

Implementasi *Support Vector Machine* (SVM) dalam Penentuan Klasifikasi Indeks Khusus Penanganan *Stunting* di Indonesia

(*On Implementation of Support Vector Machine (SVM) in Determining the Classification of Stunting-Specific Intervention Index in Indonesia*)

Vicky Alfina Nur Syafika *, Ria Dhea Layla Nur Karisma

Program Studi Matematika, Universitas Islam Negeri Maulana Malik Ibrahim Malang
Jl. Gajayana No. 50, Dinoyo, Kecamatan Lowokwaru, Kota Malang, Jawa Timur 65144
E-mail: riadhea@uin-malang.ac.id

ABSTRAK

Stunting merupakan masalah kesehatan yang menjadi tantangan di berbagai negara, salah satunya di Indonesia. Beberapa program penanganan *stunting* dari pemerintah dapat dievaluasi berdasarkan nilai indeks khusus penanganan *stunting*. Hasil evaluasi program penanganan *stunting* yang tepat akan memudahkan pemerintah dalam menentukan kebijakan selanjutnya. Penelitian ini bertujuan untuk mendapatkan klasifikasi dan tingkat akurasi klasifikasi indeks khusus penanganan *stunting* di Indonesia dengan metode *Support Vector Machine* (SVM). Hasil penelitian menunjukkan model terbaik klasifikasi indeks khusus penanganan *stunting* metode SVM menggunakan kernel polinomial dengan parameter $h = 1$ dan $C = 100$. Hasil klasifikasi yang diperoleh yaitu 4 Provinsi dengan kategori indeks khusus penanganan *stunting* rendah, 21 Provinsi dengan kategori indeks khusus penanganan *stunting* sedang, dan 9 Provinsi dengan kategori indeks khusus penanganan *stunting* tinggi. Tingkat akurasi klasifikasi indeks khusus penanganan *stunting* di Indonesia dengan metode *Support Vector Machine* (SVM) sebesar 100% menunjukkan metode SVM mampu mengklasifikasikan indeks khusus penanganan *stunting* di Indonesia dengan sangat baik.

Kata kunci: *Stunting*, Indeks Khusus Penanganan *Stunting*, *Support Vector Machine*, SVM

ABSTRACT

Stunting is a health problem that poses a challenge in various countries, including Indonesia. Several government *stunting* intervention programs can be evaluated based on the *stunting-specific intervention index*. Accurate evaluation results of *stunting* intervention programs will facilitate the government in determining the next policy. This study aims to obtain the classification and accuracy level of the *stunting-specific intervention index* in Indonesia using the *Support Vector Machine* (SVM) method. The results of the study showed that the best model for *stunting-specific intervention index* classification using the SVM method was the polynomial kernel with parameters $h = 1$ and $C = 100$. The resulting classification showed that there were 4 Provinces with low *stunting-specific intervention index* categories, 21 Provinces with moderate *stunting-specific intervention index* categories, and 9 Provinces with high *stunting-specific intervention index* categories. The 100% accuracy level of the *stunting-specific intervention index* classification in Indonesia using the SVM method indicates that the SVM methods is highly effective in classifying the *stunting-specific intervention index* in Indonesia.

Keywords: *Stunting*, *Stunting-Specific Intervention Index*, *Support Vector Machine*, SVM

PENDAHULUAN

Masalah *stunting* menjadi isu penting yang dijumpai dalam bidang kesehatan dari berbagai negara, salah satunya di Indonesia. Balita yang mengalami *stunting* memiliki tinggi badan yang lebih pendek daripada balita seusianya. Selain itu *stunting* juga dapat menghambat perkembangan kognitif pada anak dan memberi dampak hingga dewasa. Secara global, jumlah kasus *stunting* pada anak telah mencapai 144 juta kasus. Berdasarkan data Studi Status Gizi Indonesia (SSGI) tahun 2021, nilai prevalensi *stunting* di Indonesia mencapai angka 24,4% (Kemenkes RI, 2021). Nilai prevalensi yang dicapai belum memenuhi ambang batas yang telah ditetapkan oleh *World Health Organization* (WHO) yaitu sebesar 20% (WHO, 2020).

Pemerintah telah melakukan berbagai upaya untuk mencegah *stunting*, salah satunya ikut serta program *Scaling Up Nutrition* (SUN) pada tahun 2011 mengenai komitmen pemerintah bahwa setiap warga negara berhak memperoleh akses untuk mendapatkan makanan yang bergizi. Pada tahun 2013 pemerintah membentuk Gerakan Nasional Perbaikan Gizi (Gernas PPG) yang membahas mengenai rencana anggaran untuk 1000 HPK (Hari Pertama Kehidupan). Hal ini dikarenakan banyak kasus *stunting* yang disebabkan oleh kurangnya gizi pada masa 1000 HPK. Selain itu terdapat proyek *Investing in Nutrition and Early Years* dengan fokus pada peningkatan kualitas pelayanan kesehatan, kebutuhan air, nutrisi dan sanitasi (BPS, 2021).

