkan data secara visual [31]. Platform mencakup setiap fase proses pembelajaran mesin, termasuk persiapan data, visualisasi hasil, validasi, dan pengoptimalan. RapidMiner dibuat menggunakan arsitektur inti terbuka [30].

RESULTS AND DISCUSSION

3.1 Preprocessing

Sebelum data diproses menggunakan algoritma, data akan dilakukan *preprocessing* terlebih dahulu karena pada data terdapat value (-) dan juga *missing value*. Saat dilakukannya *preprocessing* data, data akan diubah dalam bentuk angka agar dapat mempermudah melakukan pemrosesan. Data dengan variable (X) diubah menjadi angka 0 dan data dengan variable (V) diubah menjadi angka 1. Sedangkan untuk *class* variable (X) diubah menjadi “tidak” dan data dengan variable (V) diubah menjadi “ya”. Selanjutnya data-data yang terdapat *missing value* diolah terlebih dahulu menggunakan operator *missing value* yang ada di rapid miner. Tabel 2 menampilkan data yang telah melalui proses *preprocessing*.

Tabel 2. Data yang telah diprocessing

5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	
0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	tidak
0	0	1	0	1	0	0	0	0	0	0	0	1	0	1	0	1	0	ya
0	0	1	0	1	0	0	0	0	0	0	0	0	0	1	0	0	0	ya
0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	tidak
0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	ya
0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	ya
...
0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	ya
0	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	1	0	ya
0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	tidak

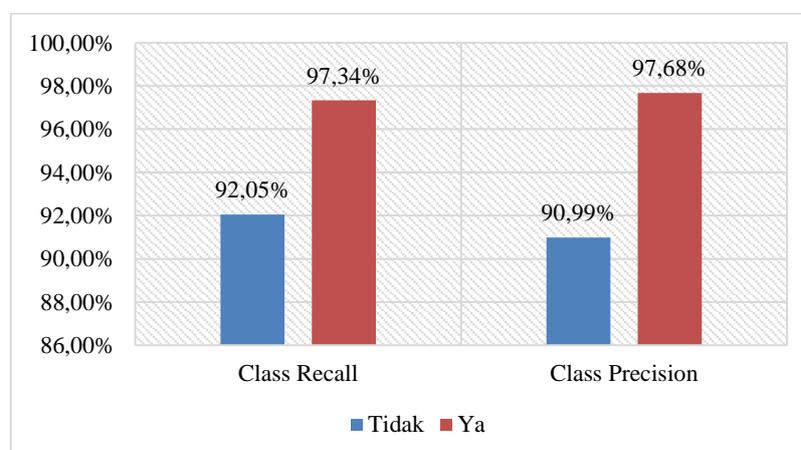
3.2 Klasifikasi Decision Tree

Dataset survei dibaca dalam format CSV. Dataset dibagi menjadi partisi data latih dan partisi data uji menggunakan operator pemisahan data, dengan persentase masing-masing set 70% dan 30%. Menggunakan perhitungan dari algoritma *Decision Tree*. Selanjutnya menggunakan data pelatihan pengujian, operator *Apply Model* digunakan untuk menerapkan model pra-pelatihan. Kinerja, operator terakhir, sangat membantu untuk memeriksa evaluasi metode klasifikasi. Hasil penerapan algoritma *Decision Tree* pada informasi pada Tabel 3.

Tabel 3. Performance Algoritma Decision Tree

Accuracy: 96,15%			
	True Tidak	True Ya	Class Precision
Pred Tidak	313	31	90,99%
Pred Ya	27	1135	97,68%
Class Recall	92,05%	97,34%	

Tabel 3 menunjukkan bahwa metode pohon keputusan memiliki tingkat akurasi sebesar 96,15%. 92,06% nilai *recall* dari kelas tidak, sedangkan kelas ya 97,34%. Skor presisi untuk setiap kelas adalah 90,99% untuk kelas Tidak dan 97,68% untuk kelas Ya. Angka akurasi ini dihasilkan dari sistem yang salah mengklasifikasikan data tertentu. Dengan kata lain, 31 data Ya termasuk dalam kelas No, sedangkan 27 data Tidak termasuk dalam kelas Ya. Visualisasi dari *Performance Algoritma Decision Tree* dapat dilihat pada gambar 2.



