Klasifikasi Status *Stunting* Balita Dengan Metode *Support Vector Machine* Berbasis Web

Fauzan Adzhima[1], Elvia Budianita[2], Alwis Nazir[3], Fadhilah Syafria[4]
[1,2,3,4]Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Riau, Indonesia
Email: 11950115064@students.uin-suska.ac.id[1], elvia.budianita@uin-suska.ac.id[2], alwis.nazir@uin-suska.ac.id[3], fadhilah.syafria@uin-suska.ac.id[4]

Abstrack - Parents should pay attention to their children during their toddler years because at that age, they are vulnerable to various growth and developmental disorders, one of which is stunting. Stunting is a growth and developmental disorder caused by nutritional deficiencies and is characterized by a height that does not meet the normal growth criteria for children of the same age. To prevent stunting, healthcare workers or integrated health post (Posyandu) cadres measures the anthropometry of children's bodies at Posyandu. The data from these body measurements are then processed manually, which poses a significant risk of processing errors due to human error. By studying the patterns in measurement data, data mining can help address issues in the data processing process. Support Vector Machine (SVM) is one of the commonly used data mining methods for classification problems, known for its ability to work with small memory and separate data that cannot be linearly separated. Age, gender, Early Initiation of Breastfeeding (EIBF), weight, and height are the attributes used for classification using the SVM algorithm. Based on the conducted tests, there were 1172 data points with an average performance result of the best model using the parameter $\gamma = 0.01$, achieving an accuracy of 98.99%. This means that the model can be used to accurately predict new measurement data, enabling timely preventive measures for stunting.

Keywords - Children, Stunting, Data Mining, Classification, Support Vector Machine

Intisari - Orang tua harus memperhatikan anak mereka saat balita, karena di usia tersebut mereka rentan terhadap berbagai gangguan pertumbuhan dan perkembangan, salah satunya *stunting*. *Stunting* adalah gangguan pertumbuhan dan perkembangan yang disebabkan oleh kekurangan gizi dan ditandai dengan tinggi badan yang tidak memenuhi kriteria pertumbuhan normal anak seusianya. Untuk mencegah *stunting*, tenaga kesehatan atau kader posyandu mengukur antropometri tubuh anak-anak di posyandu. Data hasil pengukuran tubuh anak diproses secara manual, sehingga ada kemungkinan besar kesalahan pemrosesan karena kesalahan manusia (*human error*). Dengan mempelajari pola data pengukuran, *data mining* dapat mengatasi masalah dalam proses pengolahan data pengukuran. SVM merupakan salah satu metode *data mining* yang umum dipakai untuk permasalahan klasifikasi dengan kelebihannya yang dapat bekerja dengan menggunakan memori yang kecil serta dapat memisah data yang tidak dapat dipisahkan secara linier. Usia, jenis kelamin, Inisiasi Menyusui Dini (IMD), berat badan, dan tinggi badan adalah atribut yang digunakan untuk klasifikasi menggunakan algoritma SVM ini. Berdasarkan pengujian yang dilakukan, terdapat 1172 data dengan hasil rata-rata performa model terbaik menggunakan parameter $\gamma = 0.01$ dan akurasi 98.99%, sehingga model dapat digunakan untuk memprediksi data pengukuran baru secara akurat dan tindakan pencegahan *stunting* dapat segera dilakukan.

Kata Kunci – Balita, *Stunting*, *Data Mining*, Klasifikasi, *Support Vector Machine*.

I. PENDAHULUAN

Gangguan petumbuhan atau *stunting* masih menjadi masalah utama yang banyak ditemukan pada balita di Indonesia. Hasil dari Survei Status Gizi Indonesia (SSGI) yang diumumkan oleh Kementrian Kesehatan pada Rapat Kerja Nasional BKKBN tahun 2023 menunjukkan bahwa prevalensi *stunting* di Indonesia mengalami penurunan dari 24,4%

menjadi 21,6% di tahun 2022 [1]. Pemerintah terus berupaya untuk menekan angka *stunting* balita berada di bawah 20%, mengikuti standar dari WHO.

Stunting merupakan gangguan pertumbuhan yang dialami oleh anak-anak karena gizi buruk, infeksi yang berulang, dan stimulasi psikososial yang kurang memadai [2]. *Stunting* ditandai dengan kondisi tubuh yang pendek atau sangat pendek berdasarkan indeks Panjang Badan menurut Umur (PB/U) atau Tinggi Badan menurut Umur (TB/U) berada pada ambang batas (*z-score*) antara -3 SD sampai dengan < -2 SD [3]. Faktor yang menyebabkan terjadinya *stunting* pada balita terbagi menjadi dua, yaitu faktor eksternal dari lingkungan masyarakat dan faktor internal yang meliputi keadaan di dalam lingkungan rumah. Faktor eksternal penyebab *stunting* diantaranya yaitu kebudayaan, pendidikan, pelayanan kesehatan, keadaan ekonomi dan politik, keadaan pertanian dan sistem pangan, serta kondisi air, sanitasi dan lingkungan. Sedangkan faktor internal dapat disebabkan dari perawatan anak yang kurang memadai, pemberian Air Susu Ibu (ASI) eksklusif dan Makanan Pendamping Air Susu Ibu (MPASI) yang kurang optimal, keadaan ibu, kondisi rumah, kualitas makanan yang rendah, keamanan makanan dan air, dan infeksi [4].