Sebagai bentuk pengawasan dan evaluasi terkait perkembangan kinerja dari program penanganan *stunting*, maka disusun sebuah instrumen yaitu Indeks Khusus Penanganan *Stunting* (IKPS) pada tahun 2018. Indeks Khusus Penanganan *Stunting* (IKPS) adalah tolok ukur keberhasilan penanganan *stunting* yang terbentuk atas 6 dimensi dan 11 indikator. Dimensi yang terbentuk antara lain, dimensi kesehatan, gizi, perumahan, pangan, pendidikan, dan perlindungan sosial. Pada masing-masing dimensi terdiri dari beberapa indikator yang bersifat spesifik sehingga memudahkan terkait analisis perkembangan penanganan *stunting* di lapangan (BPS, 2021).

Salah satu metode yang dapat digunakan untuk melakukan klasifikasi indeks khusus penanganan *stunting* di Indonesia adalah *Support Vector Machine* (SVM). SVM pada awalnya digunakan untuk klasifikasi biner (*binary classification*), kemudian dikembangkan untuk masalah klasifikasi *multi-class* dengan kombinasi *binary classification* (Liang, 2004). SVM memiliki kelebihan yaitu dapat memberikan akurasi yang baik meskipun data yang dianalisis tidak seimbang dan kemampuan generalisasi yang tinggi (Siddiqui & Ali, 2016). Penelitian ini bertujuan untuk mendapatkan klasifikasi dan tingkat akurasi indeks khusus penanganan *stunting* di Indonesia dengan metode *Support Vector Machine* (SVM). Penelitian ini diharapkan dapat memberikan informasi kepada pemerintah sebagai bahan pertimbangan dalam menentukan kebijakan penanganan masalah *stunting* di Indonesia.

METODE

Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan metode klasifikasi *machine learning* dengan konsep kerja mencari margin yang maksimal pada *hyperplane* (Dickers, 2005). Klasifikasi dengan SVM mempunyai prinsip yang dapat dipisahkan secara linier, namun dalam tahap pengembangannya, SVM dibentuk untuk menangani permasalahan nonlinier. Proses menangani masalah nonlinier dapat dilakukan dengan memanfaatkan konsep kernel dalam ruang berdimensi tinggi untuk menentukan *hyperplane* sehingga margin antar kelas pada data dapat maksimal (Ayungtyas, 2017).

1. *Non-Linear Support Vector Machine*


Non-Linear Support Vector Machine merupakan pengembangan dalam proses menyelesaikan masalah data yang tidak bisa dipisahkan secara linear. Pada permasalahan nonlinier tidak memerlukan konstruksi secara eksplisit, tetapi akan menggunakan pendekatan fungsi kernel (Dickers, 2005). Fungsi kernel bekerja dengan melakukan proses transformasi data ke dalam ruang dimensi yang lebih tinggi (*feature space*), di mana data dapat dipisahkan secara linier. Proses penggunaan fungsi kernel agar dapat menyelesaikan permasalahan SVM nonlinier disebut *kernel trick* (Hamel, 2009). *Kernel trick* dapat dirumuskan sebagai berikut:

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \tag{1}$$

di mana:

Φ = notasi transformasi

x_i = dataset



Sumber: (Nugroho, 2008)

Gambar 1. Proses Transformasi Data dalam Ruang Dimensi Tinggi (*Feature Space*).

Berdasarkan Gambar 1 data antara kelas positif dan kelas negatif yang berdimensi dua tidak dapat dipisahkan oleh *hyperplane* secara *linear*. Kemudian dilakukan proses transformasi dengan melakukan pemetaan dari data berdimensi dua ke dalam ruang yang berdimensi lebih tinggi yaitu dimensi tiga, akibatnya antara kelas positif dan kelas negatif dapat dipisahkan oleh *hyperplane* secara *linear*. Proses pemetaan dapat dinotasikan sebagai berikut:

$$\Phi : R^p \rightarrow R^q, \text{dimana } p < q \tag{2}$$

di mana p dan q merupakan dimensi. Transformasi Φ didefinisikan secara implisit oleh fungsi kernel karena transformasi tersebut biasanya tidak diketahui. Proses menentukan klasifikasi data dapat dicari melalui persamaan berikut (Vapnik, 1995):

$$\begin{aligned} f(\Phi(x)) &= \text{sign}(w_i \cdot \Phi(x) + b) \\ f(\Phi(x)) &= \text{sign}\left(\sum_{i=1}^n \alpha_i y_i \Phi(x_i) \cdot \Phi(x_j) + b\right) \\ f(\Phi(x)) &= \text{sign}\left(\sum_{i=1}^n \alpha_i y_i K(x_i, x_j) + b\right) \end{aligned} \tag{3}$$

di mana $\alpha_i > 0$. Sedangkan nilai α_i dan b dapat dihitung menggunakan persamaan berikut:

$$\alpha_i = \frac{N}{\sum_{i=1}^N (K(x_i, x_j) y_i y_j)} \tag{4}$$

$$b = -\frac{1}{2}(wx^+ + wx^-) \tag{5}$$

di mana:

w = vektor pembobot

w_i = vektor pembobot pada i

b = bias

α_i = nilai bobot pada data

Fungsi kernel yang biasanya digunakan pada metode SVM diantaranya berikut (Han dkk., 2012):

a. Kernel Linier

$$K(x_i, x_j) = x_i \cdot x_j \tag{6}$$

b. Kernel Polinomial

$$K(x_i, x_j) = (x_i \cdot x_j + 1)^h \tag{7}$$

c. Kernel Gaussian Radial Basis Function (RBF)