Gambar 2. Visualisasi Performance Algoritma Decision Tree

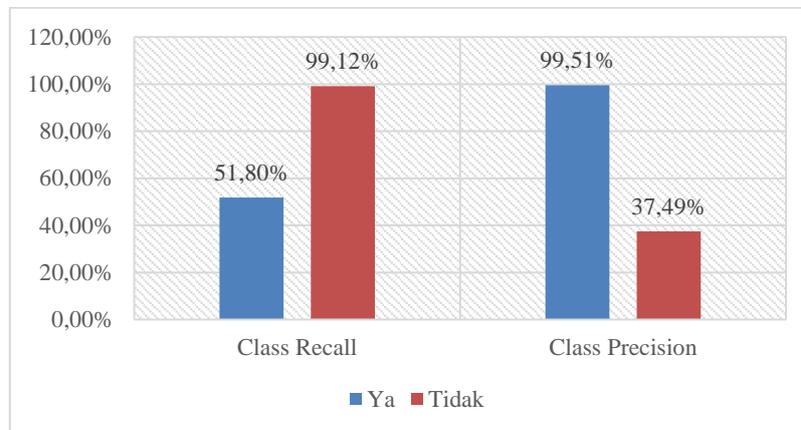
3.3 Klasifikasi Support Vector Machine (SVM)

Secara keseluruhan operator yang digunakan dalam algoritma SVM sama dengan yang digunakan dalam implementasi algoritma *Decision Tree*. Namun, operator SVM digunakan dalam pengujian ini. Hasil pengujian algoritma pada dataset penelitian ditunjukkan pada Tabel 4.

Tabel 4. Performance Algoritma SVM

Accuracy: 62,48%			
	True Tidak	True Ya	Class Precision
Pred Tidak	337	562	37,49%
Pred Ya	3	604	99,51%
Class Recall	99,12%	51,8%	

Tabel 4 menunjukkan bahwa akurasi algoritma SVM adalah 62,48%. 99,12% adalah nilai *recall* untuk kelas Tidak, sedangkan 51,80% *recall* untuk kelas Ya. Persentase presisi untuk kelas Tidak dan kelas Ya berturut-turut adalah 37,49% dan 99,51%. Angka akurasi ini dihasilkan dari sistem yang salah mengklasifikasikan data tertentu. Dengan kata lain, 3 data Tidak diklasifikasikan sebagai kelas Ya, sedangkan 562 data Ya dikelompokkan pada kelas Tidak. Visualisasi dari *Performance* Algoritma SVM dapat dilihat pada gambar 3.



Gambar 3. Visualisasi *Performance* Algoritma SVM

3.4 Perbandingan Klasifikasi Decision Tree dan SVM

Berdasarkan hasil implementasi algoritma *decision tree* dan SVM, nilai *performance* keduanya ditunjukkan pada tabel 5.

Tabel 5. Perbandingan Performance Decision Tree dan SVM

No	Algoritma	Akurasi	Recall		Presisi	
			True Tidak	True Ya	Pred. Tidak	Pred. Ya
1	Decision Tree	96.15%	92.06%	97.34%	90.99%	97.68%
2	SVM	62.48%	99.12%	51.80%	37.49%	99.51%

Terlihat dari data diatas, algoritma yang tercantum tidak memiliki nilai akurasi yang sama. Algoritma *decision tree* mendapatkan nilai akurasi yang tinggi yaitu sebesar 96.15%. Sedangkan untuk akurasi SVM sendiri sangat jauh dibawah *Decision Tree* yaitu hanya sebesar 62.48%. Untuk *Recall* data Tidak SVM lebih unggul dibandingkan *Decision Tree* sebesar 99.12% namun untuk data Ya *Decision Tree* jauh lebih unggul dibandingkan SVM 97.34%. Untuk presisi kelas Tidak *Decision Tree* jauh lebih unggul dibandingkan SVM yaitu sebesar 90.99%, sedangkan pada kelas Ya SVM lebih unggul dibandingkan *decision tree* yaitu sebesar 99.51%. Pada gambar 4 terdapat visualisasi akurasi dari kedua algoritma yaitu *Decision Tree* dan SVM.