Penelitian terkait klasifikasi *stunting* juga dilakukan dengan menerapkan beberapa algoritma tertentu, seperti pada penelitian Syahrani Lonang dan Dwi Normawati dengan judul *Klasifikasi Status Stunting Pada Balita Menggunakan K-Nearest Neighbor Dengan Feature Selection Backward Elimination*. Penelitian tersebut menggunakan data dengan 2 kelas dan 9 atribut yaitu jenis kelamin, umur, berat, tinggi, berat badan dibandingkan umur (bb/u), *z-score* bb/u, berat badan dibandingkan tinggi badan (bb/tb), *z-score* bb/tb, *z-score* tb/u, mendapatkan hasil nilai akurasi 92,2%, presisi 93,7%, *recall* 71% dan *f1-score* 77,8% dengan menerapkan algoritma KNN dengan seleksi fitur *backward elimination* [5]. Penelitian lain yang dilakukan oleh Monica Yoshe Titimeidara dan Wiwien Hadikurniawati dengan judul penelitian *Implementasi Metode Naïve Bayes Classifier Untuk Klasifikasi Status Gizi Stunting Pada Balita*, mendapatkan hasil akurasi 88% dari proses klasifikasi terhadap data dengan 2 kelas dan 5 atribut yang disederhanakan menjadi 3 atribut yaitu umur, berat badan dan tinggi badan [6] Proses klasifikasi *stunting* dalam penelitian-penelitian tersebut menerapkan prinsip-prinsip *data mining*.

Data mining merupakan sebuah proses menemukan atau mengekstrak pola-pola, asosiasi, perubahan, anomali dan struktur yang penting dari kumpulan data yang disimpan dalam beberapa sumber data seperti *file system*, basis data, *data warehouse* atau tempat penyimpanan informasi lainnya [7]. Metode *data mining* dapat dibagi menjadi 2 kategori, yaitu deskriptif dan prediktif [8]. Metode deskriptif mencirikan sifat umum dari data, seperti analisa asosiasi dan analisas klastering. Sedangkan metode prediktif meringkas terhadap data yang tersedia, seperti analisa regresi dan analisa klasifikasi.

Klasifikasi merupakan proses menemukan model atau fungsi yang membedakan kelas data [9]. Proses utama dari klasifikasi yaitu membangun model dan melakukan klasifikasi (prediksi) pada objek data lain agar kelas objek tersebut dapat dilihat kemiripan karakteristiknya terhadap objek yang sudah tersimpan dalam model [10].

Dalam penelitian yang dilakukan oleh Dimas Aryo Anggoro dan Naqshauliza Devi Kurnia dengan judul *Comparison of Accuracy Level of Support Vector Machine (SVM) and K-Nearest Neighbors (KNN) Algorithms in Predicting Heart Disease*, digunakan sebuah *dataset* berjumlah 304 data dengan 14 atribut. Hasil dari penelitian tersebut menunjukkan bahwa akurasi dari algoritma SVM yaitu 90,10%, lebih besar dari akurasi algoritma KNN yaitu 81,31% [11]. Penelitian lain yang dilakukan oleh Yash Jayesh Chauhan dengan judul *Cardiovascular Disease Prediction using Classification Algorithms of Machine Learning*, data yang digunakan sebanyak 3751 data, terdiri dari 2 kelas yaitu pasien yang beresiko terkena penyakit jantung dan pasien yang tidak beresiko terkena penyakit jantung dengan 14 atribut. Berdasarkan penelitian tersebut, algoritma SVM mendapatkan hasil akurasi 88,13% [12]. Penelitian

mengenai klasifikasi *stunting* dengan algoritma SVM oleh Izzati Rahmi, Mega Susanti, Hazmira Yozza dan Frilianda Wulandari menggunakan data balita sebanyak 440 data. Atribut yang digunakan antara lain yaitu umur, panjang bayi saat lahir, jumlah tanggungan, jenis kelamin, pemasukan rata-rata, status pekerjaan, status menyusui, status kebiasaan ibu, pendidikan terakhir ibu, dan status pengetahuan ibu. Dari penelitian tersebut, parameter terbaik algoritma SVM dalam mengklasifikasikan data tersebut adalah dengan menggunakan *cost* = 10, *gamma* = 5 dan fungsi *kernel* RBF, dengan akurasi yang didapat yaitu 100%, menunjukkan bahwa data dapat diklasifikasikan dengan sangat baik [13].

Dalam penelitian ini, penulis bertujuan untuk menerapkan metode *data mining* dengan algoritma SVM dalam mengklasifikasi status *stunting* pada balita yang berbasis web untuk mengetahui apakah balita tersebut masuk dalam kategori *stunting*, sehingga dapat dilakukan tindakan pencegahan dini. Berdasarkan penelitian tentang penyebab dan gejala *stunting* yang telah dijelaskan, penelitian ini akan menggunakan data dengan 5 atribut yaitu usia, jenis kelamin, berat badan, tinggi badan dan Inisiasi Menyusui Dini (IMD).

II. SIGNIFIKANSI STUDI

A. *Metode Penelitian*

Tahapan dari proses klasifikasi *stunting* balita digambarkan dalam *flowchart* pada Gambar 1. Berikut proses dari penelitian yang akan dilakukan:

Gambar 1. Proses Penelitian

1. *Mengumpulkan Data*

Data yang digunakan yaitu data *stunting* balita dari beberapa provinsi di Indonesia. Total data berjumlah 1190 data yang disimpan dalam format *.xlsx*, dengan atribut Kelurahan, Anak_Ke, Tgl_Lahir, Jenis_Kelamin, NIK_Anak, Nama_Anak, BB_Lahir, PB_Lahir, Berat_Badan, Tinggi_Badan, Buku, IMD, Nama_Orangtua, No_Hp_Orangtua, Alamat, RT dan RW.

TABEL I
SUMBER DATA

Provinsi	Kota/Kabupaten	Tahun	Jumlah Data
Jawa Tengah	Grobogan	2018	20
Kalimantan Selatan	Hulu Sungai Tengah	2019	49
Kalimantan Tengah	Barito Utara	2017	30
Bengkulu	Kepahiang	2020	508
Jambi	Tanjung Jabung Timur	2018	39
Maluku	Maluku Tengah	2021	29
Sulawesi Tenggara	Muna Barat	2020	32
Sumatera Utara	Nias Utara	2020	73
Riau	Pekanbaru	2021	410
Total			1190