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), \sigma \in \mathbb{R}^+ \tag{8}$$

d. Kernel Sigmoid

$$K(x_i, x_j) = \tanh(\kappa x_i \cdot x_j - \delta) \tag{9}$$

dengan h, σ, κ , dan δ sebagai parameter kernel.

Selain parameter bebas pada kernel, terdapat juga parameter pinalti kesalahan C yang ditentukan peneliti. Pada kernel linier dapat diaplikasikan untuk data yang bisa dipisahkan oleh *hyperplane* secara linier atau berbentuk garis. Sedangkan pada kernel nonlinier diaplikasikan untuk data yang bisa dipisahkan *hyperplane* dengan bentuk bidang di ruang berdimensi yang tinggi (Dikkers, 2005).

2. Support Vector Machine Multi Kelas

Support Vector Machine (SVM) multi kelas dapat diimplementasikan melalui dua pendekatan yaitu metode *one-against-all* dan *one-against-one*. Pendekatan *one-against-all* atau sering disebut pendekatan satu lawan semua memiliki konsep klasifikasi yang membandingkan antara satu kelas dengan semua kelas lainnya. Contohnya klasifikasi 3 kelas maka terbentuk 3 model, pada model SVM pertama diuji dengan seluruh data untuk melihat klasifikasi data ke dalam kelas 1 atau bukan. Selanjutnya model SVM kedua diuji dengan seluruh data untuk melihat klasifikasi data ke dalam kelas 2 atau bukan. Terakhir, model SVM ketiga diuji dengan seluruh data untuk melihat klasifikasi data ke dalam kelas 3 atau bukan. Sedangkan pendekatan *one-against-one* atau satu lawan satu adalah pendekatan dengan membentuk model SVM biner dari perbandingan satu kelas dengan satu kelas lainnya. Model SVM pertama akan diuji dengan seluruh data yang ada untuk mengetahui kelompok pada kelas 1 atau 2. Kemudian model kedua diuji dengan seluruh data yang ada untuk mengetahui kelompok pada kelas 2 atau 3. Selanjutnya model ketiga diuji dengan seluruh data yang ada untuk mengetahui kelompok pada kelas 1 atau 3 (Suyanto, 2019).

Pengukuran Ketepatan Klasifikasi

Pengukuran ketepatan klasifikasi bertujuan untuk mengetahui kebaikan dalam klasifikasi data yang dilakukan oleh *classifier*. Salah satu cara untuk menghitung ketepatan klasifikasi adalah menggunakan *confusion matrix*. Berikut adalah bentuk *confusion matrix* untuk permasalahan multi kelas (Markoulidakis dkk., 2021):

Tabel 1. Confusion Matrix.

Confusion Matrix		Kelas Aktual			
		C_1	C_2	...	C_N
Kelas Prediksi	C_1	$C_{1,1}$	FN	...	$C_{1,N}$
	C_2	FP	TP	...	FP

	C_N	$C_{N,1}$	FN	...	$C_{N,N}$

Berdasarkan Tabel 1. *confusion matrix* terdapat 4 istilah yaitu TP, FP, FN, dan TN. Pertama, TP (True Positive) yaitu hasil prediksi kelas positif tepat sesuai data aktual. Kemudian FP (*False Positive*) menunjukkan hasil prediksi kelas negatif berada di kelas positif. FN (*False Negative*) yaitu hasil prediksi kelas positif berada di kelas negatif dan TN (*True Negative*) yang menunjukkan hasil prediksi kelas negatif tepat sesuai data aktual (Hilmiyah, 2017). Pengukuran ketepatan klasifikasi dapat dilakukan dengan cara menghitung nilai *accuracy*, *precision*, *sensitivity*, dan *specificity*. *Accuracy* (akurasi) menunjukkan nilai atau persentase keakuratan hasil klasifikasi. *Precision* (presisi) digunakan untuk mengetahui rasio yang membandingkan antara kelas positif yang benar dengan keseluruhan prediksi kelas positif. Selanjutnya *sensitivity* atau *recall* menunjukkan proporsi kelas positif yang hasil prediksinya benar. Terakhir *specificity* yang menunjukkan proporsi kelas negatif yang hasil prediksinya benar (Han dkk., 2012).