4. CONCLUSION

Dari penelitian yang telah dilakukan membuahkan hasil akurasi algoritma *Decision Tree* jauh lebih baik dibandingkan dengan algoritma SVM dalam *dataset stunting* yang digunakan dalam riset ini. Pada algoritma *Decision Tree* didapatkan akurasi sebesar 96.15% sedangkan pada algoritma SVM akurasi yang didapatkan memiliki selisih 33.67% dengan algoritma *Decision Tree* yaitu sebesar 62.48%. Apabila pada

penelitian selanjutnya terdapat pola data yang hampir sama dapat menggunakan *Decision Tree* untuk pengolahannya.

REFERENCES

- [1] K. Rahmadhita, "Permasalahan Stunting dan Pencegahannya Stunting Problems and Prevention," *Jurnal Ilmiah Kesehatan Sandi Husadah*, vol. 11, no. 1, pp. 225–229, 2020, doi: 10.35816/jiskh.v10i2.253.
- [2] R. A. Saputri and J. Tumangger, "Hulu-Hilir Penanggulangan Stunting Di Indonesia," *Journal of Political Issues*, vol. 1, no. 1, pp. 1–9, Jul. 2019, doi: 10.33019/jpi.v1i1.2.
- [3] A. Rahmadhani, "LITERATURE REVIEW PENGALAMAN IBU DENGAN ANAK STUNTING."
- [4] L. S. Nisa, "KEBIJAKAN PENANGGULANGAN STUNTING DI INDONESIA STUNTING PREVENTION POLICIES IN INDONESIA," *Jurnal Kebijakan Pembangunan*, vol. 13, no. 02, pp. 173–179, 2018.
- [5] R. T. Handayani, A. T. Darmayanti, C. Setyorini, A. Widiyanto, and J. T. Atmojo, "Intervensi Gizi dalam Penanganan dan Pencegahan Stunting di Asia: Tinjauan Sistematis," *Jurnal Keperawatan Global*, vol. 5, no. 1, pp. 26–30, 2020.
- [6] Komalasari, E. Supriati, R. Sanjaya, and H. Ifayanti, "Faktor-Faktor Penyebab Kejadian Stunting Pada Balita," *Majalah Kesehatan Indonesia*, vol. 1, no. 2, pp. 51–56, 2020.
- [7] A. Daracantika, Ainin, and Besral, "Systematic Literature Review: Pengaruh Negatif Stunting terhadap Perkembangan Kognitif Anak," 2021.
- [8] D. Dwi Astuti, R. Benya Adriani, T. Widyastuti Handayani, J. Keperawatan, and P. Kemenkes Surakarta, "PEMBERDAYAAN MASYARAKAT DALAM RANGKA STOP GENERASI STUNTING," *Jurnal Masyarakat Mandiri*, vol. 4, no. 2, pp. 156–162, 2020, doi: 10.31764/jmm.v4i2.1910.
- [9] J. Mantik, M. Ula, A. Faridhatul Ulva, and I. Sahputra, "Implementation of Machine Learning in Determining Nutritional Status using the Complete Linkage Agglomerative Hierarchical Clustering Method," *Jurnal Mantik*, vol. 5, no. 3, pp. 1910–1914, 2021.
- [10] H. Maruli Siregar *et al.*, "UPAYA PENINGKATAN KUNJUNGAN POSYANDU DI DUSUN SERAI SERUMPUN DESA SUMBER AGUNG," *Jurnal Pengembangan dan Pengabdian Masyarakat*, vol. 1, no. 1, pp. 1–5, 2022.