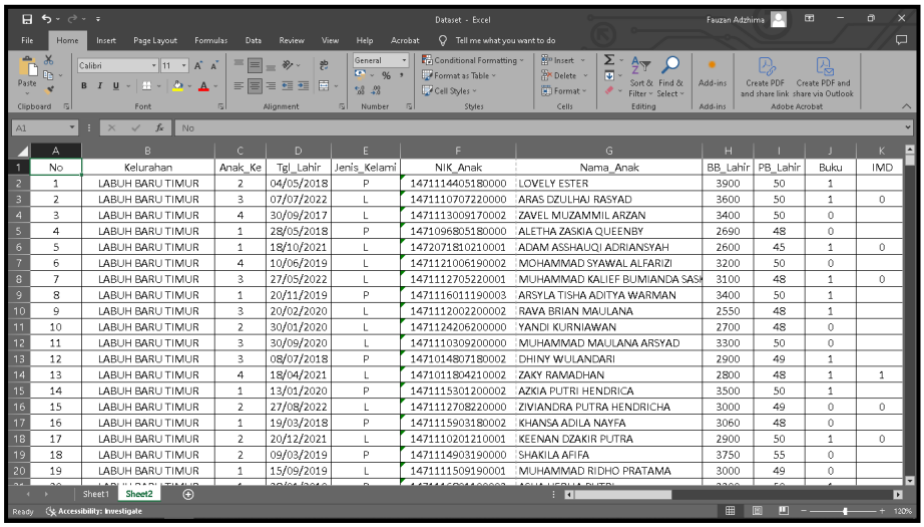

No	Kelurahan	Anak_Ke	Tgl_Lahir	Jenis_Kelami	NIK_Anak	Nama_Anak	BB_Lahir	PB_Lahir	Buku	IMD
1	LABUH BARU TIMUR	2	04/05/2018	P	1471114405180000	LOVELY ESTER	3900	50	1	
2	LABUH BARU TIMUR	3	07/07/2022	L	1471110707220000	ARAS DZULHAJ RASYAD	3600	50	1	0
3	LABUH BARU TIMUR	4	30/09/2017	L	1471113009170002	ZAVEL MUZAMMIL ARZAN	3400	50	0	
4	LABUH BARU TIMUR	1	28/05/2018	P	1471096805180000	ALETHA ZASKIA QUEENBY	2690	48	0	
5	LABUH BARU TIMUR	1	18/10/2021	L	1472071810210001	ADAM ASSHAUQI ADRIANSYAH	2600	45	1	0
6	LABUH BARU TIMUR	4	10/06/2019	L	1471121006190002	MOHAMMAD SYAWAL ALFARIZI	3200	50	0	
7	LABUH BARU TIMUR	3	27/05/2022	L	1471112705220001	MUHAMMAD KALIEF BUMIANDA SASH	3100	48	1	0
8	LABUH BARU TIMUR	1	20/11/2019	P	1471116011190003	ARSYLA TISHA ADITYA WARMAN	3400	50	1	
9	LABUH BARU TIMUR	3	20/02/2020	L	1471112002200002	RAWA BRIAN MAULANA	2550	48	1	
10	LABUH BARU TIMUR	2	30/01/2020	L	1471124206200000	YANDI KURNIAWAN	2700	48	0	
11	LABUH BARU TIMUR	3	30/09/2020	L	1471110309200000	MUHAMMAD MAULANA ARSYAD	3300	50	0	
12	LABUH BARU TIMUR	3	08/07/2018	P	1471014807180002	DHINY WULANDARI	2900	49	1	
13	LABUH BARU TIMUR	4	18/04/2021	L	1471011804210002	ZAKY RAMADHAN	2800	48	1	1
14	LABUH BARU TIMUR	1	13/01/2020	P	1471115301200002	AZKIA PUTRI HENDRICA	3500	50	1	
15	LABUH BARU TIMUR	2	27/08/2022	L	1471112708220000	ZIVIANDRA PUTRA HENDRICHA	3000	49	0	0
16	LABUH BARU TIMUR	1	19/03/2018	P	1471115903180002	KHANSA ADILA NAYFA	3060	48	0	
17	LABUH BARU TIMUR	2	20/12/2021	L	1471110201210001	KEENAN DZAKIR PUTRA	2900	50	1	0
18	LABUH BARU TIMUR	2	09/03/2019	P	1471114903190000	SHAKILA AFIFA	3750	55	0	
19	LABUH BARU TIMUR	1	15/09/2019	L	1471111509190001	MUHAMMAD RIDHO PRATAMA	3000	49	0	

Gambar 2. Atribut Data

2. Analisa Kebutuhan Data

Data yang digunakan berjumlah 1190 data *stunting* balita yang diambil dari hasil pengukuran balita di beberapa provinsi di Indonesia. Untuk memaksimalkaan performa dari model yang akan dibangun, perlu dilakukan *preprocessing* terhadap data yang akan digunakan.

a) *Data Selection*

Langkah pertama dari tahapan *preprocessing* adalah memilih atribut yang memiliki pengaruh signifikan terhadap karakteristik dari kelas dari data. Dalam penelitian ini, atribut yang dipakai yaitu usia, jenis kelamin, Inisiasi Menyusui Dini (IMD), berat badan, tinggi badan, dan 2 kelas yaitu status dengan nilai normal dan *stunting*.

b) *Data Cleaning*

Tahap berikutnya dari *preprocessing* yaitu membersihkan data. Tujuannya adalah untuk membersihkan data dari baris data yang kosong dan tidak konsisten, sehingga model dapat dibangun dengan performa yang baik. Setelah melakukan pembersihan, data berkurang menjadi 1172 data dengan 851 kelas normal dan 321 kelas *stunting*. Data kemudian disimpan dalam format *.xlsx* dengan menggunakan aplikasi *Microsoft Office Excel*.

c) *Data Encoding*

Data dilakukan proses *encoding* untuk menyesuaikan dengan algoritma yang dipakai yaitu SVM. Metode *encoding* yang digunakan adalah *One-Hot Encoding*. Metode ini menghasilkan atribut baru dari atribut nominal seperti atribut jenis kelamin dan IMD. Sedangkan untuk kelas menggunakan metode *Label Encoding*, sehingga kelas normal menjadi bernilai 0 dan kelas *stunting* menjadi bernilai 1.