Stunting

Stunting adalah kegagalan tumbuh kembang anak di bawah usia 5 tahun (balita) yang disebabkan oleh kurangnya gizi secara kronis dan infeksi berulang. Pada umumnya, *stunting* terjadi pada periode 1000 HPK yaitu mulai janin sampai anak berusia 23 bulan. Anak yang mengalami *stunting* memiliki tinggi badan di bawah minus 2 dari standar deviasi tinggi badan anak seusianya (BPS, 2021). Menurut *World Health Organization* (WHO) terdapat beberapa faktor yang menjadi penyebab *stunting* seperti pemberian ASI kurang optimal, terkena penyakit menular, malabsorpsi nutrisi, kemiskinan, pola asuh yang kurang memadai, kurangnya stimulasi pada anak dan adanya kerawanan pangan (WHO, 2014).

Data dan Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder. Data sekunder merupakan jenis data yang diperoleh dari sumber yang telah tersedia. Adapun data penelitian diakses melalui *website* Badan Pusat Statistik (BPS) Indonesia. Data yang digunakan terdiri dari variabel *dependent* (Y) dan variabel *independent* (X). Variabel yang akan digunakan pada penelitian sebagai berikut:

Tabel 2. Variabel Penelitian.

No.	Variabel		Skala	Keterangan
1.	Indeks Khusus Penanganan <i>Stunting</i> (IKPS) Menurut Provinsi di Indonesia	Y	Ordinal	Rendah : 41,7 – 54,4 Sedang : 54,5 – 67,2 Tinggi : 67,3 – 80,0
2.	Imunisasi	X_1	Rasio	0 – 90
3.	Penolong persalinan oleh tenaga kesehatan di fasilitas kesehatan	X_2	Rasio	0 – 100
4.	Keluarga Berencana (KB) modern	X_3	Rasio	0 – 80
5.	ASI eksklusif	X_4	Rasio	0 – 80
6.	Makanan Pendamping ASI	X_5	Rasio	0 – 80
7.	Air minum layak	X_6	Rasio	0 – 100
8.	Sanitasi layak	X_7	Rasio	0 – 100
9.	Ketidakcukupan konsumsi pangan	X_8	Rasio	0 – 60
10.	Pendidikan Anak Usia Dini (PAUD)	X_9	Rasio	0 – 90
11.	Pemanfaatan jaminan kesehatan	X_{10}	Rasio	0 – 80
12.	Penerima KPS/KKS	X_{11}	Rasio	0 – 80

Tahapan Penelitian

1. Pengumpulan data klasifikasi penanganan *stunting* yang terdiri dari variabel *dependent* dan variabel *independent*.
2. Melakukan normalisasi data pada indikator IKPS agar memiliki rentang dan arah yang sama.
3. Membagi data menjadi dua bagian yaitu data *training* dan data *testing* berdasarkan akurasi terbaik dari kombinasi beberapa persentase. Berikut hasil akurasi yang diperoleh:

Tabel 3. Akurasi Perbandingan Data Training dan Data Testing.

Data Training	Data Testing	Akurasi
70%	30%	70%
75%	25%	50%
80%	20%	85,61%
85%	15%	60%
90%	10%	66,67%

4. Membentuk model SVM menggunakan data *training* dengan proses sebagai berikut:
 - a. Menentukan metode pendekatan *hyperplane* SVM multi kelas yang akan digunakan dalam penentuan pembagian kelas.
 - b. Menentukan fungsi kernel yang akan digunakan untuk membentuk model SVM.
 - c. Menentukan parameter terbaik pada fungsi kernel.
 - d. Membentuk model SVM menggunakan fungsi kernel.
5. Melakukan evaluasi dengan data *testing* dan data *training* terkait ketepatan model klasifikasi metode SVM menggunakan *confusion matrix*.
6. Melakukan analisis terhadap hasil klasifikasi yang telah terbentuk dan menguji akurasi menggunakan *confusion matrix*.

HASIL DAN PEMBAHASAN

Normalisasi data pada indikator IKPS bertujuan agar semua indikator memiliki rentang dan arah yang sama. Pada indikator IKPS terdapat satu indikator yang memiliki arah negatif yaitu indikator ketidakcukupan konsumsi pangan. Sedangkan indikator lainnya memiliki arah positif. Langkah pertama dalam proses normalisasi yaitu menentukan nilai minimal dan nilai maksimal setiap indikator. Kemudian dilakukan normalisasi pada semua data dengan contoh perhitungan menggunakan data indeks khusus penanganan *stunting* Provinsi Jawa Timur sebagai berikut.