- [11] K. Isni *et al.*, "Pelatihan Pengukuran Status Gizi Balita sebagai Upaya Pencegahan Stunting Sejak Dini pada ibu di Dusun Randugunting, Sleman, DIY Toddler Nutrition Status Measurement Training as an Early Prevention of Stunting to Mothers in Dusun Randugunting," 2020. [Online]. Available: <http://journal.unhas.ac.id/index.php/panritaabdi>
- [12] F. N. Rohmah and Siti Arifah, "OPTIMALISASI PERAN KADER KESEHATAN DALAM DETEKSI DINI STUNTING," *BEMAS: Jurnal Bermasyarakat*, vol. 1, no. 2, pp. 95–102, Mar. 2021, doi: 10.37373/bemas.v1i2.88.
- [13] I. K. A. W. Guna, E. Setyati, and E. Pramana, "Prediksi Anak Stunting Berdasarkan Kondisi Orang Tua Dengan Metode Support Vector Machine Dengan Study Kasus Di Kabupaten Tabanan-Bali," *SMATIKA JURNAL*, vol. 12, no. 01, pp. 47–54, Jun. 2022, doi: 10.32664/smatika.v12i01.662.
- [14] A. Rozaq, Y. Yunitasari, K. Sussolaikah, E. R. N. Sari, and R. I. Syahputra, "Analisis Sentimen Terhadap Implementasi Program Merdeka Belajar Kampus Merdeka Menggunakan Naïve Bayes, K-Nearest Neighbors Dan Decision Tree," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 6, no. 2, p. 746, Apr. 2022, doi: 10.30865/mib.v6i2.3554.
- [15] Ardiyansyah, P. Agustia Rahayuningsih, and R. Maulana, "Analisis Perbandingan Algoritma Klasifikasi Data Mining Untuk Dataset Blogger Dengan Rapid Miner," *JURNAL KHATULISTIWA INFORMATIKA*, vol. VI, no. 1, pp. 20–28, 2018.
- [16] L. Indah Prahartiwi, W. Dari, and S. Nusa Mandiri, "Komparasi Algoritma Naive Bayes, Decision Tree dan Support Vector Machine untuk Prediksi Penyakit Kanker Payudara," *Jurnal Teknik Komputer AMIK BSI*, vol. 7, no. 1, 2021, doi: 10.31294/jtk.v4i2.
- [17] F. Alamsyah, M. Dzikrullah Suratn, and M. Hamid, "Analisis Perbandingan Metode Support Vector Machine (SVM) dan Decision Tree Pada Klasifikasi Penyakit Acute Lymphoblastic Leukimia (ALL)," *Jurnal PRODUKTIF*, vol. 6, no. 2, pp. 581–587, 2022.
- [18] A. Arham, E. R. Swedia, M. Cahyanti, and M. R. D. Septian, "IMPLEMENTASI SENTIMENT ANALYSIS PADA OPINI MASYARAKAT INDONESIA DI TWITTER TERHADAP VIRUS COVID-19 VARIAN OMICRON DENGAN ALGORITMA NAÏVE BAYES, DECISION TREE, DAN SUPPORT VECTOR MACHINE," *Sebatik*, vol. 26, no. 2, pp. 565–572, Dec. 2022, doi: 10.46984/sebatik.v26i2.1961.
- [19] A. Y. Perdana, R. Latuconsina, and A. Dinimaharawati, "PREDIKSI STUNTING PADA BALITA DENGAN ALGORITMA RANDOM FOREST," in *e-Proceeding of Engineering*, 2021, pp. 6650–6656.