3. Analisa Metode SVM

Metode atau algoritma SVM (*Support Vector Machine*) merupakan salah satu metode klasifikasi yang bekerja dengan cara memisah dua buah kelas dengan sebuah *hyperplane* terbaik yang ditemukan. Metode SVM menggunakan fungsi-fungsi linier dalam ruang fitur berdimensi tinggi. Akurasi dari model SVM yang dibangun sangat bergantung pada fungsi *kernel* dan parameter yang digunakan [14].

Langkah-langkah dalam melakukan perhitungan dari klasifikasi dengan metode SVM dapat dijelaskan sebagai berikut. Pertama, tentukan *kernel* yang akan dipakai, dalam hal ini yaitu *kernel polynomial*. Fungsi dari kernel ini ditunjukkan dengan persamaan berikut.

$$K(x, y) = (x^T.\mathrm{y} + \mathrm{c})^2 \quad (1)$$

Dimana $K(x, y)$ merupakan fungsi *kernel polynomial*, x^T adalah *transpose* dari data x, y untuk kelas data, dan c merupakan konstanta. Berdasarkan persamaan fungsi *kernel polynomial*, dapat dilakukan pemetaan fitur untuk data x , sehingga didapat persamaan pemetaan fitur.

$$\varphi(x) = [(x^T.\mathrm{x} + \mathrm{c})^2] \quad (2)$$

Ulangi proses ini untuk semua data x untuk mendapatkan pemetaan fitur $\varphi(x)$ di setiap data x. Untuk mendapatkan pembatas dari tiap kelas maka digunakan persamaan berikut.

$$\left(\frac{1}{2}\right) \times \|w\|^2 \quad (3)$$

Dimana w adalah bobot vektor yang menentukan pembatas, dan ||w|| merupakan norma *Euclidean* dari bobot vektor w. Kemudian, dengan nilai bobot vektor yang didapat, maka klasifikasi tiap kelas dapat ditentukan dengan persamaan berikut.

$$y_i \times (w^T \times \varphi(x_i) + b) \geq 1 \quad (4)$$

Semua data latih (x_i, y_i) dihitung dengan persamaan diatas. $\varphi(x_i)$ adalah pemetaan fitur terhadap data latih ke -i, sedangkan y_i adalah kelas data ke -i. Penentuan kelas dari data baru dengan menggunakan persamaan berikut.

$$f(x_j) = sign(w^T \times \varphi(x_j) + b) \quad (5)$$

$f(x_j)$ merupakan kelas data baru. Jika $f(x_j)$ lebih besar atau sama dengan 0.5, maka data merupakan kelas *stunting*, dan jika $f(x_j)$ lebih kecil dari 0.5, maka data merupakan kelas normal.

4. Analisa Fungsional Sistem

Fungsionalitas dari sistem klasifikasi status *stunting* balita dengan metode SVM dapat dilihat pada *use case diagram* berikut.

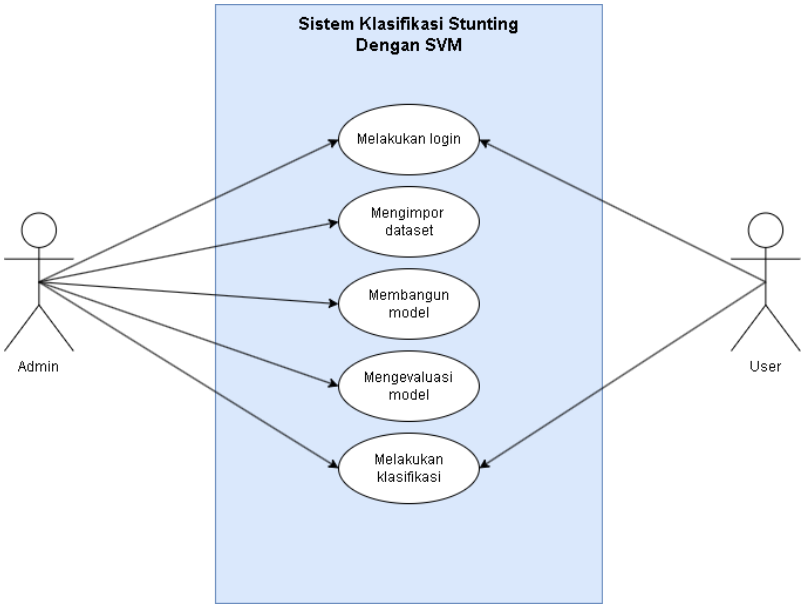

Gambar 3. *Use Case Diagram* Sistem Klasifikasi Status *Stunting* Balita Dengan SVM

III. HASIL DAN PEMBAHASAN

A. *Implementasi*

Implementasi sistem klasifikasi status *stunting* balita dengan menggunakan metode SVM dapat dilihat pada gambar 4.