Indikator imunisasi dengan arah positif

$$KX_1 = \frac{66,12 - 0}{90 - 0} \times 100 = 73,47$$

Indikator ketidakcukupan konsumsi pangan dengan arah negatif

$$KX_8 = 100 - \left(\frac{8,58 - 0}{60 - 0} \times 100 \right) = 85,7$$

Hasil Klasifikasi dengan Metode Support Vector Machine

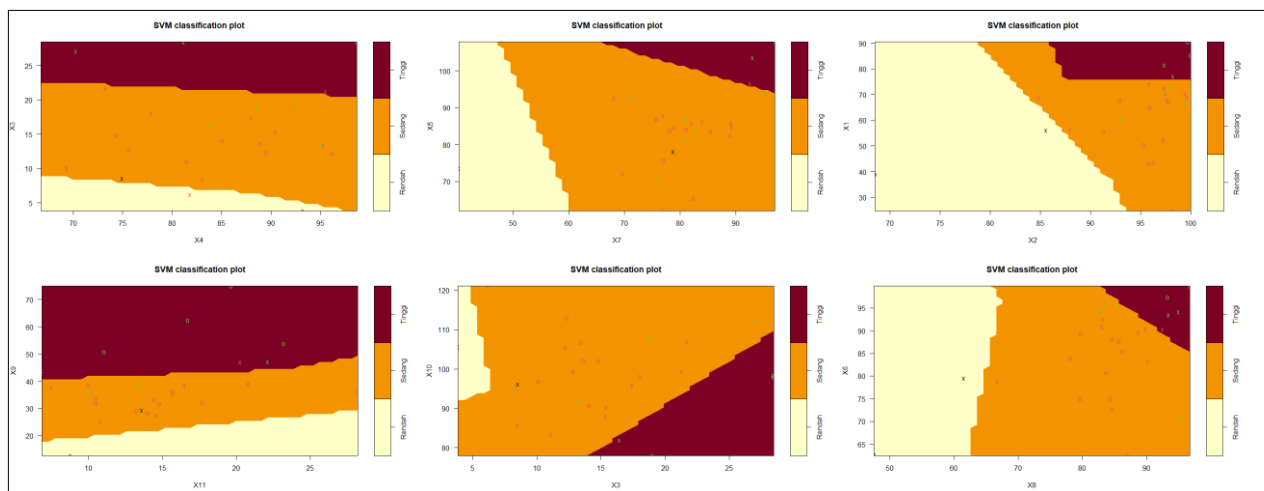
Proses klasifikasi dimulai dengan membagi data menjadi dua, yaitu data *training* dan data *testing*. Berdasarkan keseluruhan 34 data IKPS terdapat 27 data *training* dan 7 data *testing*. Tahapan awal dalam membentuk model SVM yaitu menentukan metode pendekatan SVM multi kelas yang berguna untuk pembagian kelas. Penelitian ini menggunakan pendekatan *one-against-one*. Kemudian fungsi kernel yang digunakan untuk klasifikasi SVM adalah kernel polinomial dengan parameter *degree* (h) yaitu 1, 2, dan 3 serta parameter *cost* (C) dengan rentang 10^{-2} sampai 10^2 . Metode yang digunakan dalam penentuan parameter terbaik ini menggunakan metode *trial and error* (Pratiwi & Ulama, 2016). Setelah model SVM terbentuk dengan menggunakan data *training*, maka diperoleh nilai akurasi model menggunakan data *testing* pada masing-masing parameter kernel polinomial sebagai berikut:

Tabel 4. Nilai Akurasi Parameter Model SVM Kernel Polinomial.

Parameter	Akurasi		
	h = 1	h = 2	h = 3
C = 0,01	57,14%	57,14%	57,14%
C = 0,1	57,14%	57,14%	57,14%
C = 1	100%	85,71%	85,71%
C = 10	100%	85,71%	100%
C = 100	100%	71,43%	100%

Berdasarkan *trial and error* yang telah dilakukan, diperoleh nilai akurasi tertinggi pada parameter *degree* (h) = 1 dengan nilai $C = 1$, $C = 10$, dan $C = 100$ serta parameter *degree* (h) = 3 dengan nilai $C = 10$ dan $C = 100$. Dari kelima model tersebut dilakukan analisis berdasarkan *number of support vectors* dan nilai *cost* (C) untuk menentukan model terbaik. Model SVM dengan jumlah *support vectors* yang kecil akan memiliki generalisasi yang baik (Han dkk., 2012). Pada penelitian ini diperoleh jumlah *support vectors* terkecil pada parameter *degree* (h) = 1 dengan nilai $C = 10$ dan $C = 100$ yaitu sebanyak 13 *support vectors*. Kemudian nilai *cost* (C) sebagai parameter regularisasi yang berperan dalam memaksimalkan margin dan meminimalkan kesalahan klasifikasi. Nilai *cost* (C) yang kecil cenderung memperluas margin dengan mengabaikan *outlier* pada data *training*, sedangkan nilai *cost* (C) yang besar akan menyesuaikan data *training* sehingga mengurangi kasus kesalahan klasifikasi (Don, 2018). Oleh karena itu model SVM terbaik untuk klasifikasi Indeks Khusus Penanganan *Stunting* di Indonesia adalah SVM kernel polinomial dengan parameter *degree* (h) = 1 dan $C = 100$.

Model klasifikasi SVM yang telah terbentuk dapat divisualisasikan dalam bentuk plot klasifikasi SVM. Plot dapat dibentuk dengan kombinasi dua variabel *independent* (X). Pada penelitian ini diperoleh 55 plot yang mencakup semua kombinasi antar variabel *independent* (X). Berikut beberapa contoh plot klasifikasi SVM dengan kernel polinomial parameter $h = 1$ dan $C = 100$.