- [20] D. Sri Sumardilah and A. Rahmadi, "Risiko Stunting Anak Baduta (7-24 bulan)," *Jurnal Kesehatan*, vol. 10, no. 1, pp. 93–104, 2019, [Online]. Available: <http://ejurnal.poltekkes-tjk.ac.id/index.php/JK>
- [21] A. Supriyatna, W. Prima Mustika, A. BSI Karawang Jl Banten No, S. Nusa Mandiri Jl Kramat Raya No, and J. Pusat, "Komparasi Algoritma Naive bayes dan SVM Untuk Memprediksi Keberhasilan Imunoterapi Pada Penyakit Kulit," 2018. [Online]. Available: <http://tunasbangsa.ac.id/ejurnal/index.php/jsakti>
- [22] Mustakim, Rosdina, D. Ramadhani, M. Afdal, and M. Rahmawita, "The Classification Status of River Water Quality in Riau Province Using Modified K-Nearest Neighbor Algorithm with STORET Modeling and Water Pollution Index," *J Phys Conf Ser*, vol. 1783, no. 1, p. 012020, Feb. 2021, doi: 10.1088/1742-6596/1783/1/012020.
- [23] A. Riani, Y. Susianto, and N. Rahman, "Implementasi Data Mining Untuk Memprediksi Penyakit Jantung Menggunakan Metode Naive Bayes," *Journal of Innovation Information Technology and Application (JINITA)*, vol. 1, no. 01, pp. 25–34, Dec. 2019, doi: 10.35970/jinita.v1i01.64.
- [24] Mustakim *et al.*, "Data Sharing Technique Modeling for Naive Bayes Classifier for Eligibility Classification of Recipient Students in the Smart Indonesia Program," *J Phys Conf Ser*, vol. 1424, no. 1, p. 012009, Dec. 2019, doi: 10.1088/1742-6596/1424/1/012009.
- [25] D. Novianti, S. Nusa, M. Jakarta, and C. Sitasi, "Implementasi Algoritma Naïve Bayes Pada Data Set Hepatitis Menggunakan Rapid Miner," *Jurnal Komputer dan Informatika Akademi Bina Saran Informatika*, vol. 21, no. 1, pp. 49–54, 2019, doi: 10.31294/p.v20i2.
- [26] S. Situmorang, "Analisis Kinerja Algoritma Machine Learning Dalam Deteksi Anomali Jaringan," *Jurnal Matematika dan Ilmu Pengetahuan Alam*, vol. 1, no. 4, 2023, doi: 10.59581/konstanta.v1i4.1722.
- [27] I. Setiawati, A. P. Wibowo, A. Hermawan, M. Teknologi, I. Universitas, and T. Yogyakarta, "IMPLEMENTASI DECISION TREE UNTUK MENDIAGNOSIS PENYAKIT LIVER," *JURNAL OF INFORMATION SYSTEM MANAGEMENT*, vol. 1, no. 1, pp. 13–17, 2019.
- [28] F. Akbar, H. Wira Saputra, A. Karel Maulaya, and M. Fikri Hidayat, "Implementasi Algoritma Decision Tree C4.5 dan Support Vector Regression untuk Prediksi Penyakit Stroke," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 2, no. 2, pp. 61–67, 2022.
- [29] W. S. Dharmawan, "I N F O R M A T I K A DALAM PREDIKSI PENYAKIT JANTUNG," *Jurnal Informatika, Manajemen dan Komputer*, vol. 13, no. 2, 2021.
- [30] R. Nofitri and N. Irawati, "ANALISIS DATA HASIL KEUNTUNGAN MENGGUNAKAN SOFTWARE RAPIDMINER," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 5, no. 2, pp. 199–204, Jul. 2019, doi: 10.33330/jurtekxi.v5i2.365.
- [31] A. A. R and O. H. I, "PERFORMANCE EVALUATION OF SELECTED DISTANCE-BASED AND DISTRIBUTION-BASED CLUSTERING ALGORITHMS," *International Journal of Software Engineering and Computer Systems*, vol. 4, no. 2, pp. 38–48, Aug. 2018, doi: 10.15282/ijsecs.4.2.2018.3.0047.