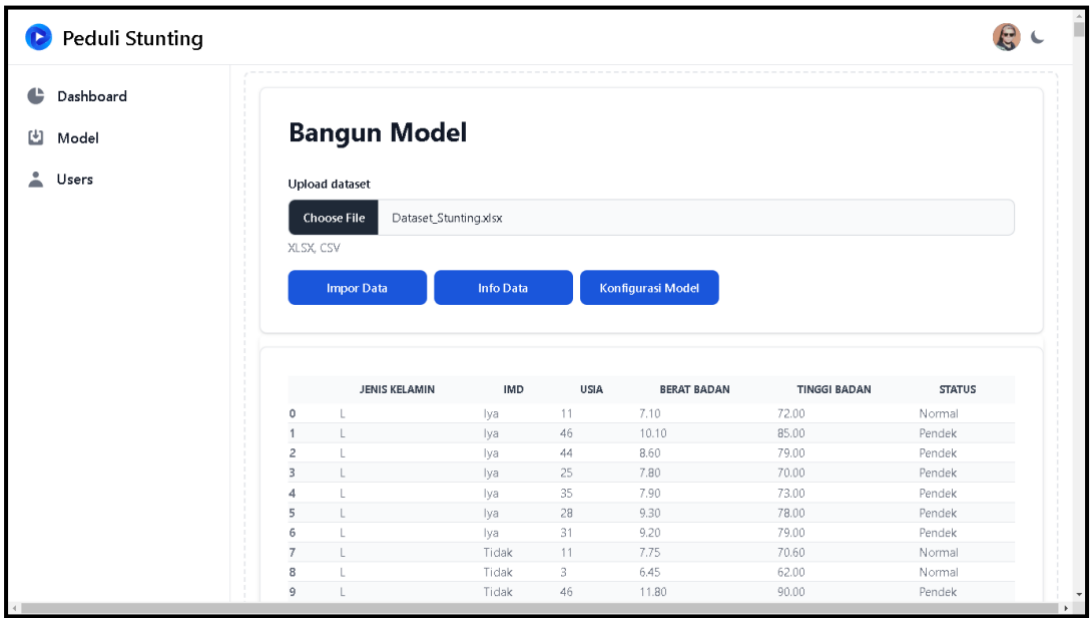

Gambar 4. Halaman Bangun Model

Gambar 4 merupakan gambar tampilan halaman untuk membangun model. Dalam halaman ini, ada beberapa perintah yang dapat dilakukan, diantaranya mengimpor *dataset* yang akan digunakan, melakukan *encoding data*, dan mengatur konfigurasi dari model yang akan dibangun. Data yang digunakan saat penelitian berjumlah 1172 data, dengan 5 atribut. Proses *encoding* data akan menghasilkan 2 atribut tambahan, sehingga jumlah atribut keseluruhan yang digunakan adalah 7 atribut, yaitu usia, berat badan, tinggi badan, jenis kelamin_L, jenis kelamin_P, IMD_Iya, IMD_Tidak.

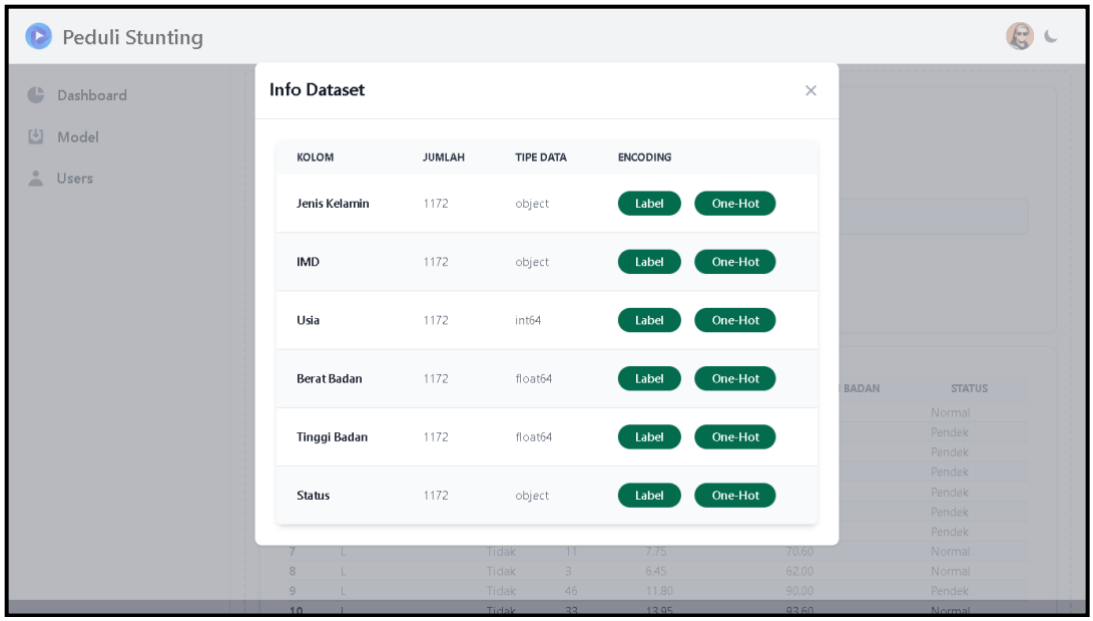

Gambar 5. Halaman *Encoding Data*

Gambar 5 menampilkan sebuah jendela untuk melakukan *encoding data*. Opsi dari *encoding data* yaitu *One-Hot* dan *Label*. *One-Hot Encoding* untuk data atribut, dan *Label Encoding* untuk data kelas. Atribut yang dapat dilakukan *encoding* adalah atribut dengan tipe data *object*, seperti yang terlihat pada gambar 5.