Gambar 2. Plot Klasifikasi SVM Kernel Polinomial $h = 1$ dan $C = 100$.

Berdasarkan Gambar 2. contoh plot klasifikasi SVM yang mampu mengklasifikasikan data IKPS pada tiga kategori diperoleh informasi mengenai ketepatan klasifikasi data IKPS. Jika data IKPS dapat dipisahkan oleh *hyperplane* sesuai kategori masing-masing, maka variabel *independent* (X) yang membentuk plot memiliki peranan penting dalam pembentukan model. Variabel *independent* (X) yang berpengaruh besar dalam ketepatan model klasifikasi IKPS adalah variabel X_2 dan X_8 untuk kategori IKPS Rendah, variabel X_3 dan X_9 untuk kategori IKPS Sedang, serta variabel X_6 dan X_9 untuk kategori IKPS Tinggi.

Tabel 5. Kategori IKPS dan Variabel Terpenting Setiap Provinsi.

Variabel Terpenting	Kategori IKPS	Provinsi
Penolong persalinan oleh tenaga kesehatan di fasilitas kesehatan (X_2) Ketidacukupan pangan (X_8)	Rendah	Maluku, Maluku Utara, Papua, dan Papua Barat.
Keluarga Berencana (KB) modern (X_3) Pendidikan Anak Usia Dini (PAUD) (X_9)	Sedang	Aceh, Sumatera Utara, Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, Lampung, Kep. Bangka Belitung, Kep. Riau, Banten, NTT, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, dan Sulawesi Barat.
Air minum layak (X_6) Pendidikan Anak Usia Dini (PAUD) (X_9)	Tinggi	DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, Bali, NTB, Kalimantan Selatan, dan Gorontalo.

Berdasarkan Tabel 5. tentang variabel terpenting IKPS setiap provinsi dapat dijadikan landasan untuk melakukan evaluasi pada keenam variabel tersebut. Pemerintah pada provinsi dengan IKPS Rendah dapat mengambil tindakan dengan menambah dan mempermudah akses fasilitas kesehatan di daerah tersebut. Sedangkan untuk mengatasi ketidacukupan pangan dapat dilakukan dengan menambah dan memastikan program bantuan pangan telah diberikan tepat sesuai sasaran. Selanjutnya provinsi dengan kategori IKPS Sedang meningkatkan sosialisasi pentingnya KB dan dampak positif dari program KB, serta program PAUD Negeri yaitu program sekolah PAUD gratis. Terakhir provinsi dengan kategori IKPS Tinggi mempermudah akses air minum layak, mengevaluasi kinerja Perusahaan Air Minum Daerah (PDAM), dan sosialisasi program sekolah PAUD gratis.

Analisis Tingkat Akurasi Metode Support Vector Machine

Perhitungan ketepatan klasifikasi IKPS pada metode SVM kernel polinomial dengan parameter *degree* (h) = 1 dan $C = 100$ dapat dianalisis menggunakan data *testing* dan data *training* dari *confusion matrix* berikut:

Tabel 6. Confusion Matrix Menggunakan Data Testing.

Confusion Matrix		Kelas Aktual		
		Rendah	Sedang	Tinggi
Kelas Prediksi	Rendah	2	0	0
	Sedang	0	4	0
	Tinggi	0	0	1

Berdasarkan Tabel 6. *confusion matrix* menggunakan data *testing* diperoleh hasil bahwa 2 Provinsi yang memiliki kategori IKPS Rendah diprediksi benar menjadi Provinsi dengan kategori IKPS Rendah, 4 Provinsi yang memiliki kategori IKPS Sedang diprediksi benar menjadi Provinsi dengan kategori IKPS Sedang, dan 1 Provinsi yang memiliki kategori IKPS Tinggi diprediksi benar menjadi Provinsi dengan kategori IKPS Tinggi. Sedangkan perhitungan nilai *accuracy*, *precision*, *sensitivity*, dan *specificity* pada data *testing* sebagai berikut.

$$Accuracy = \frac{2 + 4 + 1}{2 + 4 + 1} \times 100\% = 100\%$$

$$Precision = \frac{1}{3} \times (1 + 1 + 1) \times 100\% = 100\%$$

$$Sensitivity = \frac{1}{3} \times (1 + 1 + 1) \times 100\% = 100\%$$

$$Specificity = \frac{1}{3} \times (1 + 1 + 1) \times 100\% = 100\%$$

Tabel 7. *Confusion Matrix* Menggunakan Data Training.