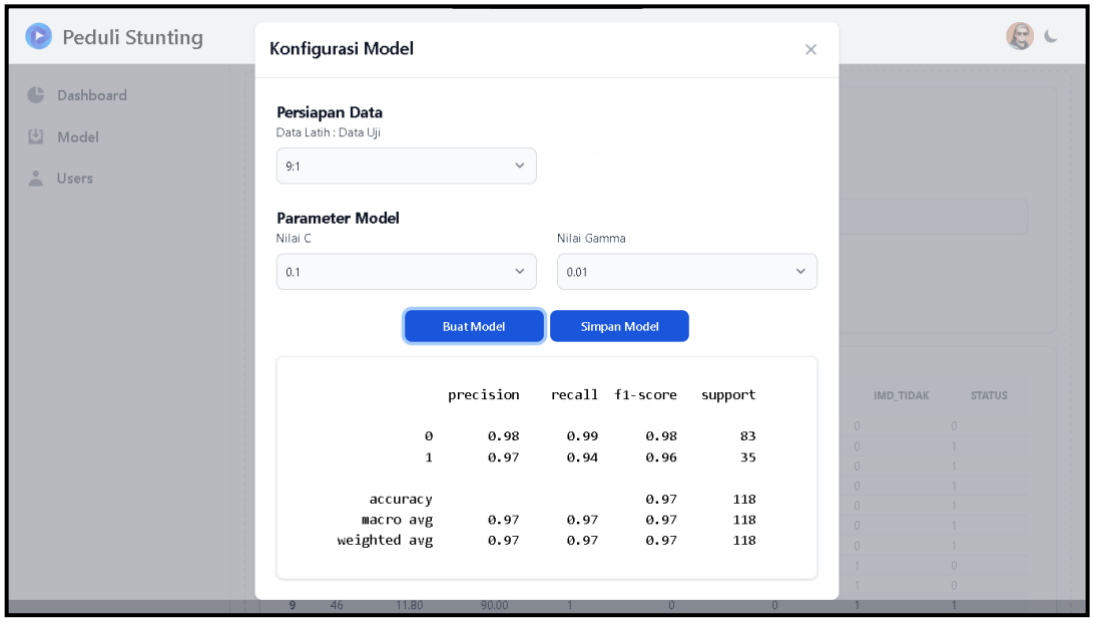

Gambar 6. Halaman Konfigurasi Model

Setelah proses *encoding data* selesai, maka bisa dilanjutkan dengan proses konfigurasi model, dimana parameter dari model yang akan dibangun dapat diatur untuk mendapatkan model dengan performa terbaik. Gambar 6 menunjukkan hasil performa dari model yang telah dibangun, yaitu akurasi, *f1-score*, *recall*, dan *precision*.

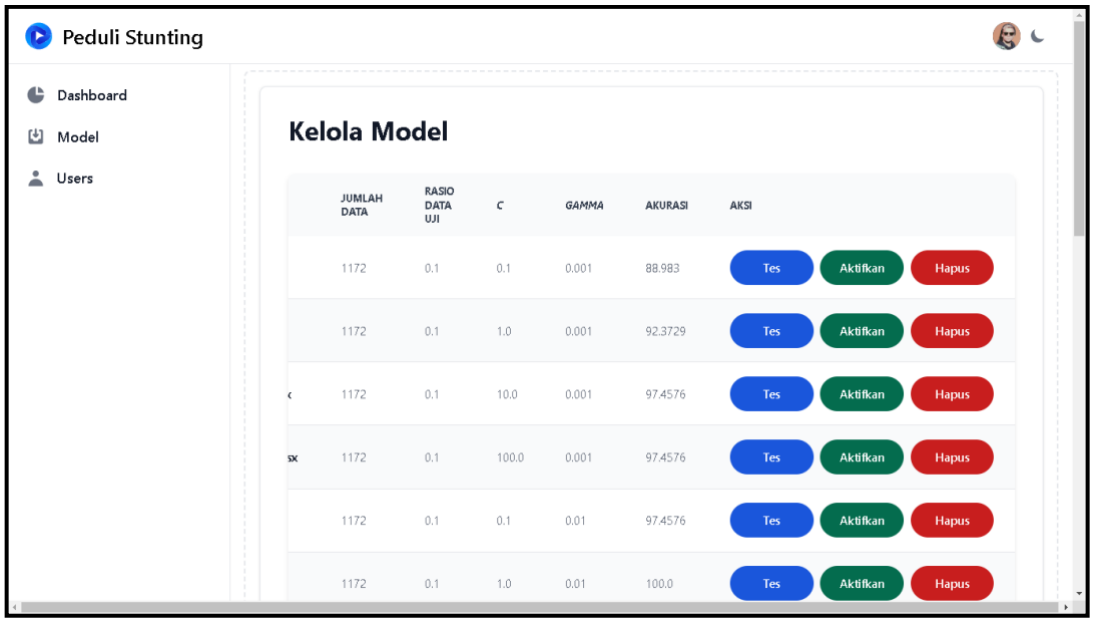

Gambar 7. Halaman Kelola Model

Model-model yang sudah dibangun disimpan ke dalam *database*. Model tersebut dapat dikelola oleh *Admin* untuk dilakukan pengujian terhadap model yang sudah dibangun, aktivasi model yang akan digunakan dalam sistem, dan penghapusan model.

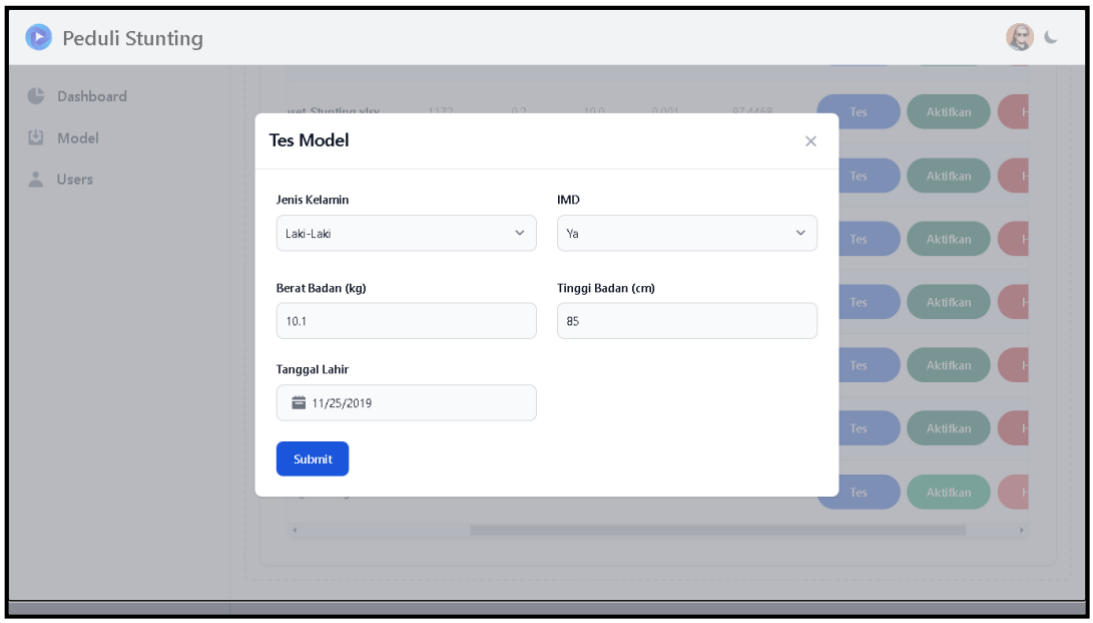

Gambar 8. Halaman Prediksi Data

Prediksi dapat dilakukan dengan menginput data pengukuran balita, yaitu jenis kelamin, IMD, berat badan, tinggi badan, dan tanggal lahir.