<i>Confusion Matrix</i>		Kelas Aktual		
		Rendah	Sedang	Tinggi
Kelas Prediksi	Rendah	2	0	0
	Sedang	0	17	0
	Tinggi	0	0	8

Berdasarkan Tabel 7. *confusion matrix* menggunakan data *training* diperoleh hasil bahwa 2 Provinsi yang memiliki kategori IKPS Rendah diprediksi benar menjadi Provinsi dengan kategori IKPS Rendah, 17 Provinsi yang memiliki kategori IKPS Sedang diprediksi benar menjadi Provinsi dengan kategori IKPS Sedang, dan 8 Provinsi yang memiliki kategori IKPS Tinggi diprediksi benar menjadi Provinsi dengan kategori IKPS Tinggi. Selanjutnya adalah perhitungan nilai *accuracy*, *precision*, *sensitivity*, dan *specificity* pada data *training*.


$$Accuracy = \frac{2 + 17 + 8}{2 + 17 + 8} \times 100\% = 100\%$$

$$Precision = \frac{1}{3} \times (1 + 1 + 1) \times 100\% = 100\%$$

$$Sensitivity = \frac{1}{3} \times (1 + 1 + 1) \times 100\% = 100\%$$

$$Specificity = \frac{1}{3} \times (1 + 1 + 1) \times 100\% = 100\%$$

Nilai akurasi (*accuracy*) klasifikasi IKPS menggunakan metode SVM pada data *testing* dan data *training* diperoleh sebesar 100%. Hal ini membuktikan bahwa metode SVM dapat melakukan klasifikasi pada permasalahan IKPS dengan sangat baik. Kemudian nilai *precision* sebesar 100% yang menunjukkan rasio perbandingan antara setiap kategori IKPS yaitu IKPS Rendah, Sedang, dan Tinggi sebagai kelas positif dengan keseluruhan hasil prediksi kelas positif. Nilai tersebut memiliki arti bahwa setiap kategori IKPS kelas positif diprediksi sebagai kelas positif dan tidak ada kategori IKPS kelas negatif yang diprediksi sebagai kelas positif. Selanjutnya nilai *sensitivity* sebesar 100% menunjukkan setiap kategori IKPS Rendah, Sedang, dan Tinggi sebagai kelas positif mampu diprediksi 100% benar bahwa setiap kategori IKPS tersebut berada di kelas positif. Terakhir nilai *specificity* sebesar 100% artinya setiap kategori IKPS Rendah, Sedang, dan Tinggi sebagai kelas negatif mampu diprediksi 100% benar bahwa setiap kategori IKPS tersebut berada di kelas negatif. Selain itu, hubungan antara *sensitivity* dan *specificity* dapat direpresentasikan dalam bentuk kurva ROC sebagai berikut.

Gambar 3. Kurva ROC (*Receiver Operating Characteristic*).

Kurva ROC (*Receiver Operating Characteristic*) pada Gambar 3. dapat digunakan sebagai evaluasi model klasifikasi IKPS dengan metode SVM. Pada kurva ROC, *True Positive Rate* atau *sensitivity* dibentuk plot terhadap *False Positive Rate* atau $1 - \text{specificity}$ dari model klasifikasi. Kemudian area di bawah kurva ROC terdapat AUC (*Area Under the Curve*) yaitu ukuran kebaikan model klasifikasi dalam membedakan setiap kelas (Don, 2018). Kurva ROC dan nilai AUC dari klasifikasi IKPS menunjukkan bahwa model klasifikasi

IKPS dengan metode SVM mampu memprediksi seluruh data *testing* dan data *training* IKPS dengan sangat baik. Hal ini dapat dilihat dari semakin luasnya area di bawah kurva ROC dan nilai AUC sebesar 1 yang mengindikasikan model klasifikasi IKPS dengan metode SVM dapat diterima (Hosmer dkk., 2013). Berikut hasil prediksi klasifikasi IKPS pada 34 provinsi di Indonesia beserta data observasi atau data yang sebenarnya.

Tabel 8. Hasil Prediksi IKPS Menggunakan SVM.

Provinsi	Prediksi	Observasi
Maluku, Maluku Utara, Papua, dan Papua Barat.	Rendah	Rendah
Aceh, Sumatera Utara, Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, Lampung, Kep. Bangka Belitung, Kep. Riau, Banten, NTT, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, dan Sulawesi Barat.	Sedang	Sedang
DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, Bali, NTB, Kalimantan Selatan, dan Gorontalo.	Tinggi	Tinggi

Berdasarkan Tabel 8. hasil prediksi IKPS menggunakan SVM membuktikan bahwa metode SVM mampu memprediksi dalam klasifikasi data IKPS menurut provinsi di Indonesia dengan sangat baik. Hasil prediksi menunjukkan dari 34 provinsi di Indonesia diperoleh kategori IKPS yang sama dengan data observasi atau data IKPS sebenarnya. Oleh karena itu, metode SVM menjadi salah satu metode yang tepat untuk klasifikasi IKPS di Indonesia.

KESIMPULAN

Berdasarkan hasil penelitian tersebut maka diperoleh kesimpulan bahwa klasifikasi metode *Support Vector Machine* (SVM) pada indeks khusus penanganan *stunting* di Indonesia menunjukkan model terbaik klasifikasi menggunakan kernel polinomial. Nilai parameter model klasifikasi kernel polinomial SVM yaitu model dengan parameter *degree* (h) = 1 dan nilai $C = 100$. Provinsi dengan kategori IKPS Rendah seperti Maluku, Maluku Utara, Papua, dan Papua Barat dilakukan evaluasi pada indikator penolong persalinan oleh tenaga kesehatan di fasilitas kesehatan dan ketidakcukupan pangan. Kemudian provinsi dengan kategori IKPS Sedang seperti Aceh, Sumatera Utara, Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, Lampung, Kep. Bangka Belitung, Kep. Riau, Banten, NTT, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, dan Sulawesi Barat dilakukan evaluasi pada indikator Keluarga Berencana (KB) modern dan Pendidikan Anak Usia Dini (PAUD). Selanjutnya provinsi dengan kategori IKPS Tinggi seperti DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, Bali, NTB, Kalimantan Selatan, dan Gorontalo dilakukan evaluasi pada indikator air minum layak dan Pendidikan Anak Usia Dini (PAUD). Kemudian tingkat akurasi klasifikasi indeks khusus penanganan *stunting* di Indonesia dengan metode *Support Vector Machine* (SVM) sebesar 100%. Hal ini menunjukkan bahwa metode SVM mampu mengklasifikasikan indeks khusus penanganan *stunting* di Indonesia dengan sangat baik.

DAFTAR PUSTAKA

- Ayungtyas, D. A. (2017). *Klasifikasi Menggunakan Metode Regresi Logistik dan Support Vector Machine* [Universitas Brawijaya]. <http://repository.ub.ac.id/id/eprint/3988>
- BPS. (2021). *Laporan Indeks Khusus Penanganan Stunting 2019-2020*. <https://www.bps.go.id/publication/2021/09/08/3b622d713a80363685aef508/laporan-indeks-khusus-penanganan-stunting-2019-2020.html>
- Dickers, H. J. (2005). *Support vector machines in ordinal classification* [Delft University of Technology]. https://www.researchgate.net/publication/228718638_Support_vector_machines_in_ordinal_classification
- Don, D. P. W. R. (2018). *Multiclass Classification Using Support Vector Machines* [Georgia Southern University]. <https://digitalcommons.georgiasouthern.edu/etd/1845/>
- Hamel, L. (2009). *Knowledge Discovery with Support Vector Machines*. John Wiley & Sons. <https://doi.org/10.1002/9780470503065>
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann. <https://doi.org/10.1016/C2009-0-61819-5>
- Hilmiyah, F. (2017). *Prediksi Kinerja Mahasiswa Menggunakan Support Vector Machine untuk Pengelola*

- Program Studi di Perguruan Tinggi (Studi Kasus: Program Studi Magister Statistika ITS)* [Institut Teknologi Sepuluh Nopember]. <http://repository.its.ac.id/id/eprint/46712>
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression*. John Wiley & Sons. <https://doi.org/10.1002/9781118548387>
- Kemenkes RI. (2021). *Hasil Studi Status Gizi Indonesia (SSGI) Tingkat Nasional, Provinsi, dan Kabupaten/Kota Tahun 2021*. Kemenkes RI. <https://www.litbang.kemkes.go.id/buku-saku-hasil-studi-status-gizi-indonesia-ssgi-tahun-2021/>
- Liang, J. Z. (2004). SVM Multi-Classfier and Web Document Classification. *Proceedings of 2004 International Conference on Machine Learning and Cybernetics*, 3, 1347–1351. <https://doi.org/10.1109/ICMLC.2004.1381982>
- Markoulidakis, I., Kopsiaftis, G., Rallis, I., Georgoulas, I., Doulamis, A., & Doulamis, N. (2021). Multi-Class Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. *Technologies*, 9(81), 1–22. <https://doi.org/10.3390/technologies9040081>
- Nugroho, A. S. (2008). Support Vector Machine : Paradigma Baru Dalam Softcomputing. *Konferensi Nasional Sistem Dan Informatika*, 92–99.
- Pratiwi, S. N. D., & Ulama, B. S. S. (2016). Klasifikasi Email Spam dengan Menggunakan Metode Support Vector Machine dan k-Nearest Neighbor. *Jurnal Sains Dan Seni ITS*, 5(2), 344–349.
- Siddiqui, F., & Ali, Q. M. (2016). Performance of non-parametric classifiers on highly skewed data. *Global Journal of Pure and Applied Mathematics*, 12(2), 1547–1565. <http://www.ripublication.com/gjgam.htm>
- Suyanto. (2019). *Data Mining untuk Klasifikasi dan Klasterisasi Data*. INFORMATIKA.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag New York. <https://doi.org/10.1007/978-1-4757-3264-1>
- WHO. (2014). *Global nutrition targets 2025: stunting policy brief (WHO/NMH/NHD/14.3)*. World Health Organization. <https://www.who.int/publications/i/item/WHO-NMH-NHD-14.3>
- WHO. (2020). *Levels and trends in child malnutrition: Key Findings of the 2020 Edition of the Joint Child Malnutrition Estimates*. World Health Organization. <https://www.who.int/publications/i/item/9789240003576>