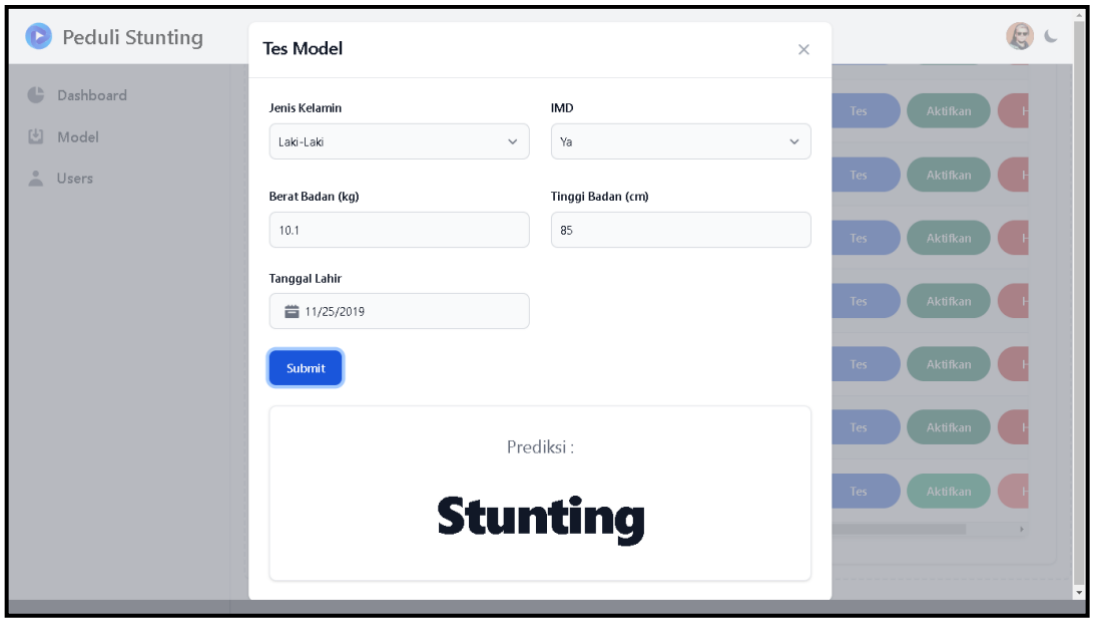

Gambar 9. Halaman Hasil Prediksi

Gambar 9 menampilkan hasil dari prediksi status *stunting* balita dengan menggunakan *input* data seperti yang terlihat pada gambar 8.

B. Pengujian

1. Pengujian Black Box

Sistem dilakukan pengujian dengan menggunakan metode *Black Box testing*. Penggunaan *Black Box testing* bertujuan untuk menguji fungsionalitas sistem, apakah sistem sudah menghasilkan respon yang sesuai terhadap perintah dan *input* pengguna, tanpa mengetahui secara langsung cara kerja sistem tersebut.

Hasil dari pengujian *Black Box* terhadap sistem klasifikasi status *stunting* balita dengan metode SVM ditunjukkan dengan Tabel II.

TABEL III
PENGUJIAN *BLACK BOX*

Input	Proses	Output	Hasil Uji
Tombol *home*	Menampilkan halaman utama	Halaman *home* tampil	Berhasil
Tombol bangun model	Menampilkan halaman untuk membangun model	Halaman bangun model tampil	Berhasil
Tombol *import* data	Menampilkan dataset yang akan digunakan	Halaman bangun model dengan tabel dataset	Berhasil
Tombol info data	Menampilkan informasi tipe data mengenai data yang digunakan	Halaman bangun model dengan jendela info data	Berhasil
Tombol konfigurasi model	Menampilkan konfigurasi parameter model yang akan dibangun	Halaman bangun model dengan jendela konfigurasi model	Berhasil
Tombol Prediksi	Melakukan proses prediksi dan menampilkan hasil prediksinya	Halaman Kelola model dengan jendela prediksi	Berhasil

2. Evaluasi Confusion Matrix

Model dilakukan evaluasi dengan menggunakan *confusion matrix*, dengan beberapa kali pengujian. Adapun parameter yang digunakan dalam pengujian yaitu nilai γ (*gamma*), nilai C

(konstanta C), serta perbandingan data latih dan data uji. Hasil pengujian dengan nilai γ = 0.001 terdapat pada Tabel III.

TABEL IIIII
PENGUJIAN DENGAN γ = 0.001

γ	C	Data	Akurasi
0.001	0.1	90:10	88.99%
0.001	1	90:10	92.37%
0.001	10	90:10	97.45%
0.001	100	90:10	97.45%
0.001	0.1	80:20	90.63%
0.001	1	80:20	93.61%
0.001	10	80:20	97.44%
0.001	100	80:20	97.83%
Rata-rata			94.47%

Tabel 3 menunjukkan hasil dari pengujian dengan menggunakan parameter γ = 0.001. Hasil pengujian terbaik diperoleh pada perbandingan data 80:20 dan nilai C = 100, dengan akurasi 97.83%. Rata-rata dari hasil pengujian dengan nilai γ = 0.001 mendapatkan model dengan akurasi 94.47%.

TABEL IVV
PENGUJIAN DENGAN γ = 0.01

γ	C	Data	Akurasi
0.01	0.1	90:10	97.45%
0.01	1	90:10	100%
0.01	10	90:10	99.15%
0.01	100	90:10	99.15%
0.01	0.1	80:20	97.87%
0.01	1	80:20	99.57%
0.01	10	80:20	99.57%
0.01	100	80:20	99.14%
Rata-rata			98.99%

Hasil pengujian dengan nilai γ = 0.01 menunjukkan performa yang lebih baik dari pengujian sebelumnya. Performa terbaik dihasilkan dari parameter γ = 0.01 dan C = 1 pada data dengan perbandingan data latih dan data uji yaitu 90:10. Rata-rata hasil pengujian dengan menggunakan nilai γ = 0.01 mendapatkan model dengan akurasi 98.99%. Hasil pengujian ini menunjukkan bahwa dengan menggunakan parameter γ = 0.01 akan mendapatkan model dengan performa terbaik untuk *dataset* yang digunakan dalam penelitian ini.

IV. KESIMPULAN

Pengujian fungsionalitas sistem dengan metode *Black Box testing* menunjukkan bahwa sistem klasifikasi status *stunting* balita dengan metode SVM dapat memberikan respon yang sesuai dengan perintah dan masukan *user* terhadap sistem. Berdasarkan hasil pengujian dengan menggunakan *confusion matrix*, dapat disimpulkan bahwa model terbaik dalam penelitian ini didapat dengan menggunakan parameter γ = 0.01 terhadap klasifikasi dengan atribut usia, jenis kelamin, Inisiasi Menyusui Dini (IMD), berat badan dan tinggi badan. Rata-rata akurasi dari model dengan parameter γ = 0.01 mencapai 98.99%. Hasil dari penelitian ini menunjukkan

bahwa algoritma SVM memiliki performa yang lebih baik dibandingkan dengan algoritma-algoritma lainnya yang telah dilakukan dalam penelitian-penelitian sebelumnya terkait klasifikasi *stunting*.

Dari penelitian ini dapat disimpulkan bahwa algoritma SVM dapat digunakan untuk mengklasifikasi status *stunting* balita secara akurat, serta dengan penerapan berbasis web yang telah diuji secara fungsionalitas, diharapkan dapat mempermudah dan mempercepat pengambilan tindakan pencegahan terhadap balita yang terindikasi *stunting* bagi tenaga kesehatan, kader posyandu, maupun orang tua.

REFERENSI

[1] Kementerian Kesehatan RI, "Prevalensi Stunting di Indonesia Turun ke 21,6% dari 24,4%", *Biro Komunikasi dan Pelayanan Publik, Kementerian Kesehatan RI*, Jan. 25, 2023. Accessed: Sep. 18, 2023. [Online]. Available: https://sehatnegeriku.kemkes.go.id/baca/rilis-media/20230125/3142280/prevalensi-stunting-di-indonesia-turun-ke-216-dari-244/

[2] World Health Organization, "Stunting in a nutshell", Nov. 19, 2015. Accessed: Sep. 19, 2023. [Online]. Available: https://www.who.int/news/item/19-11-2015-stunting-in-a-nutshell

[3] N. D. Yanti;, F. Betriana, and I. R. Kartika, "Faktor Penyebab Stunting pada Anak: Tinjauan Literatur", *Real in Nursing Journal*, vol. 3, no. 1, pp. 1–10, 2020, [Online]. Available: https://ojs.fdk.ac.id/index.php/Nursing/article/view/447/227

[4] N. O. Nirmalasari, "STUNTING PADA ANAK: PENYEBAB DAN FAKTOR RISIKO STUNTING DI INDONESIA", *QAWWAM: JOURNAL FOR GENDER MAINSTREAMING*, vol. 14, no. 1, pp. 19–28, 2020.

[5] S. Lonang and D. Normawati, "Klasifikasi Status Stunting Pada Balita Menggunakan K-Nearest Neighbor Dengan Feature Selection Backward Elimination", *Jurnal Media Informatika Budidarma*, vol. 6, no. 1, p. 49, 2022, doi: 10.30865/mib.v6i1.3312.

[6] M. Y. Titimeidara and W. Hadikurniawati, "Implementasi Metode Naïve Bayes Classifier Untuk Klasifikasi Status Gizi Stunting Pada Balita", *Jurnal Ilmiah Informatika*, vol. 9, no. 01, pp. 54–59, 2021, doi: 10.33884/jif.v9i01.3741.

[7] J. Han, M. Kamber, and J. Pei, "*Data Mining: Concepts and Techniques (3rd ed.)"*, 3rd ed. Elsevier/Morgan Kaufmann, 2012.

[8] J. Yang *et al.*, "Brief introduction of medical database and data mining technology in big data era", *J Evid Based Med*, vol. 13, no. 1, pp. 57–69, Feb. 2020, doi: 10.1111/jebm.12373.

[9] N. B. Putri and A. W. Wijayanto, "Analisis Komparasi Algoritma Klasifikasi Data Mining Dalam Klasifikasi Website Phishing", *Komputika : Jurnal Sistem Komputer*, vol. 11, no. 1, pp. 59–66, Jan. 2022, doi: 10.34010/komputika.v11i1.4350.

[10] H. F. Putro, R. T. Vulandari, and W. L. Y. Saptomo, "Penerapan Metode Naive Bayes Untuk Klasifikasi Pelanggan", *Jurnal Teknologi Informasi dan Komunikasi (TIKomSiN)*, vol. 8, no. 2, Oct. 2020, doi: 10.30646/tikomsin.v8i2.500.

[11] D. A. Anggoro and N. D. Kurnia, "Comparison of Accuracy Level of Support Vector Machine (SVM) and K-Nearest Neighbors (KNN) Algorithms in Predicting Heart Disease", *International Journal of Emerging Trends in Engineering Research*, vol. 8, no. 5, pp. 1689–1694, 2020, doi: 10.30534/ijeter/2020/32852020.

[12] Y. J. Chauhan, "Cardiovascular Disease Prediction using Classification Algorithms of Machine Learning", *International Journal of Science and Research*, vol. Volume 9, no. Isuue 5 May, pp. 194–200, 2020, doi: 10.21275/SR20501193934.

[13] I. Rahmi, M. Susanti, H. Yozza, and F. Wulandari, "CLASSIFICATION OF STUNTING IN CHILDREN UNDER FIVE YEARS IN PADANG CITY USING SUPPORT VECTOR MACHINE", *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 16, no. 3, pp. 771–778, Sep. 2022, doi: 10.30598/barekengvol16iss3pp771-778.

[14] P. A. Octaviani, Y. Wilandari, and D. Ispriyanti, "PENERAPAN METODE KLASIFIKASI SUPPORT VECTOR MACHINE (SVM) PADA DATA AKREDITASI SEKOLAH DASAR (SD) DI KABUPATEN MAGELANG", *Jurnal Gaussian*, vol. 3, pp. 811–820, Oct. 2014.